التعمق في التعلم العميق

الجزء الاول: الاساسيات والمقدمات

تأليف : أنتون زانغ وآخرون

ترجمة : د. علاء طعيمة

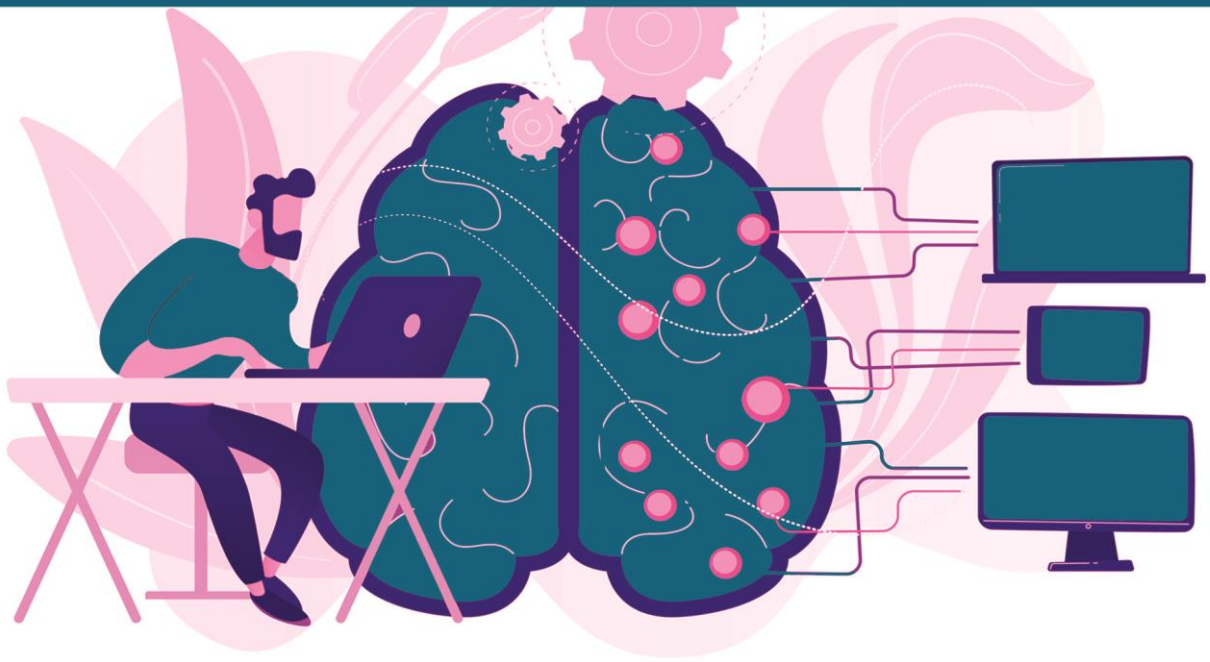

بـــمه تعالى

التعمق فى التعلم العميق

الأســاسيات والمقدمات

تأليف:

آــتون زانغ وآخرون

ترجمة:

د. علاء طعيمة

مقدمة المترجم

على مدى السنوات القليلة الماضية، طور فريق من علماء أمازون كتاباً " Dive into Deep Learning" يكتسب شعبية بين الطلاب والمطورين الذين ينجذبون إلى مجال التعلم العميق المزدهر، وهو مجموعة فرعية من التعلم الآلي تركز على الشبكات العصبية الاصطناعية واسعة النطاق.

عند انتهائي من قراءه هذا الكتاب، احببت ان اترجم هذا الكتاب وأشارككم هذه الترجمة لان هناك عدد من الأشياء الرائعة حول هذا الكتاب وأكثر ما يعجبني هو أنه يغطي كل مجالات التعلم العميق تقريبًا مثلاً للمبتدئين هناك فصول مثل الشبكات العصبية والبيرسيبترون متعدد الطبقات والانحدار والتصنيف بالإضافة الى المفاهيم الأساسية من الجبر الخطي، وحساب التفاضل والتكامل، والاحتمال الى فصول متقدمة مثل الشبكات العصبية الالتفافية CNN، تم تضمين الشبكات العصبية المتكررة RNN والرؤية الحاسوبية CV ومعالجة اللغات الطبيعية NLP أيضًا.

هذا كتاب تفاعلي مفتوح المصدر مقدمفي شكل فريد يدمج النص والرياضيات والكود، ويدعم الآن أطر برمجة TensorFlow وPyTorch وApache MXNet، والتي تمت صياغتها بالكامل من خلال Jupyter Notebook.

يمكن تقسيم الكتاب إلى ثلاثة أجزاء تقريبًا، لقد قمنافي الوقت الحالي بترجمة الجزء الأول والذي يشمل الأساسيات والمقدمات وان شاء اللهفي المستقبل القريب سنقوم بنشر الجزء الثاني والذي يشمل التقنيات الحديثة للتعلم العميق وبعده الجزء الثالث والذي يشمل مواضيع مثل الرؤية الحاسوبية ومعالجة اللغات الطبيعية.

لقد اخترت كتاب "Dive into Deep Learning" لما رأيته من جودة هذا الكتاب، وللمنهجية التي اتبعها المؤلفونفي ترتيبه وبساطة شرحه. لقد حاولت قدر المستطاع ان اخرج بترجمة ذات جودة عالية، ومع هذا يبقى عملاً بشرياً يحتمل النقص، فاذاكان لديك أي ملاحظات حول هذا الكتاب، فلا تتردد بمراسلتنا عبر بريدنا الالكتروني alaa.taima@qu.edu.iq .

نأمل ان يساعد هذا الكتاب كل من يريد ان يدخلفي مجال التعلم العميق ومساعدة القارئ العربي على تعلم هذا المجال. اسأل الله التوفيقفي هذا العمل لأثراء المحتوى العربي الذي يفتقر أشد الافتقار إلى محتوى جيد ورصينفي مجال الذكاء الاصطناعي وتعلم الالة والتعلم العميق. ونرجو لك الاستمتاع مع التعلم العميق ولا تنسونا من صالح الدعاء.

د. علاء طعيمة/كلية علوم الحاسوب وتكنولوجيا المعلومات/جامعة القادسية/العراق

المقدمة

قبل بضع سنوات فقط، لم يكن هناك جحافل من علماء التعلم العميق deep learning يطورون منتجات وخدمات ذكيةفي الشركات الكبرى والشركات الناشئة. عندما دخلنا هذا المجال، لم يكن التعلم الآلي machine learning يتصدر عناوين الصحف اليومية. لم يكن لدى والدينا أي فكرة عن ماهية التعلم الآلي، ناهيك عن سبب تفضيلنا له على مهنةفي الطب أو القانون. كان التعلم الآلي تخصصًا أكاديميًافي السماء الزرقاء اقتصرت أهميته الصناعية على مجموعة ضيقة من تطبيقات العالم الحقيقي، بمافي ذلك التعرف على الكلام speech recognition والرؤية الحاسوبية computer vision. علاوة على ذلك، تطلب العديد من هذه التطبيقات قدرًا كبيرًا من المعرفة بالمجال لدرجة أنه غالبًا ما كان يُنظر إليها على أنها مناطق منفصلة تمامًا كان التعلم الآلي مكونًا صغيرًا لها.في ذلك الوقت، كانت الشبكات العصبية neural networks ـ أسلاف أساليب التعلم العميق التي نركز عليهافي هذا الكتاب ـ تعتبر بشكل عام عفا عليها الزمن.

في السنوات القليلة الماضية فقط، فاجأ التعلم العميق العالم، مما أدى إلى تقدم سريعفي مجالات متنوعة مثل لرؤية الحاسوبية computer vision، ومعالجة اللغة الطبيعية natural language processing، والتعرف التلقائي على الكلام automatic speech recognition، والتعلم المعزز reinforcement learning، والمعلوماتية الطبية الحيوية biomedical informatics. علاوة على ذلك، أدى نجاح التعلم العميقفي العديد من المهام ذات الأهمية العملية إلى تحفيز التطوراتفي التعلم الآلي النظري والإحصاءات. مع هذه التطوراتفي متناول اليد، يمكننا الآن بناء سيارات تقود نفسها باستقلالية أكثر من أي وقت مضى (واستقلالية أقل مما قد تعتقده بعض الشركات)، أنظمة الرد الذكية التي تقوم تلقائيًا بصياغة معظم رسائل البريد الإلكتروني العادية، مما يساعد الناس مساعدة الناس على الخروج من البريد الوارد الكبير بشكل قمعي، ووكلاء برمجيات يهيمنون على أفضل البشرفي العالمفي ألعاب الطاولة مثل Go، وهو إنجاز كان يُعتقدفي السابق أنه يبعد عقودًا. بالفعل، تمارس هذه الأدوات تأثيرات واسعة النطاق على الصناعة والمجتمع، وتغير طريقة صناعة الأفلام، وتشخيص الأمراض، وتلعب دورًا متزايدًا في العلوم الأساسية ـ من الفيزياء الفلكية إلى علم الأحياء.

حول هذا الكتاب

يمثل هذا الكتاب محاولتنا لجعل التعلم العميق سهل المنال، ويعلمك المفاهيم والسياق والبرمجة.

متوسط واحد يجمع بين الكود والرياضيات وHTML

لكي تصل أي تقنية حوسبة إلى تأثيرها الكامل، يجب أن تكون مفهومة جيداً وموثقة جيداً ومدعومة بأدوات ناضجة وجيدة الصيانة. يجب أن تكون الأفكار الرئيسية موجزة بوضوح، مما يقلل من وقت الإعداد اللازم لتحديث الممارسين الجدد. يجب أن تقوم المكتبات الناضجة بأتمتة المهام الشائعة، ويجب أن تسهل التعليمات البرمجية النموذجية على الممارسين تعديل التطبيقات الشائعة وتطبيقها وتوسيعها لتناسب احتياجاتهم. خذ تطبيقات الويب الديناميكية كمثال. على الرغم من وجود عدد كبير من الشركات، مثل Amazon، التي طورت تطبيقات ويب ناجحة تعتمد على قواعد البياناتفي التسعينيات، فقد تم تحقيق إمكانات هذه التكنولوجيا لمساعدة رواد الأعمال المبدعين إلى درجة أكبر بكثيرفي السنوات العشر الماضية، ويرجع ذلك جزئيًا إلى التطور من الأطر القوية والموثقة جيداً.

يمثل اختبار إمكانات التعلم العميق تحديات فريدة لأن أي تطبيق فردي يجمع بين مختلف التخصصات. يتطلب تطبيق التعلم العميق فهمًا متزامنًا (1) لدوافع طرح مشكلة بطريقة معينة؛ (2) الشكل الرياضي لنموذج معين. (3) خوارزميات التحسين لتلائم النماذج مع البيانات؛ (4) المبادئ الإحصائية التي تخبرنا متى يجب أن نتوقع أن تعمم نماذجنا على البيانات غير المرئية والطرق العملية للتصديق على أنها،في الواقع، معممة؛ و (5) التقنيات الهندسية المطلوبة لتدريب النماذج بكفاءة، والتغلب على مخاطر الحوسبة الرقمية وتحقيق أقصى استفادة من الأجهزة المتاحة. يمثل تدريس كل من مهارات التفكير النقدي المطلوبة لصياغة المشكلات، والرياضيات لحلها، والأدوات البرمجية لتنفيذ هذه الحلول كلهافي مكان واحد تحديات هائلة. هدفنافي هذا الكتاب هو تقديم مورد موحد لإطلاع الممارسين المحتملين على السرعة.

عندما بدأنا مشروع الكتاب هذا، لم تكن هناك موارد (1) ظلت محدثةفي نفس الوقت؛ (2) تغطية اتساع نطاق ممارسات التعلم الآلي الحديثة بعمق تقني كافٍ؛ و (3) عرض معشق للجودة التي يتوقعها المرء من كتاب مدرسي مع الكود النظيف القابل للتشغيل الذي يتوقعه المرء من برنامج تعليمي عملي. لقد وجدنا الكثير من أمثلة التعليمات البرمجية لكيفية استخدام إطار عمل تعليمي عميق معين (على سبيل المثال، كيفية إجراء الحوسبة الرقمية الأساسية باستخدام المصفوفاتفي TensorFlow) أو لتنفيذ تقنيات معينة (على سبيل المثال، مقتطفات التعليمات البرمجية لـ LeNet و AlexNet و ResNet وما إلى ذلك) المتناثرة عبر العديد من منشورات المدونة ومستودعات GitHub. ومع ذلك، ركزت هذه الأمثلة عادةً على كيفية تنفيذ نهج معين، لكنها استبعدت مناقشة سبب اتخاذ قرارات خوارزمية معينة. بينما ظهرت بعض الموارد التفاعلية بشكل متقطع لمعالجة موضوع معين، على سبيل المثال، منشورات المدونة الجذابة المنشورة على موقع الويب Distill أو المدونات الشخصية، فإنها تغطي فقط موضوعات محددةفي التعلم العميق، وغالبًا ما تفتقر إلى التعليمات البرمجية المرتبطة. من ناحية أخرى، بينما ظهرت العديد

من كتب التعلم العميق – على سبيل المثال، (Goodfellow et al.، 2016)، والتي تقدم مسحًا شاملاً لأساسيات التعلم العميق – فإن هذه الموارد لا تقرن الأوصاف بإدراك المفاهيمفي الكود. وأحيانًا يترك القراء جاهلين بكيفية تنفيذها. علاوة على ذلك، يتم إخفاء عدد كبير جدًا من الموارد خلف جدران حظر الاشتراك المدفوعة لمقدمي الدورات التدريبية التجارية.

شرعنافي إنشاء مورد يمكن (1) أن يكون متاحًا للجميع؛ (2) توفر عمقًا تقنيًا كافيًا لتوفير نقطة انطلاق على الطريق لتصبح بالفعل عالمًا تطبيقيًا للتعلم الآلي؛ (3) تضمين التعليمات البرمجية القابلة للتشغيل، والتي توضح للقراء كيفية حل المشكلات عمليًا؛ (4) السماح بالتحديثات السريعة، سواء من جانبنا أو من قبل المجتمع community ككل؛ و (5) استكماله بمنتدى للمناقشة التفاعلية للتفاصيل التقنية وللإجابة على الأسئلة.

كانت هذه الأهداففي كثير من الأحيان متعارضة. من الأفضل إدارة المعادلات والنظريات والاستشهادات ووضعهافي LaTeX. أفضل وصف للكودفي بايثون. وصفحات الويب أصلية بتنسيق HTML وJavaScript. علاوة على ذلك، نريد أن يكون المحتوى متاحًا سواء أكان رمزًا قابلاً للتنفيذ أو كتابًا ماديًا أو ملف PDF قابل للتنزيل أو على الإنترنت كموقع ويب. لم يبدُ أي سير عمل مناسبًا لهذه المطالب، لذلك قررنا تجميع مهامنا الخاصة (القسم 20.6). اتفقنا على GitHub لمشاركة المصدر وتسهيل مساهمات المجتمع؛ دفاتر جوبيتر Jupyter notebooks لخلط الكود والمعادلات والنص؛ Sphinx كمحرك تقديم؛ وDiscourse كمنصة مناقشة.في حين أن نظامنا ليس مثاليًا، إلا أن هذه الخيارات تقدم حلاً وسطًا بين الاهتمامات المتنافسة. نعتقد أن كتاب Dive into Deep Learning قد يكون الكتاب الأول الذي يتم نشره باستخدام سير العمل المتكامل integrated workflow هذا.

التعلم عبر الممارسة

تقدم العديد من الكتب المدرسية المفاهيم على التوالي، وتغطي كل منها بتفصيل شامل. على سبيل المثال، يُعلِّم الكتاب المدرسي الممتاز لكريس بيشوب Chris Bishop's excellent textbook (Bishop، 2006) كل موضوع بدقة شديدة لدرجة أن الوصول إلى فصل الانحدار الخطي يتطلب قدرًا غير ضئيل من العمل. بينما يحب الخبراء هذا الكتاب على وجه التحديد لشموله، بالنسبة للمبتدئين الحقيقيين، فإن هذه الخاصية تحد من فائدته كنص تمهيدي.

في هذا الكتاب، نقوم بتدريس معظم المفاهيمفي الوقت المناسب. بمعنى آخر، سوف تتعلم المفاهيمفي نفس اللحظة التي تكون فيها ضرورية لتحقيق بعض الأهداف العملية. بينما نأخذ بعض الوقتفي البداية لتدريس المقدمات الأساسية، مثل الجبر الخطي linear algebra والاحتمالية probability، نريدك أن تتذوق الرضا بتدريب نموذجك الأول قبل القلق بشأن المزيد من المفاهيم الباطنية esoteric concepts.

بصرف النظر عن بعض النوتبوكس notebooks الأولية التي توفر دورة تدريبية مكثفةفي الخلفية الرياضية الأساسية، يقدم كل فصل لاحق عددًا معقولًا من المفاهيم الجديدة ويوفر العديد من أمثلة العمل المستقلة، باستخدام مجموعات بيانات حقيقية. قدم هذا تحديا تنظيميا. قد يتم بشكل منطقي تجميع بعض الطرز معًافي دفتر ملاحظات واحد. وأفضل طريقة لتدريس بعض الأفكار هي تنفيذ عدة نماذج متتالية. من ناحية أخرى، هناك ميزة كبيرة للالتزام بسياسة مثال عملي واحد، نوتبوك واحد: هذا يجعل الأمر سهلاً قدر الإمكان بالنسبة لك لبدء مشاريع البحث الخاصة بك من خلال الاستفادة من التعليمات البرمجية الخاصة بنا. فقط انسخ النوتبوك وابدأفي تعديله.

طوال الوقت، نقوم بإدخال الكود القابل للتشغيل مع مواد الخلفية حسب الحاجة. بشكل عام، نخطئفي جانب إتاحة الأدوات قبل شرحها بالكامل (غالبًا ما يتم ملء الخلفية لاحقًا). على سبيل المثال، قد نستخدم التدرج الاشتقاقي العشوائي stochastic gradient descent قبل شرح سبب فائدته أو تقديم حدس حول سبب نجاحه. يساعد هذافي إعطاء الممارسين الذخيرة اللازمة لحل المشكلات بسرعة، على حساب مطالبة القارئ بالثقة بنافي بعض القرارات التنظيمية.

يعلم هذا الكتاب مفاهيم التعلم العميق من الصفر.في بعض الأحيان، نتعمقفي التفاصيل الدقيقة حول النماذج التي عادةً ما تكون مخفية عن المستخدمين بواسطة أطر التعلم العميق الحديثة. يظهر هذا بشكل خاصفي البرامج التعليمية الأساسية، حيث نريد منك أن تفهم كل ما يحدثفي طبقة أو مُحسِّن معين.في هذه الحالات، غالبًا ما نقدم نسختين من المثال: أحدهما ننفذ فيه كل شيء من البداية، ونعتمد فقط على دوال تشبه NumPy والتمايز التلقائي automatic differentiation، ومثال عملي أكثر، حيث نكتب كودًا موجزًا باستخدام واجهات برمجة التطبيقات عالية المستوى high-level API لـ أطر التعلم العميق. بعد شرح كيفية عمل بعض المكونات، نعتمد على واجهة برمجة التطبيقات عالية المستوىفي البرامج التعليمية اللاحقة.

المحتوى والبنية

يمكن تقسيم الكتاب إلى ثلاثة أجزاء تقريبًا، مع التركيز على المقدمات وتقنيات التعلم العميق والموضوعات المتقدمة التي تركز على الأنظمة والتطبيقات الحقيقية (الشكل 1).

- الجزء الأول: **الأساسيات والمقدمات**. يقدم القسم الاول مقدمة للتعلم العميق. بعد ذلك،في القسم الثاني، نطلعك بسرعة على المتطلبات الأساسية اللازمة للتعلم العميق العملي، مثل كيفية تخزين البيانات ومعالجتها، وكيفية تطبيق العمليات العددية المختلفة بناءً على المفاهيم الأساسية من الجبر الخطي، وحساب التفاضل والتكامل، والاحتمال. يغطي القسم الرابع والقسم والخامس المفاهيم والتقنيات الأساسيةفي التعلم العميق، بمافي ذلك الانحدار regression والتصنيف classification؛ نماذج

خطية linear models؛ البيرسبيترون متعددة الطبقات multilayer perceptron.
وفرط التجهيز overfitting والتنظيم .regularization

- الجزء الثاني: **تقنيات التعلم العميق الحديثة**. يصف القسم السادس المكونات الحسابية الرئيسية لأنظمة التعلم العميق ويضع الأساس لتطبيقاتنا اللاحقة لنماذج أكثر تعقيداً. بعد ذلك، يقدم القسم السابع والقسم الثامن الشبكات العصبية التلافيفية (CNNs)، وهي أدوات قوية تشكل العمود الفقري لمعظم أنظمة الرؤية الحاسوبية الحديثة. وبالمثل، يقدم القسم التاسع والقسم العاشر الشبكات العصبية المتكررة (RNNs)، وهي نماذج تستغل البنية المتسلسلة (على سبيل المثال، الزمنية)في البيانات وتستخدم بشكل شائع لمعالجة اللغة الطبيعية والتنبؤ بالسلاسل الزمنية.في القسم الحادي عشر، قدمنا فئة جديدة نسبيًا من النماذج تعتمد على ما يسمى بآليات الانتباه attention mechanisms التي حلت محل RNNs باعتبارها البنية المهيمنة لمعظم مهام معالجة اللغة الطبيعية. ستُطلعك هذه الأقسام على أقوى الأدوات والأدوات العامة المستخدمة على نطاق واسع من قبل ممارسي التعلم العميق.
- الجزء الثالث: **قابلية التوسع والكفاءة والتطبيقات**.في القسم الثاني عشر، نناقش العديد من خوارزميات التحسين الشائعة المستخدمة لتدريب نماذج التعلم العميق. بعد ذلك، في القسم الثالث عشر، ندرس العديد من العوامل الرئيسية التي تؤثر على الأداء الحسابي لكود التعلم العميق. بعد ذلك،في القسم الرابع عشر، نوضح التطبيقات الرئيسية للتعلم العميقفي الرؤية الحاسوبية. أخيرًا،في القسم الخامس عشر والقسم السادس عشر، نوضح كيفية التدريب المسبق لنماذج تمثيل اللغة وتطبيقها على مهام معالجة اللغة الطبيعية. هذا الجزء متاح على الإنترنت.

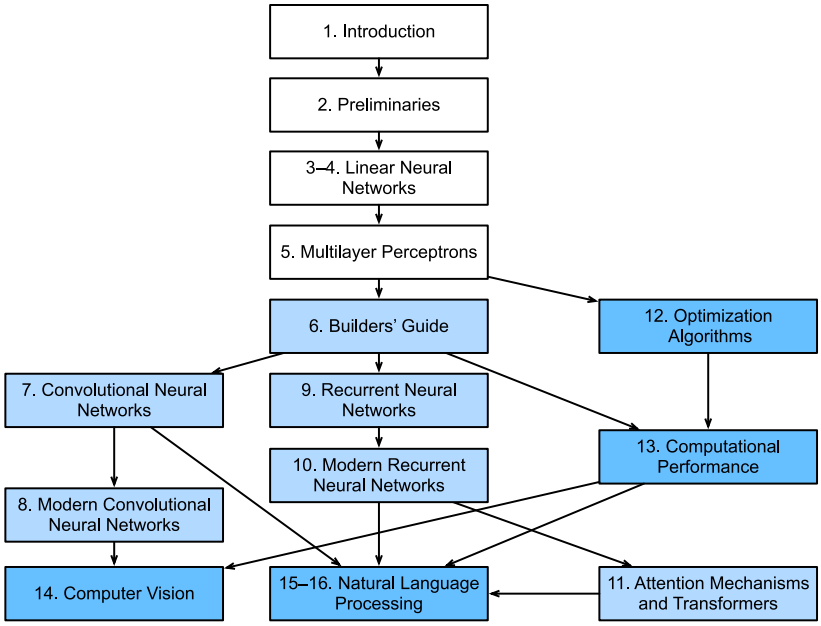

الكود

تتميز معظم أقسام هذا الكتاب بكود قابل للتنفيذ. نعتقد أن أفضل طريقة لتطوير بعض البديهيات هي التجربة والخطأ trial and error، وتعديل الكود بطرق صغيرة ومراقبة النتائج. من الناحية المثالية، قد تخبرنا النظرية الرياضية الأنيقة بدقة كيفية تعديل الكود الخاص بنا لتحقيق النتيجة المرجوة. ومع ذلك، يجب على ممارسي التعلم العميق اليوم أن يسيروافي كثير من الأحيان حيث لا توجد نظرية قوية توفر التوجيه. على الرغم من أفضل محاولاتنا، لا تزال التفسيرات الرسمية لفعالية التقنيات المختلفة غير متوفرة، لأن الرياضيات لتوصيف هذه النماذج يمكن أن تكون صعبة للغاية، لأن التفسير يعتمد على الأرجح على خصائص البيانات التي تفتقر حاليًا إلى تعريفات واضحة، ولأن التحقيق الجاد حول هذه الموضوعات مؤخرًا إلى مستوى عالٍ. نأمل أنه مع تقدم نظرية التعلم العميق، ستوفر كل طبعة مستقبلية من هذا الكتاب رؤى تتفوق على تلك المتاحة حاليًا.

لتجنب التكرار غير الضروري، نقوم بتغليف بعض الدوال والفئات الأكثر استخدامًا واستيرادًا في حزمة `d2l`. طوال الوقت، نقوم بتمييز كتل التعليمات البرمجية (مثل الدوال أو الفئات أو مجموعة عبارات الاستيراد) باستخدام `#@save` للإشارة إلى أنه سيتم الوصول إليها لاحقًا عبر حزمة `d2l`. نقدم نظرة عامة مفصلة عن هذه الدوال والفئاتفي القسم 20.8. حزمة `d2l` خفيفة الوزن وتتطلب فقط التبعيات التالية:

```
#@save
```

```
import collections
import hashlib
import inspect
import math
import os
import random
import re
import shutil
import sys
import tarfile
import time
import zipfile
from collections import defaultdict
import pandas as pd
import requests
from IPython import display
from matplotlib import pyplot as plt
from matplotlib_inline import backend_inline

d2l = sys.modules[__name__]
```

يعتمد معظم الكودفي هذا الكتاب على TensorFlow، وهو إطار مفتوح المصدر للتعلم العميق يتم اعتماده على نطاق واسعفي الصناعة ويحظى بشعبية بين الباحثين. اجتازت جميع التعليمات البرمجية الموجودةفي هذا الكتاب الاختبارات بموجب أحدث إصدار ثابت من TensorFlow. ومع ذلك، نظرًا للتطور السريعفي التعلم العميق، فقد لا تعمل بعض التعليمات البرمجيةفي النسخة المطبوعة بشكل صحيحفي الإصدارات المستقبلية من TensorFlow. نحن نخطط لتحديث النسخة عبر الإنترنت.في حالة مواجهة أي مشاكل، يرجى الرجوع إلى التثبيت لتحديث التعليمات البرمجية وبيئة وقت التشغيل.

إليك كيفية استيراد الوحدات النمطية من TensorFlow.

```
#@save
import numpy as np
import tensorflow as tf
```

الجمهور المستهدف

هذا الكتاب مخصص للطلاب (الجامعيين أو الخريجين) والمهندسين والباحثين الذين يسعون إلى فهم قوي للتقنيات العملية للتعلم العميق. نظرًا لأننا نشرح كل مفهوم من البداية، فلا يلزم وجود خلفية سابقةفي التعلم العميق أو التعلم الآلي. يتطلب التفسير الكامل لأساليب التعلم العميق بعض الرياضيات والبرمجة، لكننا سنفترض فقط أنك تأتي ببعض الأساسيات، بمافي ذلك

كميات متواضعة من الجبر الخطي وحساب التفاضل والتكامل والاحتمالات وبرمجة بايثون. فقطفي حالة نسيان الأساسيات، يوفر الملحق تجديدًا لمعظم الرياضيات التي ستجدهافي هذا الكتاب.في معظم الأحيان، سنمنح الحدس والأفكار الأولوية على الدقة الرياضية. إذا كنت ترغب في توسيع هذه الأسس إلى ما هو أبعد من المتطلبات الأساسية لفهم كتابنا، فإننا نوصي بسعادة ببعض الموارد الرائعة الأخرى: التحليل الخطي بواسطة Bollobas (Bela Bollobas ، 1999) يغطي الجبر الخطي والتحليل الدالي بعمق كبير. توفر كافة الإحصائيات (Wasserman، 2013) مقدمة رائعة للإحصاءات. تعد كتب ودورات جو بليتزشتاين حول الاحتمالات والاستدلال جواهر تربوية. وإذا لم تكن قد استخدمت بايثون من قبل، فقد ترغبفي الاطلاع على برنامج بايثون التعليمي هذا Python tutorial .

المنتدى

مرتبطًا بهذا الكتاب، أطلقنا منتدى للمناقشة، يقعفي discuss.d2l.ai . عندما يكون لديك أسئلة حول أي قسم من الكتاب، يمكنك العثور على ارتباط إلى صفحة المناقشة المرتبطةفي نهاية كل نوتبوك.

شكر وتقدير

نحن مدينون لمئات المساهمينفي كل من المسودتين الإنجليزية والصينية. لقد ساعدوافي تحسين المحتوى وقدموا ملاحظات قيمة. على وجه التحديد، نشكر كل مساهمفي هذه المسودة الإنجليزية لجعلها أفضل للجميع. معرفات أو أسماء GitHub الخاصة بهم (بدون ترتيب معين): alxnorden, avinashingit, bowen0701, brettkoonce, Chaitanya Prakash Bapat, cryptonaut, Davide Fiocco, edgarroman, gkutiel, John Mitro, Liang Pu, Rahul Agarwal, Mohamed Ali Jamaoui, Michael (Stu) Stewart, Mike Müller, NRauschmayr, Prakhar Srivastav, sad-, sfermigier, Sheng Zha, sundeepteki, topecongiro, tpdi, vermicelli, Vishaal Kapoor, Vishwesh Ravi Shrimali, YaYaB, Yuhong Chen, Evgeniy Smirnov, lgov, Simon Corston-Oliver, Igor Dzreyev, Ha Nguyen, pmuens, Andrei Lukovenko, senorcinco, vfdev-5, dsweet, Mohammad Mahdi Rahimi, Abhishek Gupta, uwsd, DomKM, Lisa Oakley, Bowen Li, Aarush Ahuja, Prasanth Buddareddygari, brianhendee, mani2106, mtn, lkevinzc, caojilin, Lakshya, Fiete Lüer, Surbhi Vijayvargeeya, Muhyun Kim, dennismalmgren, adursun, Anirudh Dagar, liqingnz, Pedro Larroy, lgov, ati-ozgur, Jun Wu, Matthias Blume, Lin Yuan, geogunow, Josh Gardner,

Maximilian Böther, Rakib Islam, Leonard Lausen, Abhinav Upadhyay, rongruosong, Steve Sedlmeyer, Ruslan Baratov, Rafael Schlatter, liusy182, Giannis Pappas, ati-ozgur, qbaza, dchoi77, Adam Gerson, Phuc Le, Mark Atwood, christabella, vn09, Haibin Lin, jjangga0214, RichyChen, noelo, hansent, Giel Dops, dvincent1337, WhiteD3vil, Peter Kulits, codypenta, joseppinilla, ahmaurya, karolszk, heytitle, Peter Goetz, rigtorp, Tiep Vu, sfilip, mlxd, Kale-ab Tessera, Sanjar Adilov, MatteoFerrara, hsneto, Katarzyna Biesialska, Gregory Bruss, Duy—Thanh Doan, paulaurel, graytowne, Duc Pham, sl7423, Jaedong Hwang, Yida Wang, cys4, clhm, Jean Kaddour, austinmw, trebeljahr, tbaums, Cuong V. Nguyen, pavelkomarov, vzlamal, NotAnotherSystem, J-Arun-Mani, jancio, eldarkurtic, the-great-shazbot, doctorcolossus, gducharme, cclauss, Daniel-Mietchen, hoonose, biagiom, abhinavsp0730, jonathanhrandall, ysraell, Nodar Okroshiashvili, UgurKap, Jiyang Kang, StevenJokes, Tomer Kaftan, liweiwp, netyster, ypandya, NishantTharani, heiligerl, SportsTHU, Hoa Nguyen, manuel-arno-korfmann-webentwicklung, aterzis-personal, nxby, Xiaoting He, Josiah Yoder, mathresearch, mzz2017, jroberayalas, iluu, ghejc, BSharmi, vkramdev, simonwardjones, LakshKD, TalNeoran, djliden, Nikhil95, Oren Barkan, guoweis, haozhu233, pratikhack, Yue Ying, tayfununal, steinsag, charleybeller, Andrew Lumsdaine, Jiekui Zhang, Deepak Pathak, Florian Donhauser, Tim Gates, Adriaan Tijsseling, Ron Medina, Gaurav Saha, Murat Semerci, Lei Mao, Levi McClenny, Joshua Broyde, jake221, jonbally, zyhazwraith, Brian Pulfer, Nick Tomasino, Lefan Zhang, Hongshen Yang, Vinney Cavallo, yuntai, Yuanxiang Zhu, amarazov, pasricha, Ben Greenawald, Shivam Upadhyay, Quanshangze Du, Biswajit Sahoo, Parthe Pandit, Ishan Kumar, HomunculusK, Lane Schwartz, varadgunjal, Jason Wiener, Armin Gholampoor, Shreshtha13, eigen-arnav, Hyeonggyu Kim, EmilyOng, Bálint Mucsányi, Chase DuBois, Juntian Tao, Wenxiang Xu, Lifu Huang, filevich, quake2005, nils-werner, Yiming Li, Marsel Khisamutdinov, Francesco “Fuma” Fumagalli, Peilin Sun, Vincent Gurgul, qingfengtommy, Janmey Shukla, Mo Shan,

Kaan Sancak, regob, AlexSauer, Gopalakrishna Ramachandra, Tobias Uelwer, Chao Wang, Tian Cao, Nicolas Corthorn, akash5474, kxxt, zxydi1992, Jacob Britton, Shuangchi He, zhmou, krahets, Jie-Han Chen, Atishay Garg, Marcel Flygare, adtygan, Nik Vaessen, bolded, Louis Schlessinger, Balaji Varatharajan, atgctg, Kaixin Li, Victor Barbaros, Riccardo Musto, Elizabeth Ho, azimjonn, Guilherme Miotto, Alessandro Finamore, Joji Joseph, Anthony Biel, Sere1nz.

نشكر Amazon Web Services، وخاصة Swami Sivasubramanian و Peter DeSantis وAdam Selipsky وAndrew Jassy لدعمهم السخي في كتابة هذا الكتاب. لولا الوقت والموارد المتاحة والمناقشات مع الزملاء والتشجيع المستمر لما حدث هذا الكتاب.

الملخص

أحدث التعلم العميق ثورة في التعرف على الأنماط pattern recognition، حيث أدخل التكنولوجيا التي تعمل الآن على تشغيل مجموعة واسعة من التقنيات، في مجالات متنوعة مثل الرؤية الحاسوبية، ومعالجة اللغة الطبيعية، والتعرف التلقائي على الكلام. لتطبيق التعلم العميق بنجاح، يجب أن تفهم كيفية طرح مشكلة، والرياضيات الأساسية للنمذجة، والخوارزميات لتناسب النماذج الخاصة بك مع البيانات، والتقنيات الهندسية لتنفيذها جميعًا. يقدم هذا الكتاب مورداً شاملاً، بما في ذلك النثر والأرقام والرياضيات والاكواد، كل ذلك في مكان واحد. لطرح (أو الإجابة) أسئلة تتعلق بهذا الكتاب، قم بزيارة منتدانا على https://discuss.d2l.ai/ . جميع النوتبوكس الخاصة بنا متاحة للتنزيل على موقع الويب D2L.ai website وعلى GitHub.

التمارين

- قم بتسجيل حساب في منتدى المناقشة الخاص بهذا الكتاب discuss.d2l.ai.
- قم بتثبيت بايثون على جهاز الكمبيوتر الخاص بك.
- اتبع الروابط الموجودة في الجزء السفلي من قسم المنتدى، حيث ستتمكن من طلب المساعدة ومناقشة الكتاب والعثور على إجابات لأسئلتك من خلال إشراك المؤلفين والمجتمع الأوسع.

التثبيت

من أجل البدء والتشغيل، سنحتاج إلى بيئة لتشغيل بايثون وJupyter Notebook والمكتبات ذات الصلة والكود اللازم لتشغيل الكتاب نفسه.

تثبيت Miniconda

أبسط خيار لك هو تثبيت Miniconda. لاحظ أن إصدار Python 3.x مطلوب. يمكنك تخطي الخطوات التالية إذا كان جهازك مثبتًا بالفعل على conda.

قم بزيارة موقع Miniconda على الويب وحدد الإصدار المناسب لنظامك بناءً على إصدار Python 3.x وبنية الجهاز. افترض أن إصدار بايثون الخاص بك هو 3.9 (الإصدار الذي تم اختباره). إذا كنت تستخدم macOS، فيمكنك تنزيل برنامج bash النصي الذي يحتوي اسمه على السلاسل "MacOSX"، وانتقل إلى موقع التنزيل، وقم بتنفيذ التثبيت على النحو التالي (مع أخذ Intel Macs كمثال):

```
# The file name is subject to changes
sh Miniconda3-py39_4.12.0-MacOSX-x86_64.sh -b
```

يقوم مستخدم Linux بتنزيل الملف الذي يحتوي اسمه على السلاسل "Linux" وتنفيذ ما يلي في موقع التنزيل:

```
# The file name is subject to changes
sh Miniconda3-py39_4.12.0-Linux-x86_64.sh -b
```

بعد ذلك، قم بتهيئة shell حتى نتمكن من تشغيل conda مباشرةً.

```
~/miniconda3/bin/conda init
```

ثم أغلق وأعد فتح shell الحالي. يجب أن تكون قادرًا على إنشاء بيئة جديدة على النحو التالي:

```
conda create --name d2l python=3.9 -y
```

الآن يمكننا تنشيط بيئة d2l:

```
conda activate d2l
```

تثبيت إطار عمل التعلم العميق وحزمة d2l

قبل تثبيت أي إطار عمل للتعلم العميق، يرجى أولاً التحقق مما إذا كان لديك وحدات معالجة رسومات GPU مناسبة على جهازك أم لا (وحدات معالجة الرسومات التي تشغل الشاشة على كمبيوتر محمول قياسي ليست ذات صلة بأغراضنا). على سبيل المثال، إذا كان جهاز الكمبيوتر الخاص بك يحتوي على وحدات معالجة رسومات NVIDIA وقام بتثبيت CUDA، فأنت جاهز تمامًا. إذا كان جهازك لا يحتوي على أي وحدة معالجة رسومات، فلا داعي للقلق الآن. توفر وحدة المعالجة المركزية CPU الخاصة بك أكثر من قوة حصانية كافية لتصفح الفصول القليلة الأولى. فقط تذكر أنك سترغب في الوصول إلى وحدات معالجة الرسومات قبل تشغيل النماذج الأكبر.

يمكنك تثبيت TensorFlow باستخدام دعم وحدة المعالجة المركزية CPU أو وحدة معالجة الرسومات GPU على النحو التالي:

```
pip install tensorflow tensorflow-probability
```

خطوتنا التالية هي تثبيت حزمة `d2l` التي قمنا بتطويرها لتغليف الدوال والفئات (الكلاسات) المستخدمة بشكل متكرر والموجودةفي هذا الكتاب:

```
pip install d2l==1.0.0a1
```

تحميل وتشغيل الكود

بعد ذلك، ستحتاج إلى تنزيل النوتبوكس بحيث يمكنك تشغيل كل من كتل التعليمات البرمجية للكتاب. ما عليك سوى النقر فوق علامة التبويب "Notebooks" أعلى أي صفحة HTML على موقع D2L.ai لتنزيل الرمز ثم فك ضغطه. بدلاً من ذلك، يمكنك جلب دفاتر الملاحظات من سطر الأوامر على النحو التالي:

```
mkdir d2l-en && cd d2l-en
curl https://d2l.ai/d2l-en.zip -o d2l-en.zip
unzip d2l-en.zip && rm d2l-en.zip
cd tensorflow
```

إذا لم يكن لديك برنامج unzip مثبتًا بالفعل، فقم أولاً بتشغيل sudo apt-get install unzip.
يمكننا الآن بدء تشغيل خادم Jupyter Notebook من خلال تشغيل:

```
jupyter notebook
```

في هذه المرحلة، يمكنك فتح http://localhost:8888 (ربما تم فتحه تلقائيًا بالفعل)في مستعرض الويب الخاص بك. ثم يمكننا تشغيل الكود لكل قسم من الكتاب. عندما تفتح نافذة سطر أوامر جديدة، ستحتاج إلى تنفيذ (`conda activate d2l`) لتنشيط بيئة وقت التشغيل قبل تشغيل نوتبوكس D2L ، أو تحديث الحزم الخاصة بك (إما إطار عمل التعلم العميق أو حزمة d2l). للخروج من البيئة، قم بتشغيل `conda deactivate`.

المحتويات

1

المقدمة

1. المقدمة

حتى وقت قريب، تم ترميز كل برنامج كمبيوتر تقريبًا قد تتفاعل معهفي يوم عادي كمجموعة صارمة من القواعد التي تحدد بدقة كيف يجب أن يتصرف. لنفترض أننا أردنا كتابة تطبيق لإدارة منصة التجارة الإلكترونية e-commerce platform. بعد الالتفاف حول السبورة لبضع ساعات للتفكيرفي المشكلة، قد نستقر على الخطوط العريضة لحل عملي، على سبيل المثال: (1) يتفاعل المستخدمون مع التطبيق من خلال واجهة تعملفي متصفح الويب أو تطبيق الهاتف المحمول؛ (2) يتفاعل تطبيقنا مع محرك قاعدة بيانات من الدرجة التجارية لتتبع حالة كل مستخدم والاحتفاظ بسجلات المعاملات التاريخية؛ و(3)في قلب تطبيقنا ، يوضح منطق العمل (يمكنك القول ، العقول brains) لتطبيقنا مجموعة من القواعد التي تحدد كل ظرف يمكن تصوره للإجراء المقابل الذي يجب أن يتخذه برنامجنا.

لبناء عقول تطبيقنا، قد نقوم بتعداد جميع الأحداث المشتركة التي يجب أن يتعامل معها برنامجنا. على سبيل المثال، عندما ينقر أحد العملاء لإضافة عنصر إلى سلة التسوق الخاصة به، يجب على برنامجنا إضافة إدخال إلى جدول قاعدة بيانات عربة التسوق، مع ربط معرف المستخدم بمعرف المنتج المطلوب. قد نحاول بعد ذلك مراجعة كل حالة ركنية محتملة، واختبار مدى ملاءمة قواعدنا وإجراء أي تعديلات ضرورية. ماذا يحدث إذا بدأ المستخدم الشراء بسلة تسوق فارغة؟في حين أن عددًا قليلاً من المطورين قد فهموا الأمر بشكل صحيح تمامًافي المرة الأولى (قد يستغرق الأمر بعض الاختبارات التجريبية لحل الخلل)،في الغالب، يمكننا كتابة مثل هذه البرامج وإطلاقها بثقة قبل رؤية عميل حقيقي. إن قدرتنا على تصميم الأنظمة الآلية التي تقود المنتجات والأنظمة العاملة يدويًا، غالبًافي المواقف الجديدة، هي إنجاز معرفي رائع. وعندما تكون قادرًا على ابتكار حلول تعمل 100%في ذلك الوقت، فلا داعي للقلق بشأن التعلم الآلي.

لحسن الحظ بالنسبة للمجتمع المتنامي لعلماء التعلم الآلي ، فإن العديد من المهام التي نرغب في أتمتة لا تنحني بسهولة إلى براعة الإنسان. تخيل أنك تتجمع حول السبورة البيضاء مع أذكى العقول التي تعرفها ، لكنك هذه المرة تعالج إحدى المشكلات التالية:

- اكتب برنامجًا يتنبأ بطقس الغد بناءً على المعلومات الجغرافية وصور القمر الصناعي ونافذة تتبع الطقس السابق.
- اكتب برنامجًا يأخذ سؤالاً واقعيًا ، معبرًا عنه بنص حر ، والإجابة عليه بشكل صحيح.
- اكتب برنامجًا ،من خلال تقديم صورة ، يحدد جميع الأشخاص الذين تم تصويرهم فيه ويرسم الخطوط العريضة حول كل منهم.

- اكتب برنامجًا يقدم للمستخدمين منتجات من المحتمل أن يستمتعوا بها ولكن من غير المحتمل أن يواجهوها في سياق التصفح الطبيعي.

بالنسبة لهذه المشكلات ، سيواجه حتى نخبة المبرمجين صعوبة في ترميز الحلول من الصفر. يمكن أن تختلف الأسباب. في بعض الأحيان ، يتبع البرنامج الذي نبحث عنه نمطًا يتغير بمرور الوقت ، لذلك لا توجد إجابة صحيحة ثابتة! في مثل هذه الحالات ، يجب أن يتكيف أي حل ناجح برشاقة مع عالم متغير. في أوقات أخرى ، قد تكون العلاقة (على سبيل المثال بين وحدات البكسل والفئات المجردة abstract categories) معقدة للغاية ، وتتطلب آلاف أو ملايين الحسابات واتباع مبادئ غير معروفة. في حالة التعرف على الصور ، تكمن الخطوات الدقيقة المطلوبة لأداء المهمة خارج فهمنا الواعي ، على الرغم من أن عمليات الإدراك اللاواعي لدينا تنفذ المهمة دون عناء.

التعلم الآلي Machine learning هو دراسة الخوارزميات التي يمكن أن تتعلم من التجربة. نظرًا لأن خوارزمية التعلم الآلي تجمع المزيد من الخبرة ، عادةً في شكل بيانات رصد أو تفاعلات مع بيئة ، فإن أدائها يتحسن. قارن هذا بمنصة التجارة الإلكترونية الحتمية الخاصة بنا ، والتي تتبع نفس منطق الأعمال ، بغض النظر عن مقدار الخبرة المتراكمة ، حتى يتعلم المطورون أنفسهم ويقررون أن الوقت قد حان لتحديث البرنامج. في هذا الكتاب ، سنعلمك أساسيات التعلم الآلي، مع التركيز بشكل خاص على التعلم العميق ، ومجموعة قوية من التقنيات التي تقود الابتكارات في مجالات متنوعة مثل الرؤية الحاسوبية computer vision، ومعالجة اللغة الطبيعية natural language processing، والرعاية الصحية healthcare، وعلم الجينوم genomics.

1.1 مثال محفز

قبل البدء في الكتابة ، كان على مؤلفي هذا الكتاب ، مثل الكثير من القوى العاملة ، أن يتناولوا الكافيين. قفزنا في السيارة وبدأنا في القيادة. باستخدام جهاز iPhone ، دعا أليكس "يا Siri" ، لتنبيه نظام التعرف على الصوت في الهاتف. ثم أمر Mu بـ "الاتجاهات إلى مقهى Blue Bottle". عرض الهاتف بسرعة نسخ أمره. كما أدركنا أننا كنا نطلب الاتجاهات وأطلقنا تطبيق الخرائط (التطبيق) لتلبية طلبنا. بمجرد إطلاقه ، حدد تطبيق الخرائط عددًا من المسارات. بجانب كل مسار ، عرض الهاتف وقت عبور متوقع. بينما قمنا بتلفيق هذه القصة لتوفير الراحة التربوية، فإنها توضح أنه في غضون بضع ثوانٍ فقط ، يمكن أن تتفاعل تفاعلاتنا اليومية مع الهاتف الذكي مع العديد من نماذج التعلم الآلي.

تخيل مجرد كتابة برنامج للرد على كلمة تنبيه مثل "Alexa" و "OK Google" و "Hey Siri". جرب برمجتها في غرفة بمفردك باستخدام جهاز كمبيوتر ومحرر كود ، كما هو موضح

في الشكل 1.1.1. كيف تكتب مثل هذا البرنامج من المبادئ الأولى؟ فكر في الأمر ... المشكلة صعبة. كل ثانية ، سيجمع الميكروفون ما يقرب من 44000 عينة. كل عينة هي قياس لسعة الموجة الصوتية. ما القاعدة التي يمكن تعيينها بشكل موثوق من مقتطف صوت خام إلى تنبؤات واثقة حول ما إذا كان المقتطف يحتوي على كلمة التنبيه wake؟ إذا كنت عالقًا ، فلا تقلق. نحن لا نعرف كيف نكتب مثل هذا البرنامج من الصفر أيضًا. لهذا السبب نستخدم التعلم الآلي.

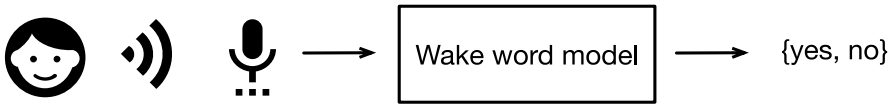

الشكل 1.1.1 تحديد كلمة Wake.

ها هي الحيلة. في كثير من الأحيان ، حتى عندما لا نعرف كيفية إخبار الكمبيوتر بشكل صريح بكيفية التعيين من المدخلات إلى المخرجات ، فإننا مع ذلك قادرون على أداء العمل الفذ المعرفي بأنفسنا. بمعنى آخر ، حتى إذا كنت لا تعرف كيفية برمجة جهاز كمبيوتر للتعرف على كلمة "Alexa" ، فأنت نفسك قادر على التعرف عليها. مسلحين بهذه الإمكانية ، يمكننا جمع مجموعة بيانات ضخمة تحتوي على أمثلة من المقتطفات الصوتية والتسميات المرتبطة بها ، مما يشير إلى المقتطفات التي تحتوي على كلمة التنبيه. في النهج السائد للتعلم الآلي ، لا نحاول تصميم نظام بشكل صريح للتعرف على كلمات التنبيه. بدلاً من ذلك ، نحدد برنامجًا مرنًا يتم تحديد سلوكه من خلال عدد من المعلمات. ثم نستخدم مجموعة البيانات لتحديد أفضل قيم المعلمات الممكنة ، أي تلك التي تعمل على تحسين أداء برنامجنا فيما يتعلق بمقياس الأداء المختار.

يمكنك التفكير في المعلمات parameters على أنها مقابض يمكننا تشغيلها ، والتلاعب بسلوك البرنامج. بتحديد المعلمات، نسمي البرنامج نموذجًا model. تسمى مجموعة جميع البرامج المميزة (تعيينات المدخلات والمخرجات input-output mappings) التي يمكننا إنتاجها فقط من خلال معالجة المعلمات بمجموعة من النماذج. والبرنامج الفوقي الذي يستخدم مجموعة البيانات الخاصة بنا لاختيار المعلمات يسمى خوارزمية التعلم learning algorithm.

قبل أن نتمكن من المضي قدمًا وإشراك خوارزمية التعلم ، يتعين علينا تحديد المشكلة بدقة ، وتحديد الطبيعة الدقيقة للمدخلات والمخرجات ، واختيار عائلة نموذجية مناسبة. في هذه الحالة، يتلقى نموذجنا مقتطفًا من الصوت كمدخلات ، ويقوم النموذج بإنشاء تحديد من بين {yes,no} المخرجات. إذا سارت الأمور وفقًا للخطة ، فعادة ما تكون تخمينات النموذج صحيحة فيما يتعلق بما إذا كان المقتطف يحتوي على كلمة wake.

إذا اخترنا مجموعة النماذج المناسبة ، فيجب أن يكون هناك إعداد واحد للمقابض بحيث يطلق النموذج "نعم" في كل مرة يسمع فيها كلمة "Alexa". نظرًا لأن الاختيار الدقيق لكلمة الاستيقاظ Wake عشوائي ، فربما نحتاج إلى عائلة نموذجية غنية بما يكفي ، من خلال إعداد آخر للمقابض ، يمكنها إطلاق "نعم" فقط عند سماع كلمة "مشمش". نتوقع أن تكون نفس العائلة النموذجية مناسبة للتعرف على "Alexa" وتقدير "المشمش Apricot" لأنهما يبدوان ، بشكل حدسي ، مهمتين متشابهتين. ومع ذلك ، قد نحتاج إلى مجموعة مختلفة من النماذج تمامًا إذا أردنا التعامل مع مدخلات أو مخرجات مختلفة اختلافًا جذريًا ، لنقل إذا أردنا التعيين من الصور إلى التسميات التوضيحية ، أو من الجمل الإنجليزية إلى الجمل الصينية.

كما قد تتخيل ، إذا قمنا بتعيين جميع المقابض بشكل عشوائي ، فمن غير المرجح أن يتعرف نموذجنا على "Alexa" أو "Apricot" أو أي كلمة إنجليزية أخرى. في التعلم الآلي ، التعلم هو العملية التي نكتشف من خلالها الإعداد الصحيح للمقابض التي تفرض السلوك المطلوب من نموذجنا. بمعنى آخر ، نقوم بتدريب نموذجنا بالبيانات. كما هو مبين في الشكل 1.1.2 ، عادة ما تبدو عملية التدريب كما يلي:

1. ابدأ بنموذج مهيأ عشوائيًا لا يمكنه فعل أي شيء مفيد.
2. احصل على بعض البيانات الخاصة بك (على سبيل المثال ، المقتطفات الصوتية والتسميات {yes,no} المقابلة).
3. قم بتعديل المقابض لجعل النموذج يعمل بشكل أفضل كما تم تقييمه في تلك الأمثلة.
4. كرر الخطوتين 2 و 3 حتى يصبح النموذج رائعًا.

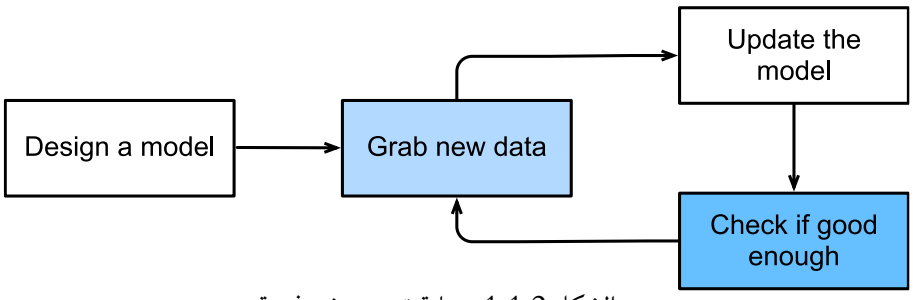

الشكل 1.1.2 عملية تدريب نموذجية.

للتلخيص ، بدلاً من ترميز أداة التعرف على كلمة التنبيه Wake ، نقوم بترميز برنامج يمكنه تعلم التعرف على كلمات التنبيه ، إذا تم تقديمها مع مجموعة بيانات كبيرة معنونة. يمكنك التفكير في هذا الفعل المتمثل في تحديد سلوك البرنامج من خلال تقديمه مع مجموعة بيانات dataset كبرمجة مع البيانات programming with data. وهذا يعني أنه يمكننا "برمجة" جهاز الكشف

عن القطط من خلال تزويد نظام التعلم الآلي الخاص بنا بالعديد من الأمثلة على القطط والكلاب. بهذه الطريقة سيتعلم الكاشف في النهاية إصدار رقم موجب كبير جداً إذا كان قطة ، ورقمًا سالبًا كبيرًا جداً إذا كان كلبًا ، وشيء أقرب إلى الصفر إذا لم يكن متأكداً. هذا بالكاد يخدش سطح ما يمكن أن يفعله التعلم الآلي. التعلم العميق Deep learning، الذي سنشرحه بمزيد من التفصيل لاحقًا ، هو مجرد واحد من بين العديد من الطرق الشائعة لحل مشاكل التعلم الآلي.

1.2 المكونات الرئيسية

في مثال كلمة التنبيه wake، وصفنا مجموعة بيانات تتكون من مقتطفات صوتية وتسميات ثنائية ، وقدمنا إحساسًا مموجًا يدويًا لكيفية تدريب نموذج لتقريب الخرائط من المقتطفات إلى التصنيفات. هذا النوع من المشاكل ، حيث نحاول التنبؤ بعلامة غير معروفة محددة بناءً على المدخلات المعروفة بمجموعة بيانات تتكون من أمثلة معروفة تسمياتها labels ، يسمى التعلم الخاضع للإشراف supervised learning. هذه مجرد واحدة من بين العديد من مشكلات التعلم الآلي. قبل أن نستكشف أصنافًا أخرى ، نود أن نلقي مزيداً من الضوء على بعض المكونات الأساسية التي ستتبعنا ، بغض النظر عن نوع مشكلة التعلم الآلي التي نتعامل معها:

1. البيانات data التي يمكننا التعلم منها.
2. النموذج model لكيفية تحويل البيانات.
3. دالة الهدف objective function تحدد مدى جودة (أو سوء) النموذج.
4. الخوارزمية algorithm لضبط معلمات النموذج لتحسين دالة الهدف.

1.2.1. البيانات Data

قد يكون من نافلة القول أنه لا يمكنك القيام بعلم البيانات data science بدون بيانات. قد نفقد مئات الصفحات عند التفكير في ماهية البيانات بالضبط ، ولكن في الوقت الحالي ، سنركز على الخصائص الرئيسية لمجموعات البيانات التي سنهتم بها. بشكل عام ، نحن مهتمون بمجموعة من الأمثلة. من أجل العمل مع البيانات بشكل مفيد ، نحتاج عادةً إلى التوصل إلى تمثيل رقمي مناسب. يتكون كل مثال (أو نقطة بيانات data point، مثيل بيانات data instance، عينة sample) عادةً من مجموعة من السمات تسمى الميزات features (تسمى أحيانًا المتغيرات المشتركة أو المدخلات) ، بناءً على النموذج الذي يجب أن يقوم بتنبؤاته. في مشاكل التعلم الخاضعة للإشراف ، هدفنا هو التنبؤ بقيمة سمة خاصة ، تسمى التسمية label (أو الهدف target) ،والتي ليست جزءًا من مدخلات النموذج.

إذا كنا نعمل مع بيانات الصورة ، فقد يتكون كل مثال من صورة فردية (الميزات features) ورقم يشير إلى الفئة التي تنتمي إليها الصورة (التسمية label). سيتم تمثيل الصورة عدديًا على شكل ثلاث شبكات من القيم الرقمية التي تمثل سطوع الضوء الأحمر والأخضر والأزرق في كل

موقع بكسل. على سبيل المثال 200×200 ، قد تتكون الصورة الملونة من $200 \times 200 \times 3 = 120000$ قيم عددية.

بدلاً من ذلك ، قد نعمل مع بيانات السجلات الصحية الإلكترونية ونتعامل مع مهمة التنبؤ باحتمالية بقاء مريض معين على قيد الحياة خلال الثلاثين يومًا القادمة. هنا ، قد تتكون ميزاتنا من مجموعة من السمات المتاحة بسهولة والقياسات المسجلة بشكل متكرر ، بما في ذلك العمر والعلامات الحيوية والأمراض المصاحبة والأدوية الحالية والإجراءات الحديثة. سيكون التسمية المتاحة label للتدريب عبارة عن قيمة ثنائية تشير إلى ما إذا كان كل مريض في البيانات التاريخية قد نجا خلال نافذة الثلاثين يومًا.

في مثل هذه الحالات، عندما يتميز كل مثال بنفس عدد السمات العددية، نقول إن المدخلات عبارة عن متجهات ذات طول ثابت ونطلق على الطول (الثابت) للمتجهات أبعاد البيانات dimensionality of the data. كما قد تتخيل، يمكن أن تكون المدخلات ذات الطول الثابت مريحة، مما يمنحنا تعقيدًا أقل للقلق. ومع ذلك، لا يمكن بسهولة تمثيل جميع البيانات كمتجهات ثابتة الطول fixed-length vectors. بينما قد نتوقع أن تأتي الصور المجهرية من معدات قياسية، لا يمكننا أن نتوقع أن تظهر الصور الملغومة من الإنترنت جميعها بنفس الدقة أو الشكل. بالنسبة للصور، قد نفكرفي اقتصاصها جميعًا إلى الحجم القياسي، لكن هذه الإستراتيجية تصلنا فقط حتى الآن. نحن نجازف بفقدان المعلوماتفي الأجزاء المقتطعة. علاوة على ذلك، تقاوم البيانات النصية التمثيلات ذات الطول الثابت بشكل أكثر عنادًا. ضعفي اعتبارك تقييمات العملاء المتبقية على مواقع التجارة الإلكترونية مثل Amazon وIMDb وTripAdvisor. بعضها قصير: "ينتن! it stinks!". يتجول آخرون للصفحات. تتمثل إحدى الميزات الرئيسية للتعلم العميق على الطرق التقليديةفي النعمة المقارنة التي يمكن للنماذج الحديثة من خلالها التعامل مع بيانات متفاوتة الطول varying-length data.

بشكل عام، كلما زادت البيانات المتوفرة لدينا، أصبحت مهمتنا أسهل. عندما يكون لدينا المزيد من البيانات، يمكننا تدريب نماذج أكثر قوة والاعتماد بشكل أقل على الافتراضات المسبقة. يعد تغيير النظام من البيانات الصغيرة (نسبيًا) إلى البيانات الكبيرة مساهماً رئيسياًفي نجاح التعلم العميق الحديث. لتوجيه هذه النقطة الرئيسية، لا تعمل العديد من النماذج الأكثر إثارةفي التعلم العميق بدون مجموعات البيانات الكبيرة. يعمل البعض الآخرفي نظام البيانات الصغيرة، لكنها ليست أفضل من الأساليب التقليدية.

أخيرًا، لا يكفي وجود الكثير من البيانات ومعالجتها بذكاء. نحن بحاجة إلى البيانات الصحيحة. إذا كانت البيانات مليئة بالأخطاء، أو إذا كانت الميزات المختارة لا تنبئ بالكمية المستهدفة من الاهتمام، فإن التعلم سيفشل. يتم التقاط الموقف جيداً من خلال الكليشيهات:

القمامةفي الداخل، والقمامة خارج garbage in, garbage out. علاوة على ذلك، فإن ضعف الأداء التنبئي ليس هو النتيجة المحتملة الوحيدة.في التطبيقات الحساسة للتعلم الآلي، مثل السياسة التنبؤية predictive policing، واستئناف الفحص resume screening، ونماذج المخاطر risk models المستخدمة للإقراض lending، يجب أن نكون متيقظين بشكل خاص لعواقب البيانات المهملة garbage data. يحدث أحد أوضاع الفشل الشائعةفي مجموعات البيانات حيث لا يتم تمثيل بعض مجموعات الأشخاصفي بيانات التدريب. تخيل تطبيق نظام التعرف على سرطان الجلدفي البرية لم يسبق له مثيل من قبل. يمكن أن يحدث الفشل أيضًا عندما لا تكون البيانات مجرد تمثيل ناقص لبعض المجموعات ولكنها تعكس التحيزات المجتمعية. على سبيل المثال، إذا تم استخدام قرارات التوظيف السابقة لتدريب نموذج تنبؤي سيتم استخدامه لفحص السير الذاتية، فيمكن لنماذج التعلم الآلي عن غير قصد التقاط المظالم التاريخية التلقائيًا automate historical injustices. لاحظ أن كل هذا يمكن أن يحدث دون أن يتآمر عالم البيانات بنشاط، أو حتى أن يكون على علم.

1.2.2. النماذج Models

يتضمن معظم التعلم الآلي تحويل البيانات إلى حد ما. قد نرغبفي بناء نظام يستوعب الصور ويتنبأ بالابتسامة. بدلاً من ذلك، قد نرغبفي استيعاب مجموعة من قراءات أجهزة الاستشعار والتنبؤ بمدى طبيعية مقارنة القراءات الشاذة. حسب النموذج، نشير إلى الآلية الحسابية لاستيعاب البيانات من نوع واحد، وإخراج تنبؤات من نوع مختلف محتمل. على وجه الخصوص، نحن مهتمون بالنماذج الإحصائية التي يمكن تقديرها من البيانات.في حين أن النماذج البسيطة قادرة تمامًا على معالجة المشكلات البسيطة بشكل مناسب، فإن المشكلات التي نركز عليهافي هذا الكتاب تزيد من حدود الطرق الكلاسيكية. يختلف التعلم العميق عن الأساليب الكلاسيكية بشكل أساسي من خلال مجموعة النماذج القوية التي يركز عليها. تتكون هذه النماذج من العديد من التحولات المتتالية للبيانات التي يتم ربطها ببعضها البعض من أعلى إلى أسفل، وبالتالي يُطلق عليها اسم التعلم العميق deep learning.في طريقنا لمناقشة النماذج العميقة، سنناقش أيضًا بعض الأساليب التقليدية.

1.2.3. دوال الهدف Objective Functions

في وقت سابق ، قدمنا التعلم الآلي باعتباره التعلم من التجربة. من خلال التعلم هنا ، فإننا نعني التحسين في بعض المهام بمرور الوقت. ولكن من سيقول ما الذي يشكل تحسنا؟ قد تتخيل أنه يمكننا اقتراح تحديث نموذجنا ، وقد يختلف بعض الأشخاص حول ما إذا كان التحديث المقترح يمثل تحسينًا أم رفضًا.

من أجل تطوير نظام رياضي رسمي لآلات التعلم ، نحتاج إلى مقاييس رسمية لمدى جودة (أو سوء) نماذجنا. في التعلم الآلي والتحسين بشكل عام ، نسمي هذه دوال الهدف Objective Functions. حسب الاصطلاح ، نحدد عادة دوال الهدف بحيث يكون الأقل أفضل. هذه مجرد اتفاقية. يمكنك أن تأخذ أي دالة أعلى هو أفضل ، وتحويلها إلى دالة جديدة متطابقة نوعيا ولكن الأقل أفضل من خلال قلب العلامة. لأن الأقل هو الأفضل ، تسمى هذه الدوال أحيانًا دوال الخسارة او الخطأ loss functions.

عند محاولة التنبؤ بالقيم العددية ، فإن دالة الخطأ الأكثر شيوعًا هي الخطأ التربيعي squared error، أي مربع الفرق بين التنبؤ والهدف الحقيقي ground truth target. بالنسبة للتصنيف، فإن الهدف الأكثر شيوعًا هو تقليل معدل الخطأ ، أي جزء من الأمثلة التي لا تتفق توقعاتنا معها مع الحقيقة الأساسية. من السهل تحسين بعض الأهداف (على سبيل المثال، الخطأ التربيعي squared error) ، بينما يصعب تحسين أهداف أخرى (على سبيل المثال ، معدل الخطأ error rate) بشكل مباشر ، بسبب عدم التفاضل أو المضاعفات الأخرى. في هذه الحالات ، من الشائع تحسين هدف بديل surrogate objective.

أثناء التحسين ، نفكر في الخطأ كدالة لمعلمات النموذج ، ونتعامل مع مجموعة بيانات التدريب باعتبارها ثابتة. نتعلم أفضل القيم لمعلمات نموذجنا من خلال تقليل الخطأ المتكبد على مجموعة تتكون من عدد من الأمثلة التي تم جمعها للتدريب. ومع ذلك ، فإن الأداء الجيد في بيانات التدريب لا يضمن أننا سنعمل بشكل جيد على البيانات غير المرئية. لذلك سنريد عادةً تقسيم البيانات المتاحة إلى قسمين: مجموعة بيانات التدريب training dataset (أو مجموعة التدريب training set)، من أجل معلمات نموذج التعلم ؛ ومجموعة بيانات الاختبار test dataset (أو مجموعة الاختبار test set)، والتي تم تعليقها للتقييم. في نهاية اليوم ، نُبلغ عادةً عن أداء نماذجنا على كلا القسمين. يمكنك التفكير في الأداء التدريبي باعتباره مشابهًا للدرجات التي يحققها الطالب في امتحانات الممارسة المستخدمة للتحضير لامتحان نهائي حقيقي. حتى لو كانت النتائج مشجعة ، فهذا لا يضمن النجاح في الامتحان النهائي. خلال فترة الدراسة ، قد يبدأ الطالب في حفظ أسئلة الممارسة ، ويبدو أنه يتقن الموضوع ولكنه يتعثر عند مواجهة أسئلة لم تتم رؤيتها من قبل في الاختبار النهائي الفعلي. عندما يكون أداء النموذج جيدًا في مجموعة التدريب ولكنه يفشل في التعميم على البيانات غير المرئية ، فإننا نقول إنه يعاني من فرط التجهيز او التعلم overfitting مع بيانات التدريب.

1.2.4. خوارزميات التحسين Optimization Algorithms

بمجرد حصولنا على بعض مصادر البيانات والتمثيل ، ونموذج ، ودالة هدف محددة جيدًا ، نحتاج إلى خوارزمية قادرة على البحث عن أفضل المعلمات الممكنة لتقليل دالة الخطأ. تعتمد

خوارزميات التحسين الشائعة للتعلم العميق على نهج يسمى التدرج الاشتقاقي gradient descent باختصار ، في كل خطوة ، تتحقق هذه الطريقة لترى ، لكل معلمة ، الطريقة التي ستتحرك بها خطأ مجموعة التدريب إذا قمت بتشويش هذه المعلمة بمقدار صغير فقط. ثم يقوم بتحديث المعلمة في الاتجاه الذي يقلل من الخطأ.

1.3 أنواع مشاكل التعلم الآلي

مشكلة كلمة الاستيقاظ Wake في مثالنا التحفيزي هي مجرد واحدة من بين العديد من المشكلات التي يمكن أن يعالجها التعلم الآلي. لتحفيز القارئ بشكل أكبر وتزويدنا ببعض اللغة المشتركة التي ستتبعنا في جميع أنحاء الكتاب ، نقدم الآن نظرة عامة واسعة على مشهد تركيبات مشكلة التعلم الآلي.

1.3.1. التعلم الخاضع للإشراف Supervised Learning

يصف التعلم الخاضع للإشراف المهام حيث يتم تزويدنا بمجموعة بيانات تحتوي على كل من الميزات features والتسميات labels ويتم تكليفنا بإنتاج نموذج للتنبؤ بالتسميات المعطاة لميزات الإدخال. يُطلق على كل زوج من السمات والتسمية (feature—label pair) مثالاً Example. في بعض الأحيان ، عندما يكون السياق واضحًا، قد نستخدم مصطلح الأمثلة للإشارة إلى مجموعة من المدخلات ، حتى عندما تكون التسميات المقابلة غير معروفة. يتم تشغيل الإشراف لأنه من أجل اختيار المعلمات ، فإننا (المشرفون) نوفر للنموذج مجموعة بيانات تتكون من أمثلة مصنفة. من الناحية الاحتمالية ، نحن مهتمون عادةً بتقدير الاحتمال الشرطي لسمات إدخال معينة. في حين أنه مجرد نموذج واحد من بين عدة نماذج في التعلم الآلي ، فإن التعلم الخاضع للإشراف يمثل غالبية التطبيقات الناجحة للتعلم الآلي في الصناعة. يرجع ذلك جزئيًا إلى أنه يمكن وصف العديد من المهام المهمة بدقة على أنها تقدير احتمالية وجود شيء غير معروف في ضوء مجموعة معينة من البيانات المتاحة:

- توقع الإصابة بالسرطان مقابل ليس السرطان ، في ضوء صورة التصوير المقطعي بالكمبيوتر.
- توقع الترجمة الصحيحة باللغة الفرنسية ، مع إعطاء جملة بالإنجليزية.
- توقع سعر السهم الشهر المقبل بناءً على بيانات التقارير المالية لهذا الشهر.

بينما يتم التقاط جميع مشكلات التعلم الخاضع للإشراف من خلال الوصف البسيط "التنبؤ بالتسميات المقدمة لميزات الإدخال" ، يمكن أن يتخذ التعلم تحت الإشراف أشكالًا متنوعة ويتطلب الكثير من قرارات النمذجة ، اعتمادًا على (من بين اعتبارات أخرى) نوع وحجم وكمية المدخلات والمخرجات. على سبيل المثال ، نستخدم نماذج مختلفة لمعالجة متواليات أطوال عشوائية sequences of arbitrary lengths ومعالجة تمثيلات المتجهات ذات الطول الثابت

fixed-length vector representations. سوف نتعمق في العديد من هذه المشاكل خلال هذا الكتاب.

بشكل غير رسمي ، تبدو عملية التعلم كما يلي. أولاً ، احصل على مجموعة كبيرة من الأمثلة التي تُعرف بها الميزات واختر منها مجموعة فرعية عشوائية ، واكتسب تسميات الحقيقة الأساسية لكل منها. في بعض الأحيان ، قد تكون هذه التسميات هي البيانات المتاحة التي تم جمعها بالفعل (على سبيل المثال ، هل مات مريض خلال العام التالي؟) وفي أحيان أخرى قد نحتاج إلى توظيف شروح بشرية لتسمية البيانات ، (على سبيل المثال ، تعيين الصور للفئات). تشكل هذه المدخلات والتسميات المقابلة معًا مجموعة التدريب. نقوم بتغذية مجموعة بيانات التدريب في خوارزمية تعلم خاضعة للإشراف ، وهي دالة تأخذ مجموعة بيانات كمدخلات وتخرج دالة أخرى: النموذج الذي تم تعلمه. أخيرًا ، يمكننا تغذية المدخلات غير المرئية سابقًا إلى النموذج الذي تم تعلمه ، باستخدام مخرجاته كتنبؤات للتسمية المقابلة. تم رسم العملية الكاملة في الشكل 1.3.1.

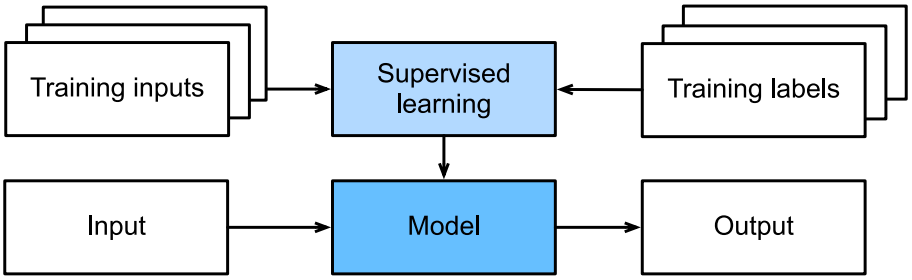

الشكل 1.3.1 التعلم الخاضع للإشراف.

1.3.1.1. الانحدار Regression

ربما يكون الانحدار هو أبسط مهمة تعليمية خاضعة للإشراف لتلتف حولها. ضع في اعتبارك، على سبيل المثال ، مجموعة من البيانات التي تم جمعها من قاعدة بيانات مبيعات المنازل. قد نقوم ببناء جدول ، حيث يتوافق كل صف مع منزل مختلف ، وكل عمود يتوافق مع بعض السمات ذات الصلة ، مثل المساحة المربعة للمنزل ، وعدد غرف النوم ، وعدد الحمامات ، وعدد الدقائق (المشي)) إلى وسط المدينة. في مجموعة البيانات هذه ، سيكون كل مثال منزلًا محددًا ، وسيكون متجه الميزة المقابل في صف واحد في الجدول. إذا كنت تعيش في نيويورك أو سان فرانسيسكو ، ولم تكن الرئيس التنفيذي لشركة Amazon أو Google أو Microsoft أو Facebook ، فإن (لقطات مربعة ، عدد غرف النوم ، عدد الحمامات ، مسافة سير) ميزة متجه لمنزلك قد يبدو مثل: [600,1,1,60]. ومع ذلك ، إذا كنت تعيش في بيتسبرغ ، فقد يبدو

الأمر أشبه [3000,4,3,10]. تعد متجهات الميزات ذات الطول الثابت مثل هذه ضرورية لمعظم خوارزميات التعلم الآلي الكلاسيكية.

ما يجعل مشكلة ما هو الانحدار هو في الواقع شكل الهدف. قل أنك في السوق للحصول على منزل جديد. قد ترغب في تقدير القيمة السوقية العادلة للمنزل ، مع الأخذ في الاعتبار بعض الميزات مثل أعلاه. قد تتكون البيانات هنا من قوائم المنازل التاريخية وقد تكون التسميات هي أسعار المبيعات المرصودة. عندما تأخذ التسميات قيمًا رقمية عشوائية (حتى ضمن فترة زمنية معينة) ، فإننا نسمي هذا مشكلة الانحدار. الهدف هو إنتاج نموذج تقارب تنبؤاته بشكل وثيق قيم التسمية الفعلية.

الكثير من المشاكل العملية توصف بسهولة بأنها مشاكل انحدار. يمكن اعتبار توقع التصنيف الذي سيخصصه المستخدم لفيلم ما مشكلة انحدار وإذا صممت خوارزمية رائعة لإنجاز هذا العمل الفذ في عام 2009 ، فربما تكون قد فزت بجائزة Netflix البالغة مليون دولار. توقع طول إقامة المرضى في المستشفى هو أيضا مشكلة الانحدار. من القواعد الأساسية الجيدة أن أي كم؟ أو كم عددها؟ يجب أن تشير المشكلة إلى الانحدار ، على سبيل المثال:

- كم ساعة ستستغرق هذه الجراحة؟
- كم ستهطل الامطار في هذه البلدة خلال الساعات الست القادمة؟

حتى لو لم تكن قد عملت مع التعلم الآلي من قبل، فمن المحتمل أنك عملت من خلال مشكلة الانحدار بشكل غير رسمي. تخيل ، على سبيل المثال ، أنك قمت بإصلاح البالوعات الخاصة بك وأن السباك الخاص بك أمضى 3 ساعات في إزالة الأوساخ من أنابيب الصرف الصحي الخاصة بك. ثم أرسل لك فاتورة بقيمة 350 دولارًا. تخيل الآن أن صديقك استأجر نفس السباك لمدة ساعتين وأنه تلقى فاتورة بقيمة 250 دولارًا. إذا سألك شخص ما بعد ذلك عن المبلغ الذي تتوقعه في فاتورته القادمة لإزالة المواد غير المرغوب فيها ، فقد تضع بعض الافتراضات المعقولة ، مثل زيادة ساعات العمل التي تكلف المزيد من الدولارات. قد تفترض أيضًا أن هناك بعض الرسوم الأساسية وأن المقاول يتقاضى رسومًا في الساعة. إذا كانت هذه الافتراضات صحيحة ، فبالنظر إلى هذين المثالين من البيانات ، يمكنك بالفعل تحديد هيكل تسعير المقاول: 100 دولار للساعة بالإضافة إلى 50 دولارًا لتظهر في منزلك. إذا اتبعت هذا كثيرًا ، فأنت بالفعل تفهم الفكرة رفيعة المستوى وراء الانحدار الخطي linear regression.

في هذه الحالة ، يمكننا إنتاج المعلمات التي تتطابق تمامًا مع أسعار السباك. في بعض الأحيان لا يكون هذا ممكنًا ، على سبيل المثال ، إذا كان بعض التباين مدينًا بعدة عوامل إلى جانب الميزتين. في هذه الحالات ، سنحاول تعلم النماذج التي تقلل المسافة بين تنبؤاتنا والقيم المرصودة. في معظم فصولنا ، سنركز على تقليل دالة الخطأ التربيعية squared error loss

function. كما سنرى لاحقًا ، تتوافق هذه الخطأ مع الافتراض بأن بياناتنا قد تعرضت للتلف بسبب الضوضاء الغاوسية Gaussian noise.

1.3.1.2. التصنيف classification

بينما تعتبر نماذج الانحدار رائعة لمعالجة كم عدد؟ الأسئلة ، الكثير من المشاكل لا تنحني بشكل مريح لهذا القالب. ضع في اعتبارك ، على سبيل المثال ، بنكًا يريد تطوير ميزة مسح الشيكات لتطبيقه على الهاتف المحمول. من الناحية المثالية ، يقوم العميل ببساطة بالتقاط صورة للشيك وسيقوم التطبيق تلقائيًا بالتعرف على النص من الصورة. بافتراض أن لدينا بعض القدرة على تجزئة تصحيحات الصور المقابلة لكل حرف مكتوب بخط اليد ، فإن المهمة الأساسية المتبقية ستكون تحديد أي حرف من بين مجموعة معروفة يتم تصويره في كل تصحيح صورة. هذه الأنواع من أي واحد؟ تسمى المشاكل التصنيف classification وتتطلب مجموعة من الأدوات مختلفة عن تلك المستخدمة في الانحدار ، على الرغم من أن العديد من التقنيات ستستمر.

في التصنيف ، نريد أن ينظر نموذجنا في الميزات ، على سبيل المثال ، قيم البكسل في صورة ما، ثم يتنبأ بالصنف category (تسمى أحيانًا فئة class) من بين مجموعة منفصلة من الخيارات ، مثال ينتمي. بالنسبة للأرقام المكتوبة بخط اليد ، قد يكون لدينا عشر فئات ، مطابقة للأرقام من 0 إلى 9. أبسط شكل من أشكال التصنيف هو عندما يكون هناك فئتان فقط ، وهي مشكلة نسميها التصنيف الثنائيbinary classification. على سبيل المثال ، يمكن أن تتكون مجموعة البيانات الخاصة بنا من صور للحيوانات وقد تكون تسمياتنا هي الفئات {cat, dog}. بينما في الانحدار ، سعينا إلى معادل لإخراج قيمة عددية ، في التصنيف ، نبحث عن مصنف classifier، يكون ناتجه هو تعيين الفئة المتوقعة.

لأسباب سوف ندخل فيها عندما يصبح الكتاب أكثر تقنية ، قد يكون من الصعب تحسين نموذج يمكنه فقط إخراج مهمة فئوية صعبة، على سبيل المثال ، إما "قطة" أو "كلب". في هذه الحالات ، يكون من الأسهل عادةً التعبير عن نموذجنا بلغة الاحتمالات. بالنظر إلى ميزات أحد الأمثلة ، يقوم نموذجنا بتعيين احتمالية لكل فئة ممكنة. بالعودة إلى مثال تصنيف الحيوانات الخاص بنا حيث توجد الفئات ، قد يرى المصنف صورة ويخرج احتمالية أن الصورة قطة بقيمة 0.9. يمكننا تفسير هذا الرقم بالقول إن المصنف متأكد بنسبة 90٪ من أن الصورة تصور قطة. ينقل حجم الاحتمالية للفئة المتوقعة فكرة واحدة عن عدم اليقين uncertainty. إنها ليست الفكرة الوحيدة لعدم اليقين وسنناقش الآخرين في فصول أكثر تقدمًا.

عندما يكون لدينا أكثر من فئتين محتملتين ، فإننا نسمي المشكلة تصنيف متعدد الفئات multiclass classification. تشمل الأمثلة الشائعة التعرف على الأحرف المكتوبة بخط اليد

{... ,9 ... ,2,1,0}. بينما هاجمنا مشاكل الانحدار من خلال محاولة تقليل دالة خسارة الخطأ التربيعية ، فإن دالة الخسارة الشائعة لمشاكل التصنيف تسمى الانتروبيا المتقاطعة cross-entropy ، والتي يمكن إزالة الغموض عن اسمها من خلال مقدمة لنظرية المعلومات في الفصول اللاحقة.

لاحظ أن الفئة الأكثر ترجيحًا ليست بالضرورة هي التي ستستخدمها لاتخاذ قرارك. افترض أنك وجدت فطرًا جميلًا في الفناء الخلفي الخاص بك كما هو موضح في الشكل 1.3.2.

الشكل 1.3.2 Death cap ـ لا تأكل!

الآن ، افترض أنك قمت ببناء مصنف ودربته على التنبؤ بما إذا كان الفطر سامًا بناءً على صورة فوتوغرافية. لنفترض أن مخرجات مصنف اكتشاف السموم لدينا تشير إلى أن احتمال احتواء الشكل 1.3.2 على فطر سام Death cap هو 0.2. بعبارة أخرى ، المصنف متأكد بنسبة 80٪ أن الفطر ليس ساماً Death cap. ومع ذلك ، يجب أن تكون أحمق لتأكله. وذلك لأن الفائدة المؤكدة من تناول عشاء لذيذ لا تساوي 20٪ خطر الموت منه. وبعبارة أخرى ، فإن تأثير المخاطر غير المؤكدة يفوق المنفعة إلى حد بعيد. وبالتالي ، من أجل اتخاذ قرار بشأن تناول الفطر ، نحتاج إلى حساب عدم الانتظام المتوقع المرتبط بكل إجراء والذي يعتمد على كل من النتائج المحتملة والفوائد أو الأضرار المرتبطة بكل منها. في هذه الحالة ، قد يكون الفقد الناتج عن تناول الفطر $0.2 \times \infty + 0.8 \times 0 = \infty$ ، في حين أن فقدان التخلص منه هو $0.2 \times 0 + 0.8 \times 1 = 0.8$. كان حذرنا مبررًا: كما يخبرنا أي اختصاصي فطريات ، فإن الفطر في الشكل 1.3.2 هو في الواقع Death cap.

يمكن أن يصبح التصنيف أكثر تعقيداً من مجرد التصنيف الثنائي أو متعدد الفئات. على سبيل المثال ، هناك بعض متغيرات التصنيف التي تتناول الفئات المهيكلة بشكل هرمي. في مثل هذه الحالات ، ليست كل الأخطاء متساوية ـ إذا كان يجب علينا أن نخطئ ، فقد نفضل أن نخطئ

في التصنيف إلى فئة ذات صلة بدلاً من فئة بعيدة. عادة ، يشار إلى هذا التصنيف الهرمي hierarchical classification. للإلهام، قد تفكر في Linnaeus ، الذي نظم الحيوانات في تسلسل هرمي.

في حالة تصنيف الحيوانات، قد لا يكون من السيئ جدًا الخلط بين كلب بودل وشنوزر ، لكن نموذجنا سيدفع غرامة كبيرة إذا خلط بين كلب بودل وديناصور. قد يعتمد التسلسل الهرمي المناسب على كيفية التخطيط لاستخدام النموذج. على سبيل المثال ، قد تكون الأفاعي الجرسية والثعابين ذات الأربطة قريبة من شجرة النشوء والتطور ، ولكن يمكن أن يكون الخلط بين أفعى الجرذ وجرباب مميتًا.

1.3.1.3. وضع العلامات Tagging

تتلاءم بعض مشكلات التصنيف بدقة مع إعدادات التصنيف الثنائي أو متعدد الفئات. على سبيل المثال ، يمكننا تدريب مصنف ثنائي عادي لتمييز القطط عن الكلاب. نظرًا للحالة الحالية للرؤية الحاسوبية ، يمكننا القيام بذلك بسهولة باستخدام أدوات جاهزة. ومع ذلك ، بغض النظر عن مدى دقة نموذجنا ، فقد نجد أنفسنا في مأزق عندما يصادف المصنف صورة لموسيقي المدينة في بريمن Town Musicians of Bremen ، وهي قصة خيالية ألمانية شهيرة تضم أربعة حيوانات (الشكل 1.3.3).

الشكل: 1.3.3 حمار ، كلب ، قطة ، وديك.

كما ترى ، تظهر الصورة قطة وديك وكلب وحمار مع بعض الأشجار في الخلفية. عندما نتوقع مواجهة مثل هذه الصور ، قد لا يكون التصنيف متعدد الفئات هو الصيغة الصحيحة للمشكلة. بدلاً من ذلك ، قد نرغب في منح النموذج خيار قول أن الصورة تصور قطة وكلبًا وحمارًا وديكًا.

تسمى مشكلة تعلم التنبؤ بالفئات التي لا تستبعد بعضها البعض بالتصنيف متعدد التسميات multi-label classification. أفضل وصف لمشاكل وضع العلامات التلقائي هو مشاكل التصنيف متعدد التصنيفات multi-label classification problems. فكر في العلامات التي قد يطبقها الأشخاص على المنشورات في مدونة تقنية ، على سبيل المثال ، "التعلم الآلي" ، "التكنولوجيا" ، "الأدوات" ، "لغات البرمجة" ، "Linux" ، "الحوسبة السحابية" ، "AWS". قد يتم تطبيق 5 ـ 10 علامات على المقالة النموذجية. عادةً ، ستعرض العلامات بعض بنية الارتباط correlation structure. من المرجح أن تشير المنشورات حول "الحوسبة السحابية" إلى "AWS" ومن المرجح أن تشير المشاركات حول "التعلم الآلي" إلى "وحدات معالجة الرسومات GPUs".

في بعض الأحيان ، تعتمد مشاكل وضع العلامات هذه على مجموعات تصنيف هائلة. توظف المكتبة الوطنية للطب العديد من المعلقين المحترفين الذين يربطون كل مقالة ليتم فهرستها في PubMed بمجموعة من العلامات المستمدة من الأنطولوجيا لعناوين الموضوعات الطبية (MeSH) ، وهي مجموعة من 28000 علامة تقريبًا. يعد وضع علامات على المقالات بشكل صحيح أمرًا مهمًا لأنه يسمح للباحثين بإجراء مراجعات شاملة للأدبيات. هذه عملية تستغرق وقتًا طويلاً وعادةً ما يكون للمضيفين فترة تأخير لمدة عام واحد بين الأرشفة ووضع العلامات. يمكن أن يوفر التعلم الآلي علامات مؤقتة حتى يمكن الحصول على مراجعة يدوية مناسبة لكل مقالة. في الواقع ، لعدة سنوات ، استضافت منظمة BioASQ مسابقات لهذه المهمة.

1.3.1.4. البحث Search

في مجال استرجاع المعلومات information retrieval، غالبًا ما نفرض تصنيفات على مجموعات من العناصر. خذ بحث الويب على سبيل المثال. لا يتمثل الهدف في تحديد ما إذا كانت صفحة معينة ذات صلة باستعلام ما ، ولكن بدلاً من ذلك ، من بين مجموعة النتائج ذات الصلة التي يجب عرضها بشكل بارز لمستخدم معين. قد يكون أحد الحلول الممكنة هو تعيين درجة لكل عنصر في المجموعة أولاً ثم استرداد العناصر ذات التصنيف الأعلى. كانت PageRank ، وهي الخلطة السرية الأصلية وراء محرك بحث Google ، مثالًا مبكرًا على نظام التسجيل هذا. ومن الغريب أن الدرجات التي يوفرها نظام ترتيب الصفحات لا تعتمد على الاستعلام الفعلي. بدلاً من ذلك ، اعتمدوا على عامل تصفية بسيط للأهمية لتحديد مجموعة المرشحين ذوي الصلة ثم استخدموا نظام ترتيب الصفحات PageRank لتحديد أولويات الصفحات الأكثر موثوقية. في الوقت الحاضر ، تستخدم محركات البحث التعلم الآلي والنماذج

السلوكية behavioral models للحصول على درجات ذات صلة تعتمد على الاستعلام. هناك مؤتمرات أكاديمية كاملة مخصصة لهذا الموضوع.

1.3.1.5. أنظمة التوصية Recommender Systems

أنظمة التوصية Recommender Systems هي إعداد مشكلة آخر يتعلق بالبحث والتصنيف. تتشابه المشكلات بقدر ما يتمثل الهدفي عرض مجموعة من العناصر ذات الصلة للمستخدم. الاختلاف الرئيسي هو التركيز على التخصيص لمستخدمين محددينفي سياق أنظمة التوصية. على سبيل المثال، بالنسبة لتوصيات الأفلام، قد تختلف صفحة النتائج لمحبي الخيال العلمي وصفحة النتائج لمتذوقي الأعمال الكوميدية لبيتر سيلرز اختلافًا كبيرًا. تظهر مشكلات مماثلةفي إعدادات التوصية الأخرى، على سبيل المثال، لمنتجات البيع بالتجزئة والموسيقى والتوصية بالأخبار.

في بعض الحالات، يقدم العملاء ملاحظات صريحة، لإبلاغهم بمدى إعجابهم بمنتج معين (على سبيل المثال، تقييمات المنتج والمراجعات على Amazon وIMDb وGoodreads). في حالات أخرى، يقدمون تعليقات ضمنية، على سبيل المثال، عن طريق تخطي العناوينفي قائمة التشغيل، مما قد يشير إلى عدم الرضا، أو قد يشير فقط إلى أن الأغنية كانت غير مناسبةفي السياق.في أبسط الصيغ، يتم تدريب هذه الأنظمة لتقدير بعض النقاط، مثل التصنيف النجمي المتوقع أو احتمال قيام مستخدم معين بشراء عنصر معين.

بالنظر إلى مثل هذا النموذج، لأي مستخدم معين، يمكننا استرداد مجموعة الكائنات ذات الدرجات الأكبر، والتي يمكن بعد ذلك التوصية بها للمستخدم. تعد أنظمة الإنتاج أكثر تقدمًا بشكل كبير وتأخذفي الاعتبار نشاط المستخدم المفصل وخصائص العنصر عند حساب مثل هذه الدرجات. يعرض الشكل 1.3.4 كتب التعلم العميق التي أوصت بها أمازون بناءً على خوارزميات التخصيص التي تم ضبطها لالتقاط تفضيلات أستون Aston's preferences.

على الرغم من قيمتها الاقتصادية الهائلة، فإن أنظمة التوصية المبنية بسذاجة على النماذج التنبؤية تعاني من بعض العيوب المفاهيمية الخطيرة. للبدء، نلاحظ فقط التعليقات الخاضعة للرقابة: يفضل المستخدمون تقييم الأفلام التي يشعرون بقوة تجاهها. على سبيل المثال، على مقياس مكون من خمس نقاط، قد تلاحظ أن العناصر تتلقى العديد من التقييمات ذات النجمة الواحدة والخمس نجوم ولكن هناك عددًا قليلاً من التقييمات الثلاث نجوم بشكل واضح. علاوة على ذلك، غالبًا ما تكون عادات الشراء الحالية نتيجة لخوارزمية التوصية المعمول بها حاليًا، لكن خوارزميات التعلم لا تأخذ دائمًا هذه التفاصيلفي الاعتبار. وبالتالي، من الممكن أن تتشكل حلقات التغذية الراجعة حيث يدفع نظام التوصية بشكل تفضيلي عنصرًا يتم أخذه ليكون أفضل (بسبب عمليات الشراء الأكبر) وبالتالي يوصى به بشكل متكرر أكثر. العديد من هذه المشاكل

المتعلقة بكيفية التعامل مع الرقابة والحوافز وحلقات التغذية الراجعة هي أسئلة بحثية مفتوحة ومهمة.

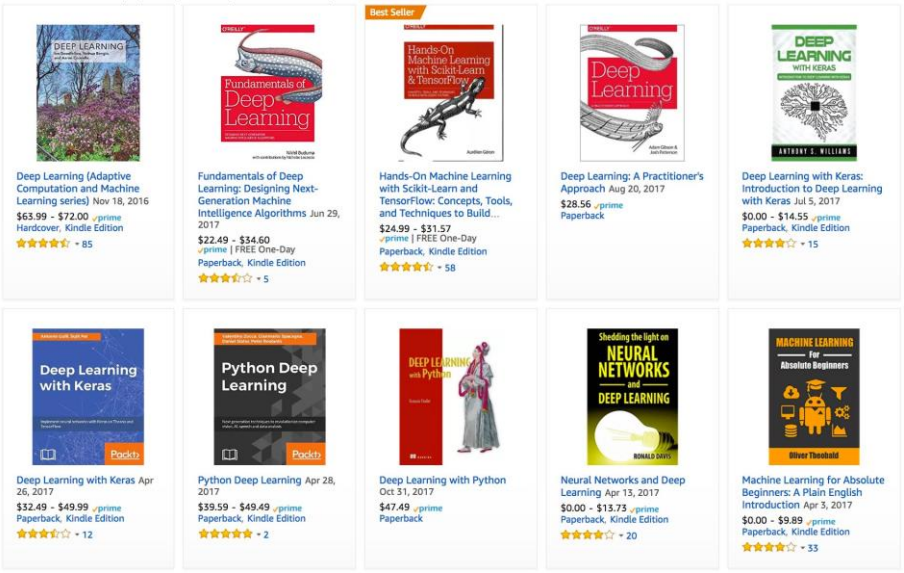

الشكل 1.3.4 كتب التعلم العميق التي أوصت بها أمازون.

1.3.1.6. التعلم المتسلسل Sequence Learning

حتى الآن ، نظرنا في المشكلات حيث لدينا عددًا ثابتًا من المدخلات وننتج عددًا ثابتًا من المخرجات. على سبيل المثال ، أخذنا في الاعتبار توقع أسعار المنازل في ضوء مجموعة ثابتة من الميزات: المساحة بالقدم المربع ، وعدد غرف النوم ، وعدد الحمامات ، ووقت العبور إلى وسط المدينة. ناقشنا أيضًا التعيين من صورة (ذات بُعد ثابت) إلى الاحتمالات المتوقعة التي تنتمي إليها كل واحدة من بين عدد ثابت من الفئات والتنبؤ بتصنيفات النجوم المرتبطة بالمشتريات بناءً على معرف المستخدم ومعرف المنتج وحده. في هذه الحالات ، بمجرد تدريب نموذجنا ، بعد إدخال كل مثال اختبار في نموذجنا ، يتم نسيانه على الفور. افترضنا أن الملاحظات المتتالية كانت مستقلة وبالتالي لم تكن هناك حاجة للتمسك بهذا السياق.

ولكن كيف نتعامل مع مقاطع الفيديو video snippets؟ في هذه الحالة ، قد يتكون كل مقطع snippet من عدد مختلف من الإطارات. وقد يكون تخميننا لما يحدث في كل إطار أقوى بكثير إذا أخذنا في الاعتبار الإطارات السابقة أو اللاحقة. الشيء نفسه ينطبق على اللغة. إحدى مشكلات التعلم العميق الشائعة هي الترجمة الآلية machine translation: مهمة استيعاب الجمل في بعض اللغات المصدر والتنبؤ بترجماتها بلغة أخرى.

تحدث هذه المشاكل أيضًا في الطب. قد نرغب في نموذج لمراقبة المرضى في وحدة العناية المركزة وإطلاق التنبيهات عندما يتجاوز خطر الوفاة خلال الـ 24 ساعة القادمة بعض العتبة. هنا، لن نتخلص من كل ما نعرفه عن تاريخ المريض كل ساعة ، ونقوم بالتنبؤات بناءً على أحدث القياسات فقط.

تعد هذه المشكلات من بين أكثر التطبيقات إثارة للتعلم الآلي وهي أمثلة على التعلم المتسلسل sequence learning. إنها تتطلب نموذجًا إما لاستيعاب تسلسلات من المدخلات أو لإصدار تسلسلات من المخرجات (أو كليهما). على وجه التحديد ، يأخذ التعلم من التسلسل إلى التسلسل sequence-to-sequence learning في الاعتبار المشكلات التي تتكون فيها المدخلات والمخرجات من متواليات متغيرة الطول. تشمل الأمثلة الترجمة الآلية ونسخ الكلام إلى نص speech-to-text transcription. في حين أنه من المستحيل مراعاة جميع أنواع تحويلات التسلسل ، فإن الحالات الخاصة التالية تستحق الذكر.

العلامات والتحليل Tagging and Parsing. يتضمن هذا التعليق على تسلسل نصي بالسمات. هنا ، تتم محاذاة المدخلات والمخرجات ، أي أنها من نفس العدد وتحدث بترتيب مطابق. على سبيل المثال ، في وضع العلامات على جزء من الكلام part-of-speech (PoS) tagging ، نقوم بتعليق توضيحي لكل كلمة في جملة مع الجزء المقابل من الكلام ، أي "اسم" أو "كائن مباشر". بدلاً من ذلك ، قد نرغب في معرفة مجموعات الكلمات المتجاورة التي تشير إلى كيانات محددة ، مثل الأشخاص أو الأماكن أو المؤسسات. في المثال الكرتوني البسيط أدناه، قد نرغب فقط في الإشارة ، لكل كلمة في الجملة ، إلى ما إذا كانت جزءًا من كيان مسمى (يُشار إليه باسم "Ent" tagged).

```
Tom has dinner in Washington with Sally
Ent  -    -    -     Ent       -    Ent
```

التعرف التلقائي على الكلام Automatic Speech Recognition. مع التعرف على الكلام ، يكون تسلسل الإدخال عبارة عن تسجيل صوتي لمكبر الصوت (الشكل 1.3.5)، والإخراج عبارة عن نسخة نصية لما قاله المتحدث. التحدي هو أن هناك العديد من الإطارات الصوتية (يتم أخذ عينات الصوت عادةً عند 8 كيلو هرتز أو 16 كيلو هرتز) من النص ، أي أنه لا يوجد تطابق 1: 1 بين الصوت والنص ، حيث قد تتوافق آلاف العينات مع كلمة منطوقة واحدة. هذه هي مشاكل التعلم من التسلسل إلى التسلسل ، حيث يكون الناتج أقصر بكثير من المدخلات.

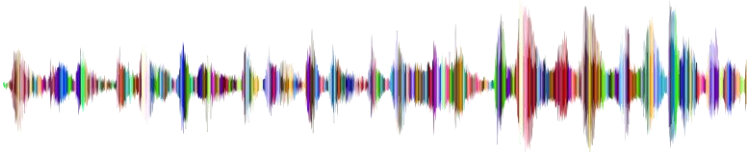

الشكل 1.3.5: D-e-e-p- L-ea-r-ni-ng ـ في تسجيل صوتي.

النص إلى الكلام Text to Speech. هذا هو عكس التعرف التلقائي على الكلام. هنا، الإدخال عبارة عن نص والمخرج عبارة عن ملف صوتي. في هذه الحالة ، يكون الإخراج أطول بكثير من الإدخال. في حين أن البشر بارعون بشكل ملحوظ في التعرف على الكلام ، حتى من الصوت منخفض الجودة ، فإن جعل أجهزة الكمبيوتر تؤدي هذا العمل الفذ يمثل تحديًا هائلاً.

الترجمة الآلية Machine Translation. على عكس حالة التعرف على الكلام ، حيث تحدث المدخلات والمخرجات المقابلة بنفس الترتيب ، في الترجمة الآلية ، تشكل البيانات غير المحاذاة تحديًا جديدًا. هنا يمكن أن يكون لتسلسل الإدخال والإخراج أطوال مختلفة ، وقد تظهر المناطق المقابلة من التسلسلات المعنية في أوامر مختلفة. تأمل المثال التوضيحي التالي للميل الغريب للألمان لوضع الأفعال في نهاية الجمل:

```
German:              Haben Sie sich schon dieses grossartige
Lehrwerk angeschaut?
English:             Did you already check out this excellent
tutorial?
Wrong alignment:  Did you yourself already this excellent
tutorial looked-at?
```

تظهر العديد من المشكلات ذات الصلة في مهام التعلم الأخرى. على سبيل المثال ، تحديد الترتيب الذي يقرأ به المستخدم صفحة ويب هو مشكلة تحليل تخطيط ثنائي الأبعاد Modern drowsiness detection in Deep Learning: a review. تعرض مشاكل الحوار جميع أنواع التعقيدات الإضافية ، حيث يتطلب تحديد ما سيقال بعد ذلك مراعاة معرفة العالم الحقيقي والحالة السابقة للمحادثة عبر مسافات زمنية طويلة. هذه هي مجالات البحث النشطة.

1.3.2. التعلم غير الخاضع للإشراف Unsupervised والإشراف الذاتي Self-Supervised

ركزت الأمثلة السابقة على التعلم الخاضع للإشراف supervised learning، حيث نقوم بتغذية النموذج بمجموعة بيانات عملاقة تحتوي على كل من الميزات وقيم التسمية المقابلة. يمكنك التفكير في أن المتعلم الخاضع للإشراف لديه وظيفة متخصصة للغاية ورئيس ديكتاتوري للغاية. يقف الرئيس فوق كتفه ويخبره بالضبط بما يجب القيام به في كل موقف حتى تتعلم التخطيط من المواقف إلى الإجراءات. يبدو أن العمل لدى مثل هذا الرئيس ضعيف جدًا. من ناحية أخرى ، فإن إرضاء مثل هذا الرئيس أمر سهل للغاية. أنت فقط تتعرف على النمط بأسرع ما يمكن وتقليد أفعالهم.

بالنظر إلى الموقف المعاكس ، قد يكون من المحبط العمل لدى رئيس ليس لديه فكرة عما يريدون منك القيام به. ومع ذلك ، إذا كنت تخطط لأن تكون عالم بيانات ، فمن الأفضل أن تعتاد عليها. قد يقوم المدير بتسليمك كمية هائلة من البيانات ويخبرك بالقيام ببعض علوم البيانات

باستخدامها! هذا يبدو غامضا لأنه كذلك. نحن نطلق على هذه الفئة من المشكلات اسم التعلم غير الخاضع للإشراف unsupervised learning، ونوع وعدد الأسئلة التي يمكن أن نطرحها يقتصر على إبداعنا فقط. سوف نتناول تقنيات التعلم غير الخاضعة للاشراف في فصول لاحقة. لإثارة شهيتك في الوقت الحالي ، نصف بعض الأسئلة التالية التي قد تطرحها.

- هل يمكننا العثور على عدد صغير من النماذج الأولية التي تلخص البيانات بدقة؟ بالنظر إلى مجموعة من الصور ، هل يمكننا تجميعها في صور مناظر طبيعية وصور للكلاب والرضع والقطط وقمم الجبال؟ وبالمثل ، في ضوء مجموعة من أنشطة تصفح المستخدمين، هل يمكننا تجميعها في مستخدمين لديهم سلوك مشابه؟ تُعرف هذه المشكلة عادةً باسم التجميع clustering.
- هل يمكننا العثور على عدد صغير من المعلمات التي تلتقط بدقة الخصائص ذات الصلة للبيانات؟ مسارات الكرة موصوفة جيدًا حسب سرعة الكرة وقطرها وكتلتها. لقد طور الخياطون عددًا صغيرًا من المعلمات التي تصف شكل جسم الإنسان بدقة إلى حد ما لغرض ملاءمة الملابس. يشار إلى هذه المشاكل باسم تقدير الفضاء الجزئي subspace estimation. إذا كان الاعتماد خطيًا linear، فإنه يسمى تحليل المكون الأساسي Principal Component Analysis(PCA).
- هل هناك تمثيل للكائنات (منظم بشكل تعسفي arbitrarily structured) في الفضاء الإقليدي بحيث يمكن مطابقة الخصائص الرمزية بشكل جيد؟ يمكن استخدام هذا لوصف الكيانات وعلاقاتها ، مثل "روما" - "إيطاليا" + "فرنسا" = "باريس".
- هل هناك وصف للأسباب الجذرية لكثير من البيانات التي نلاحظها؟ على سبيل المثال ، إذا كانت لدينا بيانات ديموغرافية حول أسعار المنازل والتلوث والجريمة والموقع والتعليم والرواتب ، فهل يمكننا اكتشاف كيفية ارتباطها بناءً على البيانات التجريبية empirical data؟ المجالات المعنية بالسببية causality والنماذج الرسومية الاحتمالية probabilistic graphical models تعالج مثل هذه الأسئلة.
- التطور الأخير المهم والمثير في التعلم غير الخاضع للإشراف هو ظهور النماذج التوليدية العميقة deep generative models. تقدر هذه النماذج كثافة البيانات، سواء بشكل صريح أو ضمني. بمجرد التدريب ، يمكننا استخدام نموذج توليدي إما لتسجيل الأمثلة وفقًا لمدى احتمالية وجودها ، أو لأخذ عينات من الأمثلة التركيبية من التوزيع المكتسب. جاءت اختراقات التعلم العميق المبكرة في النمذجة التوليدية مع اختراع المشفرات التلقائية المتنوعة variational autoencoders (Kingma and Welling، 2014) واستمرت في تطوير شبكات الخصومة

التوليدية generative adversarial networks (Goodfellow et al.، 2014). تشمل التطورات الحديثة تطبيع التدفقات normalizing flows ونماذج الانتشار diffusion models والنماذج القائمة على النقاط score-based models.

كان أحد التطورات الرئيسيةفي التعلم غير الخاضع للإشراف هو ظهور التعلم تحت الإشراف الذاتي self-supervised learning، وهي التقنيات التي تستفيد من بعض جوانب البيانات غير المصنفة لتوفير الإشراف. بالنسبة للنصوص، يمكننا تدريب النماذج على "ملء الفراغات fill in the blanks" من خلال التنبؤ بالكلمات المقنعة عشوائيًا باستخدام الكلمات المحيطة بها (السياقات contexts)في مجموعات كبيرة دون بذل أي جهدفي وضع العلامات (Devlin et al.، 2018)! بالنسبة للصور، قد نقوم بتدريب النماذج لإخبار الموضع النسبي بين منطقتين تم اقتصاصهما من نفس الصورة (Doersch et al.، 2015)، للتنبؤ بجزء مغلق من الصورة بناءً على الأجزاء المتبقية من الصورة، أو للتنبؤ بما إذا كان مثالان هما إصدارات مضطربة من نفس الصورة الأساسية. غالبًا ما تتعلم النماذج الخاضعة للإشراف الذاتي التمثيلات التي يتم الاستفادة منها لاحقًا عن طريق ضبط النماذج الناتجةفي بعض المهام النهائية ذات الأهمية.

1.3.3. التعامل مع البيئة Interacting with an Environment

حتى الآن، لم نناقش من أين تأتي البيانات فعليًا، أو ما يحدث بالفعل عندما يولد نموذج التعلم الآلي مخرجات. وذلك لأن التعلم تحت الإشراف والتعلم غير الخاضع للإشراف لا يعالجان هذه القضايا بطريقة معقدة للغاية.في كلتا الحالتين، نحصل على كومة كبيرة من البيانات مقدمًا، ثم نضع آلات التعرف على الأنماط الخاصة بنافي حالة حركة دون التفاعل مع البيئة مرة أخرى. نظرًا لأن التعلم كله يحدث بعد فصل الخوارزمية عن البيئة، يُسمى هذا أحيانًا التعلم الاوفلاين offline learning. على سبيل المثال، يفترض التعلم الخاضع للإشراف نمط التفاعل البسيط الموضحفي الشكل 1.3.6.

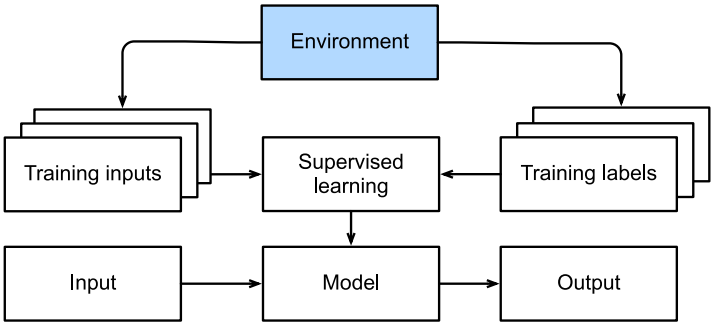

الشكل 1.3.6 جمع البيانات للتعلم الخاضع للإشراف من بيئة ما.

إن بساطة التعلم الاوفلاين له سحره. الجانب الإيجابي هو أنه يمكننا القلق بشأن التعرف على الأنماط بشكل منفصل ، دون القلق بشأن المضاعفات الناشئة عن التفاعلات مع بيئة ديناميكية. لكن صياغة هذه المشكلة محدودة. إذا نشأت في قراءة روايات روبوت Asimov ، فقد تتخيل عملاء ذكاء اصطناعيًا ليسوا فقط قادرين على التنبؤ ، ولكن أيضًا على اتخاذ الإجراءات في العالم. نريد أن نفكر في العوامل الذكية، وليس فقط النماذج التنبؤية. هذا يعني أننا بحاجة إلى التفكير في اختيار الإجراءات، وليس مجرد التنبؤ. على عكس مجرد التنبؤات ، تؤثر الإجراءات فعليًا على البيئة. إذا أردنا تدريب وكيل ذكي intelligent agent,، يجب أن نحسب الطريقة التي قد تؤثر بها أفعاله على الملاحظات المستقبلية للوكيل agent.

إن التفكير في التفاعل مع البيئة يفتح مجموعة كاملة من أسئلة النمذجة الجديدة. ما يلي مجرد أمثلة قليلة.

- هل تتذكر البيئة ما فعلناه سابقًا؟
- هل تريد البيئة مساعدتنا، على سبيل المثال، مستخدم يقرأ النص في أداة التعرف على الكلام؟
- هل تريد البيئة التغلب علينا، على سبيل المثال، تغيير مرسلي البريد الإلكتروني العشوائي لتفادي عوامل تصفية البريد العشوائي؟
- هل البيئة لديها ديناميات متغيرة؟ على سبيل المثال، هل تشبه البيانات المستقبلية الماضي دائمًا أم أن الأنماط تتغير بمرور الوقت، إما بشكل طبيعي أو استجابة لأدواتنا الآلية؟

تثير هذه الأسئلة مشكلة تحول التوزيع distribution shift، حيث تختلف بيانات التدريب والاختبار. لقد واجه معظمنا هذه المشكلة عند إجراء الاختبارات التي كتبها محاضر ، بينما كان الواجب المنزلي مؤلفًا من قبل مساعديهم التدريسيين. بعد ذلك ، نصف بإيجاز التعلم المعزز reinforcement learning، وهو إطار عمل ثري لطرح مشاكل التعلم التي يتفاعل فيها الوكيل مع البيئة.

1.3.4. التعلم المعزز Reinforcement Learning

إذا كنت مهتمًا باستخدام التعلم الآلي لتطوير عامل يتفاعل مع بيئة ويتخذ إجراءات، فمن المحتمل أن ينتهي بك الأمر بالتركيز على التعلم المعزز reinforcement learning. قد يشمل ذلك تطبيقات للروبوتات وأنظمة الحوار وحتى تطوير الذكاء الاصطناعي (AI) لألعاب الفيديو. لقد ازدادت شعبية التعلم المعزز العميق Deep reinforcement learning ، الذي يطبق التعلم العميق لمشاكل التعلم المعزز. إن شبكة Q-network العميقة التي تغلبت على البشر في ألعاب Atari باستخدام المدخلات المرئية فقط(Mnih et al.، 2015) ، وبرنامج

AlphaGo الذي فاز عالى بطل العالم في لعبة اللوحة Go (Silver et al.، 2016) هما مثالان بارزان.

يقدم التعلم المعزز بيانًا عامًا جدًا للمشكلة ، حيث يتفاعل الوكيل agent مع بيئة عبر سلسلة من الخطوات الزمنية time steps. في كل خطوة زمنية ، يتلقى الوكيل بعض الملاحظات observation من البيئة ويجب عليه اختيار إجراء action يتم نقله لاحقًا إلى البيئة عبر آلية ما (تسمى أحيانًا المشغل actuator). أخيرًا ، يتلقى الوكيل مكافأة reward من البيئة. هذه العملية موضحة في الشكل 1.3.7. ثم يتلقى الوكيل ملاحظة لاحقة subsequent observation، ويختار إجراءً لاحقًا ، وما إلى ذلك. يخضع سلوك عامل التعلم المعزز لسياسة policy. باختصار، السياسة هي مجرد دالة تقوم بالتخطيط من ملاحظات البيئة إلى الإجراءات. الهدف من التعلم المعزز هو إنتاج سياسات جيدة.

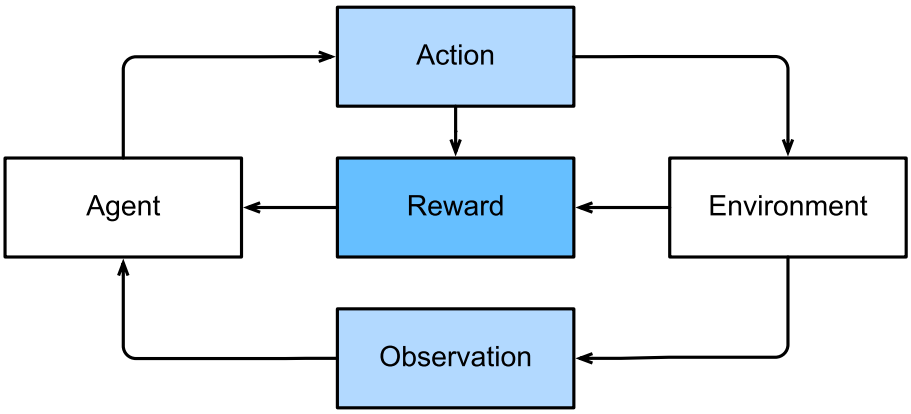

الشكل 1.3.7 التفاعل بين التعلم المعزز والبيئة.

من الصعب المبالغة في عمومية إطار التعلم المعزز. على سبيل المثال ، يمكننا أن نلقي بمشاكل التعلم الخاضع للإشراف على أنها مشاكل تعلم معزز. لنفترض أن لدينا مشكلة في التصنيف. يمكننا إنشاء عامل تعلم معزز بإجراء واحد يتوافق مع كل فئة. يمكننا بعد ذلك إنشاء بيئة تمنح مكافأة تساوي تمامًا دالة الخطأ من مشكلة التعلم الأصلية الخاضعة للإشراف.

ومع ذلك ، يمكن أن يعالج التعلم المعزز أيضًا العديد من المشكلات التي لا يستطيع التعلم الخاضع للإشراف القيام بها. على سبيل المثال ، في التعلم الخاضع للإشراف، نتوقع دائمًا أن تكون مدخلات التدريب مرتبطة بالتسمية الصحيحة. لكن في التعلم المعزز، لا نفترض أنه بالنسبة لكل ملاحظة تخبرنا البيئة بالعمل الأمثل. بشكل عام ، نحن فقط نحصل على بعض المكافآت. علاوة على ذلك ، قد لا تخبرنا البيئة حتى عن الإجراءات التي أدت إلى المكافأة.

تأمل في لعبة الشطرنج. تأتي إشارة المكافأة الحقيقية الوحيدة في نهاية اللعبة عندما نفوز ، ونكسب مكافأة ، على سبيل المثال، 1 ، أو عندما نخسر ، نحصل على مكافأة ، على سبيل المثال، 1-. لذا يجب على المتعلمين المعززين Reinforcement learners التعامل مع مشكلة تعيين الائتمان credit assignment problem: تحديد الإجراءات التي يجب إلقاء اللوم عليها في النتيجة. الشيء نفسه ينطبق على الموظف الذي حصل على ترقية في 11 أكتوبر. من المحتمل أن تعكس هذه الترقية عددًا كبيرًا من الإجراءات المختارة جيدًا خلال العام السابق. يتطلب الحصول على المزيد من الترقيات في المستقبل معرفة الإجراءات التي أدت إلى الترقية.

قد يضطر المتعلمون المعززون أيضًا إلى التعامل مع مشكلة الملاحظة الجزئية partial observability. أي أن الملاحظة الحالية قد لا تخبرك بكل شيء عن حالتك الحالية. لنفترض أن روبوت التنظيف وجد نفسه محاصرًا في واحدة من العديد من الخزانات المماثلة في المنزل. قد يتطلب استنتاج الموقع الدقيق للروبوت النظر في ملاحظاته السابقة قبل دخول الخزانة.

أخيرًا ، في أي نقطة معينة، قد يعرف متعلمو التعزيز سياسة جيدة واحدة ، ولكن قد يكون هناك العديد من السياسات الأفضل الأخرى التي لم يجربها الوكيل مطلقًا. يجب على متعلم التعزيز أن يختار باستمرار ما إذا كان سيستغل أفضل استراتيجية معروفة (حاليًا) كسياسة ، أو استكشاف مساحة الاستراتيجيات، مما قد يتخلى عن بعض المكافآت قصيرة المدى في مقابل المعرفة.

مشكلة التعلم المعزز العامة هي بيئة عامة للغاية very general setting. تؤثر الإجراءات على الملاحظات اللاحقة. يتم ملاحظة المكافآت فقط وفقًا للإجراءات المختارة. قد تتم ملاحظة البيئة بشكل كامل أو جزئي. قد يسأل الكثير من الباحثين عن تفسير كل هذا التعقيد دفعة واحدة. علاوة على ذلك، لا تظهر كل مشكلة عملية كل هذا التعقيد. نتيجة لذلك ، درس الباحثون عددًا من الحالات الخاصة لمشاكل التعلم المعزز.

عندما تتم ملاحظة البيئة بالكامل، فإننا نطلق على مشكلة التعلم المعزز عملية قرار ماركوف Markov decision process. عندما لا تعتمد الحالة على الإجراءات السابقة ، فإننا نطلق على المشكلة اسم مشكلة ~~قطاع الطرق السياقية~~ contextual bandit problem. عندما لا تكون هناك حالة ، فقط مجموعة من الإجراءات المتاحة مع مكافآت غير معروفة في البداية ، فإن هذه المشكلة هي مشكلة ماكينات الألعاب المتعددة الكلاسيكية classic multi-armed bandit problem.

1.4 الجذور Roots

لقد راجعنا للتو مجموعة فرعية صغيرة من المشكلات التي يمكن للتعلم الآلي معالجتها. بالنسبة لمجموعة متنوعة من مشكلات التعلم الآلي، يوفر التعلم العميق أدوات قوية لحلها. على

الرغم من أن العديد من أساليب التعلم العميق هي اختراعات حديثة ، فقد تمت دراسة الأفكار الأساسية وراء التعلم من البيانات لعدة قرون. في الواقع ،كان لدى البشر الرغبة في تحليل البيانات والتنبؤ بالنتائج المستقبلية لفترة طويلة والكثير من العلوم الطبيعية لها جذورها في ذلك. على سبيل المثال ، تمت تسمية توزيع برنولي Bernoulli distribution على اسم جاكوب برنولي (1705ـ1655)، واكتشف كارل فريدريش غاوس(1777ـ1855) التوزيع الغاوسي Gaussian distribution. اخترع، على سبيل المثال ، خوارزمية المربعات الأقل متوسطًا least mean squares algorithm ، والتي لا تزال تُستخدم حتى اليوم لمشاكل لا حصر لها من حسابات التأمين إلى التشخيص الطبي. أدت هذه الأدوات إلى ظهور نهج تجريبي في العلوم الطبيعية ـ على سبيل المثال ، قانون أوم المتعلق بالتيار والجهد في المقاوم موصوفًا تمامًا بواسطة نموذج خطي.

حتى في العصور الوسطى ،كان لدى علماء الرياضيات حدس شديد للتقديرات. على سبيل المثال ، يوضح كتاب الهندسة لجاكوب كوبيل (1460ـ1533) متوسط طول قدم الرجل البالغ 16 لتقدير متوسط طول القدم في السكان (الشكل 1.4.1).

شكل 1.4.1 تقدير طول القدم.

عندما خرجت مجموعة من الأفراد من الكنيسة ، طُلب من 16 رجلاً بالغًا الوقوف في صف واحد وقياس أقدامهم. ثم تم قسمة مجموع هذه القياسات على 16 للحصول على تقدير لما يصل الآن إلى قدم واحدة. تم تحسين هذه "الخوارزمية" فيما بعد للتعامل مع الأقدام المشوهة. تم طرد الرجلين ذوي أقصر وأطول أقدام ، بمتوسط أكثر من الباقي فقط. هذا من بين الأمثلة المبكرة لتقدير المتوسط المقطوع trimmed mean estimate.

لقد انطلقت الإحصائيات حقًا من خلال جمع البيانات وتوافرها. ساهم أحد روادها ، رونالد فيشر (1890ـ1962) ، بشكل كبير في نظريتها وتطبيقاتها أيضًا في علم الوراثة. لا تزال العديد من خوارزمياته (مثل تحليل التمايز الخطي linear discriminant analysis) والصيغ (مثل مصفوفة معلومات فيشر Fisher information matrix) تحتل مكانة بارزة في أسس الإحصاء الحديث. حتى موارد البيانات الخاصة به كان لها تأثير دائم. لا تزال مجموعة بيانات Iris التي أصدرها فيشر في عام 1936 مستخدمة أحيانًا لإثبات خوارزميات التعلم الآلي. كان فيشر أيضًا مؤيدًا لعلم تحسين النسل eugenics، والذي يجب أن يذكرنا بأن الاستخدام المشكوك فيه أخلاقياً لعلم البيانات له تاريخ طويل ودائم مثل استخدامه المنتج في الصناعة والعلوم الطبيعية.

جاء التأثير الثاني للتعلم الآلي من نظرية المعلومات لكلود شانون (1916ـ2001) ونظرية الحساب عبر آلان تورينج (1912ـ1954). طرح تورينج السؤال "هل يمكن للآلات أن تفكر؟" في مقالته الشهيرة Computing Machinery and Intelligence (Turing, 1950). في ما وصفه باختبار تورينج Turing test، يمكن اعتبار الآلة ذكية intelligent إذا كان من الصعب على المقيم البشري التمييز بين الردود من الآلة والإنسان بناءً على التفاعلات النصية.

يمكن العثور على تأثير آخر في علم الأعصاب neuroscience وعلم النفس psychology. بعد كل شيء، من الواضح أن البشر يظهرون سلوكًا ذكيًا. تساءل العديد من العلماء عما إذا كان بإمكان المرء تفسير هذه القدرة وربما عكسها. أحد أقدم الخوارزميات المستوحاة من الناحية البيولوجية صاغها دونالد هب (1904ـ1985). في كتابه الرائد تنظيم السلوك The Organization of Behavior (Hebb and Hebb، 1949) ، افترض أن الخلايا العصبية تتعلم من خلال التعزيز الإيجابي. أصبح هذا معروفًا باسم قاعدة التعلم Hebbian. هذه الأفكار المستوحاة من أعمال لاحقة مثل خوارزمية تعلم الإدراك الحسي لروزنبلات Rosenblatt's perceptron learning ووضعت الأسس للعديد من خوارزميات التدرج الاشتقاقي العشوائي التي تدعم التعلم العميق اليوم: تعزيز السلوك المرغوب وتقليل السلوك غير المرغوب فيه للحصول على إعدادات جيدة للمعلمات في الشبكة العصبية.

الإلهام البيولوجي Biological inspiration هو ما أعطى الشبكات العصبية اسمها. لأكثر من قرن (يعود تاريخها إلى نماذج ألكسندر باين ، 1873 وجيمس شيرينجتون ، 1890) ، حاول

الباحثون تجميع دوائر حسابية تشبه شبكات الخلايا العصبية المتفاعلة. بمرور الوقت ، أصبح تفسير علم الأحياء أقل حرفية ، لكن الاسم عالق. تكمن في جوهرها بعض المبادئ الأساسية التي يمكن العثور عليها في معظم الشبكات اليوم:

- غالبًا ما يشار إلى تبديل وحدات المعالجة الخطية وغير الخطية باسم الطبقات layers.
- استخدام قاعدة السلسلة chain rule (المعروفة أيضًا باسم backpropagation) لضبط المعلمات في الشبكة بأكملها مرة واحدة.

بعد التقدم السريع الأولي، ضعفت الأبحاث في الشبكات العصبية من حوالي عام 1995 حتى عام 2005. وهذا يرجع أساسًا إلى سببين. أولاً ، يعد تدريب شبكة ما مكلفًا للغاية من الناحية الحسابية. بينما كانت ذاكرة الوصول العشوائي وفيرة في نهاية القرن الماضي ، كانت القوة الحسابية نادرة. ثانيًا ، كانت مجموعات البيانات صغيرة نسبيًا. في الواقع ، كانت مجموعة بيانات Fisher's Iris من عام 1932 أداة شائعة لاختبار فاعلية الخوارزميات. اعتبرت مجموعة بيانات MNIST بأرقامها المكتوبة بخط اليد البالغ عددها 60000 ضخمة.

نظرًا لندرة البيانات والحسابات، أثبتت الأدوات الإحصائية القوية مثل طرق النواة kernel methods وأشجار القرار decision trees والنماذج الرسومية graphical models أنها متفوقة تجريبيًا في العديد من التطبيقات. علاوة على ذلك ، على عكس الشبكات العصبية neural networks ، لم يحتاجوا إلى أسابيع للتدريب وقدموا نتائج يمكن التنبؤ بها مع ضمانات نظرية قوية.

1.5 الطريق إلى التعلم العميق The Road to Deep Learning

تغير الكثير من هذا مع توفر كميات كبيرة من البيانات ، بسبب شبكة الويب العالمية ، وظهور الشركات التي تخدم مئات الملايين من المستخدمين عبر الإنترنت ، ونشر أجهزة استشعار رخيصة وعالية الجودة ، وتخزين بيانات رخيص (قانون Kryder) ، والحساب الرخيص (قانون Moore). على وجه الخصوص، تم إحداث ثورة في مشهد الحساب في التعلم العميق من خلال التقدم في وحدات معالجة الرسومات GPU، والتي تم تصميمها في الأصل لألعاب الكمبيوتر. فجأة ، أصبحت الخوارزميات والنماذج التي بدت غير مجدية من الناحية الحسابية ذات صلة (والعكس صحيح). هذا هو أفضل توضيح في القسم 1.5.

Decade	Dataset	Memory	Floating point calculations per second
1970	100 (Iris)	1 KB	100 KF (Intel 8080)
1980	1 K (house prices in Boston)	100 KB	1 MF (Intel 80186)
1990	10 K (optical character recognition)	10 MB	10 MF (Intel 80486)
2000	10 M (web pages)	100 MB	1 GF (Intel Core)
2010	10 G (advertising)	1 GB	1 TF (Nvidia C2050)
2020	1 T (social network)	100 GB	1 PF (Nvidia DGX-2)

الجدول: مجموعة البيانات مقابل ذاكرة الكمبيوتر والقدرة الحسابية

لاحظ أن ذاكرة الوصول العشوائي لم تواكب نمو البيانات.في الوقت نفسه، فاقت الزياداتفي القوة الحسابية النموفي مجموعات البيانات. هذا يعني أن النماذج الإحصائية تحتاج إلى أن تصبح أكثر كفاءةفي استخدام الذاكرة، وأن تكون حرةفي إنفاق المزيد من دورات الكمبيوتر لتحسين المعلمات، بسبب زيادة ميزانية الحساب. وبالتالي، انتقلت النقطة المثاليةفي التعلم الآلي والإحصاءات من النماذج الخطية (المعممة) وطرق النواة إلى الشبكات العصبية العميقة. هذا أيضًا أحد الأسباب التي تجعل العديد من الدعائم الأساسية للتعلم العميق، مثل البيرسيبترون متعدد الطبقات multilayer perceptron (McCulloch and Pitts، 1943)، والشبكات العصبية التلافيفية convolutional neural networks (.LeCun et al، 1998)، والذاكرة طويلة قصيرة المدى long short-term memory (Hochreiter and Schmidhuber, 1997)، و Q-Learning (Watkins and Dayan، 1992)، 1992(بشكل أساسي "أعيد اكتشافهما"في العقد الماضي ، بعد أن ظل خامدًا نسبيًا لفترة طويلة.

تم تشبيه التقدم الأخيرفي النماذج والتطبيقات والخوارزميات الإحصائيةفي بعض الأحيان بالانفجار الكمبري Cambrian explosion: لحظة تقدم سريعفي تطور الأنواع.في الواقع، ليست أحدث ما توصلت إليه التكنولوجيا مجرد نتيجة للموارد المتاحة، المطبقة على خوارزميات عمرها عقود. لاحظ أن القائمة أدناه بالكاد تخدش سطح الأفكار التي ساعدت الباحثين على تحقيق تقدم هائل خلال العقد الماضي.

- ساعدت الأساليب الجديدة للتحكمفي السعة، مثل الحذف العشوائي dropout (Srivastava et al.، 2014)في التخفيف من فرط التعلم overfitting. هنا، يتم حقن الضوضاء (Bishop، 1995)في جميع أنحاء الشبكة العصبية أثناء التدريب.
- حلت آليات الانتباه Attention mechanisms مشكلة ثانية ابتليت بها الإحصائيات لأكثر من قرن: كيفية زيادة الذاكرة وتعقيد النظام دون زيادة عدد

المعلمات القابلة للتعلم. وجد الباحثون حلاً أنيقًا باستخدام ما يمكن اعتباره هيكل مؤشر قابل للتعلم learnable pointer structure (Bahdanau et al.، 2014). بدلاً من الاضطرار إلى تذكر تسلسل نصي كامل، على سبيل المثال، للترجمة الآليةفي تمثيل ثابت الأبعاد، كان كل ما يلزم تخزينه هو مؤشر إلى الحالة الوسيطة لعملية الترجمة. سمح ذلك بزيادة الدقة بشكل كبير للتسلسلات الطويلة، حيث لم يعد النموذج بحاجة إلى تذكر التسلسل بالكامل قبل البدءفي إنشاء تسلسل جديد. مبنية فقط على آليات الانتباه، أظهرت بنية المحولات transformer (Vaswani et al.، 2017) نجاحًا مقنعًافي مجموعة واسعة من المجالات. على سبيل المثال، يمكن لمحول واحد تم اختباره مسبقًا على طرائق متنوعة مثل النصوص والصور وعزم الدوران joint torques المشتركة والضغط على الأزرار تشغيل Atari والصور التوضيحية والدردشة والتحكمفي الروبوت (Reed et al.، 2022).

- سمحت التصاميم متعددة المراحل Multi-stage designs ، على سبيل المثال، عبر شبكات الذاكرة (Sukhbaatar et al.، 2015) والمبرمج العصبي – المترجم neural programmer-interpreter (Reed and De Freitas، 2015) للمصممين الإحصائيين لوصف الأساليب التكرارية للاستدلال. تسمح هذه الأدوات بتعديل الحالة الداخلية للشبكة العصبية العميقة بشكل متكرر، وبالتالي تنفيذ خطوات لاحقةفي سلسلة من التفكير، على غرار الطريقة التي يمكن بها للمعالج تعديل الذاكرة لإجراء عملية حسابية.
- تطور رئيسي آخر كان اختراع شبكات الخصومة التوليدية Generative Adversarial Networks(GAN) (Goodfellow et al.، 2014). تقليديا، ركزت الطرق الإحصائية لتقدير الكثافة والنماذج التوليدية على إيجاد توزيعات احتمالية مناسبة وخوارزميات (تقريبية غالبًا) لأخذ العينات منها. نتيجة لذلك، كانت هذه الخوارزميات محدودة إلى حد كبير بسبب الافتقار إلى المرونة الكامنةفي النماذج الإحصائية. كان الابتكار الحاسمفي شبكات الخصومة التوليدية هو استبدال جهاز أخذ العينات بخوارزمية تعسفية بمعلمات قابلة للتفاضل. ثم يتم تعديلها بطريقة تجعل المميز discriminator (اختبار من عينتين فعليًا) لا يستطيع التمييز بين البيانات المزيفة والحقيقية. من خلال القدرة على استخدام الخوارزميات التعسفية لتوليد البيانات، فقد فتح تقدير الكثافة لمجموعة متنوعة من التقنيات. أمثلة على ركض الحمر الوحشية galloping Zebras (Zhu et al.، 2017) ووجوه المشاهير المزيفة (Karras et al.، 2017) دليل على هذا التقدم. يمكن حتى لرسامي رسومات الشعار المبتكرة الهواة إنتاج صور واقعية استنادًا إلى

الرسومات التخطيطية فقط التي تصف كيف يبدو تخطيط المشهد (Park et al.، 2019).

- في كثير من الحالات، لا تكفي وحدة معالجة الرسومات الواحدة لمعالجة الكميات الكبيرة من البيانات المتاحة للتدريب. على مدى العقد الماضي، تحسنت القدرة على بناء خوارزميات تدريب متوازية وموزعة بشكل كبير. أحد التحديات الرئيسية في تصميم خوارزميات قابلة للتطوير هو أن العمود الفقري لتحسين التعلم العميق، التدرج الاشتقاقي العشوائي stochastic gradient descent، يعتمد على دفعات صغيرة minibatches نسبيًا من البيانات المراد معالجتها.في الوقت نفسه، تحد الدفعات الصغيرة من كفاءة وحدات معالجة الرسومات. وبالتالي، فإن التدريب على 1024 وحدة معالجة رسومات بحجم صغير يبلغ 32 صورة على سبيل المثال لكل دفعة يصل إلى مجموعة مصغرة مجمعة من حوالي 32000 صورة. العمل الأخير، أولاً بواسطة Li (2017)، وبعد ذلك بواسطة You et al. (2017) و Jia et al.. (2018) دفع الحجم إلى 64000 ملاحظة، مما قلل من وقت التدريب لنموذج ResNet-50 على مجموعة بيانات ImageNet إلى أقل من 7 دقائق. للمقارنة ـ تم قياس أوقات التدريبفي البداية بترتيب الأيام.
- ساهمت القدرة على موازاة الحساب أيضًا في التقدم في التعلم المعزز ، وقد أدى ذلك إلى تقدم كبير في أجهزة الكمبيوتر التي تحقق أداءً خارقًا في مهام مثل Go ، وألعاب Atari ، و Starcraft ، وفي محاكاة الفيزياء (على سبيل المثال ، باستخدام MuJoCo)، حيث توجد محاكيات البيئة متوفرة. انظر ، على سبيل المثال ،(Silver et al. 2016) للحصول على وصف لكيفية تحقيق ذلك في AlphaGo. باختصار ، يعمل التعلم المعزز بشكل أفضل إذا توفر الكثير من مجموعات (الحالة state، الإجراء action ، المكافأة reward). المحاكاة توفر مثل هذا الطريق.
- لعبت أطر التعلم العميق دورًا مهمًا في نشر الأفكار. يتكون الجيل الأول من الأطر مفتوحة المصدر لنمذجة الشبكة العصبية من Caffe و Torch و Theano. تمت كتابة العديد من الأوراق الأساسية باستخدام هذه الأدوات. حتى الآن ، حلت محلها TensorFlow (غالبًا ما تستخدم عبر API Keras عالي المستوى) و CNTK و Caffe 2 و Apache MXNet. يتكون الجيل الثالث من الأدوات مما يسمى بالأدوات الإلزامية imperative tools للتعلم العميق ، وهو اتجاه أشعله تشينر على الأرجح، والذي استخدم صيغة مشابهة لـ Python NumPy لوصف النماذج. تم تبني هذه الفكرة من قبل كل من PyTorch و Gluon API من MXNet و Jax.

أدى تقسيم العمل بين الباحثين في النظام الذين يبنون أدوات أفضل والمصممين الإحصائيين لبناء شبكات عصبية أفضل إلى تبسيط الأمور إلى حد كبير. على سبيل المثال ، كان تدريب نموذج الانحدار اللوجستي الخطي linear logistic regression يمثل مشكلة واجبات منزلية غير بديهية ، تستحق أن تمنح لطلاب دكتوراه التعلم الآلي الجدد في جامعة كارنيجي ميلون في 2014. حتى الآن ، يمكن إنجاز هذه المهمة بأقل من 10 أسطر من التعليمات البرمجية ، مما يضعها بقوة في متناول المبرمجين.

1.6 قصص نجاح Success Stories

للذكاء الاصطناعي تاريخ طويل في تقديم النتائج التي يصعب تحقيقها بخلاف ذلك. على سبيل المثال ، تم نشر أنظمة فرز البريد باستخدام التعرف الضوئي على الأحرف منذ التسعينيات. هذا ، بعد كل شيء ، مصدر مجموعة بيانات MNIST الشهيرة للأرقام المكتوبة بخط اليد. الأمر نفسه ينطبق على قراءة الشيكات للودائع المصرفية وتسجيل الجدارة الائتمانية لمقدمي الطلبات. يتم فحص المعاملات المالية تلقائيًا بحثًا عن الاحتيال. يشكل هذا العمود الفقري للعديد من أنظمة الدفع للتجارة الإلكترونية ، مثل PayPal و Stripe و AliPay و WeChat و Apple و Visa و MasterCard. كانت برامج الكمبيوتر للشطرنج تنافسية منذ عقود. يغذي التعلم الآلي البحث والتوصية والتخصيص والترتيب على الإنترنت. بمعنى آخر ، التعلم الآلي منتشر ، وإن كان غالبًا ما يكون مخفيًا عن الأنظار.

في الآونة الأخيرة فقط، أصبح الذكاء الاصطناعي في دائرة الضوء ، ويرجع ذلك في الغالب إلى حلول المشكلات التي كانت تعتبر مستعصية في السابق والتي تتعلق مباشرة بالمستهلكين. يُعزى العديد من هذه التطورات إلى التعلم العميق.

- يمكن للمساعدين الرقميين الأذكياء ، مثل Siri من Apple و Alexa من Amazon ومساعد Google ، الإجابة على الأسئلة المنطوقة بدرجة معقولة من الدقة. يتضمن ذلك المهام البسيطة، مثل تشغيل مفاتيح الإضاءة ، والمهام الأكثر تعقيداً، مثل ترتيب مواعيد الحلاق وتقديم مربع حوار الدعم عبر الهاتف. من المحتمل أن تكون هذه هي العلامة الأكثر وضوحًا على أن الذكاء الاصطناعي يؤثر على حياتنا.
- أحد المكونات الرئيسية في المساعدين الرقميين هو القدرة على التعرف على الكلام بدقة. تدريجيًا، زادت دقة هذه الأنظمة إلى حد تحقيق التكافؤ البشري لبعض التطبيقات (Xiong et al.، 2018).
- كما قطع التعرف على الأشياء Object recognition شوطًا طويلاً. كان تقدير الكائن في صورة مهمة صعبة إلى حد ما في عام 2010. حقق باحثو معيار

ImageNet من NEC Labs وجامعة إلينوي في Urbana-Champaign معدل خطأ أعلى 5 بنسبة 28٪ (Lin et al.، 2010). بحلول عام 2017 ، انخفض معدل الخطأ هذا إلى 2.25٪ (Hu et al.، 2018). وبالمثل ، تم تحقيق نتائج مذهلة في التعرف على الطيور وتشخيص سرطان الجلد.

- تُستخدم البراعة Prowess في الألعاب لتوفير عصا قياس للذكاء البشري. بدءًا من TD-Gammon ، أدى برنامج لعب الطاولة باستخدام التعلم المعزز للفرق الزمني والتقدم الحسابي والخوارزمي إلى خوارزميات لمجموعة واسعة من التطبيقات. على عكس لعبة الطاولة backgammon، فإن لعبة الشطرنج بها مساحة أكثر تعقيدًا ومجموعة من الإجراءات. تغلب DeepBlue على Garry Kasparov باستخدام التوازي الهائل massive parallelism والأجهزة ذات الأغراض الخاصة والبحث الفعال من خلال شجرة اللعبة (Campbell et al.، 2002). لا يزال Go أكثر صعوبة ، بسبب مساحة الحالة الضخمة. وصل AlphaGo إلى التكافؤ البشري في عام 2015 ، باستخدام التعلم العميق جنبًا إلى جنب مع أخذ عينات شجرة مونت كارلو (Silver et al.، 2016). كان التحدي في لعبة البوكر هو أن مساحة الحالة كبيرة ولا يتم ملاحظتها إلا جزئيًا (لا نعرف بطاقات الخصم). تجاوز Libratus الأداء البشري في البوكر باستخدام استراتيجيات منظمة بكفاءة (Brown and Sandholm، 2017).
- مؤشر آخر على التقدم في الذكاء الاصطناعي هو ظهور السيارات والشاحنات ذاتية القيادة self-driving cars and trucks. في حين أن الاستقلالية الكاملة ليست في متناول اليد تمامًا ، فقد تم إحراز تقدم ممتاز في هذا الاتجاه ، مع منتجات شحن مثل Tesla و NVIDIA و Waymo التي تتيح الاستقلال الذاتي الجزئي على الأقل. ما يجعل الاستقلالية الكاملة صعبة للغاية هو أن القيادة المناسبة تتطلب القدرة على الإدراك والتفكير ودمج القواعد في النظام. في الوقت الحاضر ، يتم استخدام التعلم العميق بشكل أساسي في جانب رؤية الكمبيوتر لهذه المشاكل. يتم ضبط الباقي بشكل كبير من قبل المهندسين.

هذا بالكاد يخدش السطح للتطبيقات المؤثرة للتعلم الآلي. على سبيل المثال ، تدين الروبوتات واللوجستيات وعلم الأحياء الحسابي وفيزياء الجسيمات وعلم الفلك ببعض التطورات الحديثة الأكثر إثارة للإعجاب على الأقل في أجزاء من التعلم الآلي. وهكذا أصبح التعلم الآلي أداة منتشرة في كل مكان للمهندسين والعلماء.

في كثير من الأحيان ، أثيرت أسئلة حول نهاية العالم القادمة للذكاء الاصطناعي ومعقولية التفرد في مقالات غير تقنية عن الذكاء الاصطناعي. الخوف هو أن أنظمة التعلم الآلي ستصبح

بطريقة ما واعية وتتخذ القرارات ، بشكل مستقل عن مبرمجيها الذين يؤثرون بشكل مباشر على حياة البشر. إلى حد ما ، يؤثر الذكاء الاصطناعي بالفعل على سبل عيش البشر بطرق مباشرة: يتم تقييم الجدارة الائتمانية تلقائيًا ، ويتنقل الطيارون الآليون في الغالب في المركبات ، واتخاذ قرارات بشأن منح بيانات إحصائية لاستخدام الكفالة كمدخلات. بشكل تافه ، يمكننا أن نطلب من Alexa تشغيل آلة القهوة.

لحسن الحظ ، نحن بعيدون عن نظام ذكاء اصطناعي واعي sentient AI system يمكنه التلاعب عمدا بمنشئيه البشريين. أولاً ، يتم تصميم أنظمة الذكاء الاصطناعي وتدريبها ونشرها بطريقة محددة وموجهة نحو الهدف. في حين أن سلوكهم قد يعطي وهم الذكاء العام ، إلا أنه مزيج من القواعد والاستدلال والنماذج الإحصائية التي تكمن وراء التصميم. ثانيًا ، في الوقت الحالي، لا توجد أدوات للذكاء العام الاصطناعي قادرة على تحسين نفسها ، والتفكير حول نفسها، والقادرة على تعديل بنيتها الخاصة وتوسيعها وتحسينها أثناء محاولة حل المهام العامة.

من أكثر الأمور إلحاحًا كيفية استخدام الذكاء الاصطناعي في حياتنا اليومية. من المحتمل أن تتم أتمتة العديد من المهام الوضيعة التي ينجزها سائقي الشاحنات ومساعدو المتاجر. من المحتمل أن تقلل روبوتات المزرعة من تكلفة الزراعة العضوية ولكنها ستعمل أيضًا على أتمتة عمليات الحصاد. قد يكون لهذه المرحلة من الثورة الصناعية عواقب وخيمة على قطاعات واسعة من المجتمع، حيث أن سائقي الشاحنات ومساعدي المتاجر هم من أكثر الوظائف شيوعًا في العديد من البلدان. علاوة على ذلك ، يمكن أن تؤدي النماذج الإحصائية، عند تطبيقها دون عناية، إلى تحيز عرقي أو جنساني أو عمري وتثير مخاوف معقولة بشأن الإنصاف الإجرائي إذا كانت مؤتمتة لقيادة القرارات اللاحقة. من المهم التأكد من استخدام هذه الخوارزميات بعناية. مع ما نعرفه اليوم ، فإن هذا يثير قلقنا أكثر إلحاحًا من قدرة الذكاء الخارق الخبيث على تدمير البشرية.

1.7 جوهر التعلم العميق The Essence of Deep Learning

حتى الآن ، تحدثنا عن التعلم الآلي على نطاق واسع. التعلم العميق هو مجموعة فرعية من التعلم الآلي تهتم بالنماذج القائمة على الشبكات العصبية متعددة الطبقات. إنه عميق deep بمعنى أن نماذجها تتعلم طبقات layers كثيرة من التحولات. في حين أن هذا قد يبدو ضيقًا ، فقد أدى التعلم العميق إلى ظهور مجموعة مذهلة من النماذج والتقنيات وصياغات المشكلات والتطبيقات. تم تطوير العديد من الحدس لشرح فوائد العمق. يمكن القول أن التعلم الآلي يحتوي على العديد من طبقات الحساب، تتكون الأولى من خطوات معالجة الميزات. ما يميز التعلم العميق هو أن العمليات التي تم تعلمها في كل طبقة من طبقات التمثيلات العديدة يتم تعلمها بشكل مشترك من البيانات.

المشاكل التي ناقشناها حتى الآن، مثل التعلم من إشارة الصوت الخام ، أو قيم البكسل الأولية للصور، أو التعيين بين الجمل ذات الأطوال التعسفية ونظيراتها في اللغات الأجنبية ، هي تلك التي يتفوق فيها التعلم العميق وتعثر الأساليب التقليدية. اتضح أن هذه النماذج متعددة الطبقات قادرة على معالجة البيانات الإدراكية منخفضة المستوى low-level perceptual data بطريقة لم تستطع الأدوات السابقة القيام بها. يمكن القول إن أهم عامل مشترك في أساليب التعلم العميق هو التدريب الشامل end-to-end training. بمعنى ، بدلاً من تجميع نظام يعتمد على المكونات التي يتم ضبطها بشكل فردي، يقوم المرء ببناء النظام ثم ضبط أدائه بشكل مشترك. على سبيل المثال، استخدم العلماء في رؤية الكمبيوتر لفصل عملية هندسة الميزات feature engineering عن عملية بناء نماذج التعلم الآلي. ساد كاشف الحواف Canny (Canny، 1987) ومستخرج ميزة SIFT من Lowe(Lowe، 2004) لأكثر من عقد من الزمن كخوارزميات لتعيين الصور في متجهات الميزات feature vectors. في الأيام الخوالي ، كان الجزء الأساسي من تطبيق التعلم الآلي على هذه المشكلات يتألف من التوصل إلى طرق مصممة يدويًا لتحويل البيانات إلى شكل قابل للنماذج الضحلة shallow models. لسوء الحظ ، لا يوجد سوى القليل جدًا الذي يمكن للبشر تحقيقه بالبراعة مقارنةً بالتقييم المتسق لملايين الخيارات التي يتم تنفيذها تلقائيًا بواسطة خوارزمية. عندما تولى التعلم العميق زمام الأمور ، تم استبدال مستخلصات الميزات feature extractors هذه بفلاتر تم ضبطها تلقائيًا automatically tuned filters، مما أدى إلى الحصول على دقة فائقة.

وبالتالي ، فإن إحدى الميزات الرئيسية للتعلم العميق هي أنه لا يستبدل النماذج الضحلة في نهاية خطوط التعلم التقليدية فحسب، بل يستبدل أيضًا عملية هندسة الميزات كثيفة العمالة labor-intensive. علاوة على ذلك ، من خلال استبدال الكثير من المعالجة المسبقة الخاصة بالمجال، أزال التعلم العميق العديد من الحدود التي كانت تفصل سابقًا بين الرؤية الحاسوبية ، والتعرف على الكلام ، ومعالجة اللغة الطبيعية ، والمعلوماتية الطبية ، ومجالات التطبيق الأخرى، مما يوفر مجموعة موحدة من الأدوات لمعالجة مشاكل متنوعة.

إلى جانب التدريب الشامل end-to-end training، نشهد انتقالًا من الأوصاف الإحصائية البارامترية parametric إلى النماذج اللابارامترية nonparametric بالكامل. عندما تكون البيانات شحيحة، يحتاج المرء إلى الاعتماد على افتراضات مبسطة حول الواقع من أجل الحصول على نماذج مفيدة. عندما تكون البيانات وفيرة ، يمكن استبدالها بنماذج غير بارامترية تناسب البيانات بشكل أفضل. إلى حد ما، يعكس هذا التقدم الذي شهدته الفيزياء في منتصف القرن الماضي مع توافر أجهزة الكمبيوتر. بدلاً من حل التقريبات البارامترية لكيفية تصرف الإلكترونات يدويًا ، يمكن للمرء الآن اللجوء إلى المحاكاة العددية للمعادلات التفاضلية الجزئية المرتبطة بها. وقد أدى ذلك إلى نماذج أكثر دقة ، وإن كان ذلك في كثير من الأحيان على حساب قابلية الشرح.

هناك اختلاف آخر عن العمل السابق وهو قبول الحلول دون المثالية suboptimal ، والتعامل مع مشاكل التحسين غير الخطية غير المحدبة nonconvex nonlinear optimization ، والاستعداد لتجربة الأشياء قبل إثباتها. أدت هذه التجريبية empiricism المكتشفة حديثًا في التعامل مع المشكلات الإحصائية ، جنبًا إلى جنب مع التدفق السريع للمواهب إلى تقدم سريع في الخوارزميات العملية ، وإن كان ذلك في كثير من الحالات على حساب تعديل وإعادة اختراع الأدوات التي كانت موجودة منذ عقود.

في النهاية، يفخر مجتمع التعلم العميق بنفسه لمشاركة الأدوات عبر الحدود الأكاديمية والشركات، وإطلاق العديد من المكتبات الممتازة، والنماذج الإحصائية ، والشبكات المدربة كمصدر مفتوح. وبهذه الروح ، فإن النوتبوك notebooks التي تشكل هذا الكتاب متاحة مجانًا للتوزيع والاستخدام. لقد عملنا بجد لخفض حواجز الوصول للجميع للتعرف على التعلم العميق ونأمل أن يستفيد قرائنا من ذلك.

1.8 الملخص

يدرس التعلم الآلي كيف يمكن لأنظمة الكمبيوتر الاستفادة من الخبرة (غالبًا البيانات) لتحسين الأداء في مهام محددة. فهو يجمع بين الأفكار من الإحصائيات ، واستخراج البيانات ، والتحسين. في كثير من الأحيان ، يتم استخدامه كوسيلة لتنفيذ حلول الذكاء الاصطناعي. بصفته فئة من فئات التعلم الآلي ، يركز التعلم التمثيلي representational learning على كيفية العثور تلقائيًا على الطريقة المناسبة لتمثيل البيانات. نظرًا لأن التعلم التمثيلي متعدد المستويات من خلال تعلم العديد من طبقات التحولات، فإن التعلم العميق لا يحل محل النماذج الضحلة في نهاية خطوط أنابيب التعلم الآلي التقليدية فحسب، بل يستبدل أيضًا عملية هندسة الميزات كثيفة العمالة. تم إطلاق الكثير من التقدم الأخير في التعلم العميق من خلال وفرة البيانات الناشئة عن أجهزة الاستشعار الرخيصة والتطبيقات على نطاق الإنترنت، والتقدم الكبير في الحساب ، في الغالب من خلال وحدات معالجة الرسومات. إلى جانب ذلك ، فإن توافر أطر عمل التعلم العميق الفعالة قد جعل تصميم وتنفيذ تحسين النظام بالكامل أسهل بشكل كبير ، وهو عنصر أساسي في الحصول على أداء عالٍ.

1.9 التمارين

1. أي أجزاء من التعليمات البرمجية التي تكتبها حاليًا يمكن "تعلمها" ، أي تحسينها بالتعلم وتحديد خيارات التصميم تلقائيًا التي يتم إجراؤها في التعليمات البرمجية الخاصة بك؟ هل تتضمن التعليمات البرمجية الخاصة بك خيارات تصميم إرشادية؟ ما هي البيانات التي قد تحتاجها لتعلم السلوك المطلوب؟

2. ما هي المشاكل التي تواجهها والتي لديها العديد من الأمثلة على كيفية حلها ، ولكن لا توجد طريقة محددة لأتمتتها؟ قد يكون هؤلاء مرشحين رئيسيين لاستخدام التعلم العميق.
3. وصف العلاقات بين الخوارزميات والبيانات والحساب. كيف تؤثر خصائص البيانات والموارد الحسابية الحالية المتاحة على ملاءمة الخوارزميات المختلفة؟
4. قم بتسمية بعض الإعدادات حيث لا يكون التدريب الشامل end-to-end training هو الأسلوب الافتراضي حاليًا ولكنه قد يكون كذلك.

2

الآليات

2. الاساسيات Preliminaries

للتحضير للغوص (للتعمق)في التعلم العميق ، ستحتاج إلى بعض مهارات البقاء: (1) تقنيات تخزين البيانات ومعالجتها ؛ (2) مكتبات لاستيعاب ومعالجة البيانات من مجموعة متنوعة من المصادر؛ (3) معرفة العمليات الجبرية الخطية الأساسية التي نطبقها على عناصر البيانات عالية الأبعاد ؛ (4) ما يكفي من حساب التفاضل والتكامل لتحديد الاتجاه الذي يضبط كل معلمة لتقليل دالة الخطأ ؛ (5) القدرة على حساب المشتقات تلقائيًا بحيث يمكنك نسيان الكثير من حسابات التفاضل والتكامل التي تعلمتها للتو ؛ (6) بعض الطلاقة الأساسيةفي الاحتمالية ، لغتنا الأساسية للاستدلالفي ظل عدم اليقين ؛ و (7) بعض القدرة على العثور على إجاباتفي الوثائق الرسمية عندما تتعثر.

باختصار، يوفر هذا الفصل مقدمة سريعة للأساسيات التي ستحتاجها لمتابعة معظم المحتوى الفنيفي هذا الكتاب.

2.1. معالجة البيانات Data Manipulation

من أجل إنجاز أي شيء، نحتاج إلى طريقة ما لتخزين البيانات ومعالجتها. بشكل عام، هناك شيئان مهمان نحتاج إلى القيام بهما بالبيانات: (1) الحصول عليها؛ و (2) معالجتها بمجرد دخولها إلى الكمبيوتر. لا جدوى من الحصول على البيانات دون طريقة ما لتخزينها، لذا فلنبدأ، دعنا نتسخ أيدينا باستخدام المصفوفات ذات الأبعاد $n-dimensional\ arrays$، والتي نسميها أيضًا الموترات tensors. إذا كنت تعرف بالفعل حزمة الحوسبة العلمية NumPy، فسيكون هذا أمرًا سهلاً. بالنسبة لجميع أطر التعلم العميق الحديثة، فإن فئة الموتر (ndarrayفي MXNet و Tensorفي PyTorch و TensorFlow) تشبه ndarray من NumPy، مع إضافة بعض الميزات القاتلة. أولاً، تدعم فئة الموتر التمايز التلقائي. ثانيًا، يستفيد من وحدات معالجة الرسومات GPU لتسريع الحساب العددي، بينما يعمل NumPy فقط على وحدات المعالجة المركزية (CPU). تجعل هذه الخصائص الشبكات العصبية سهلة البرمجة وسريعة التشغيل.

2.1.1. البداية

للبدء، نستورد Tensorflow. للإيجاز، غالبًا ما يقوم الممارسون بتعيين الاسم المستعار `tf`.

```
import tensorflow as tf
```

يمثل الموتر مجموعة (ربما متعددة الأبعاد) من القيم العددية. مع محور واحد، يسمى موتر متجه vector. مع محورين، يسمى الموتر مصفوفة matrix. باستخدام المحاور $k > 2$ ، نسقط الأسماء المتخصصة ونشير فقط إلى الكائن باعتباره موتر ترتيب ($k^{\text{th}} - \text{order tensor}$).

يوفر TensorFlow مجموعة متنوعة من الدوال لإنشاء موترات جديدة معبأة مسبقًا بالقيم. على سبيل المثال، من خلال استدعاء النطاق (n)، يمكننا إنشاء متجه لقيم متباعدة بشكل متساوٍ، بدءًا من 0 (مضمّن) وينتهي عند n (غير مضمن). بشكل افتراضي، يكون حجم الفاصل الزمني هو 1. ما لم يتم تحديد خلاف ذلك، يتم تخزين الموترات الجديدةفي الذاكرة الرئيسية وتخصيصها للحسابات المعتمدة على وحدة المعالجة المركزية CPU.

```
x = tf.range(12, dtype=tf.float32)
x
```

```
<tf.Tensor: shape=(12,), dtype=float32, numpy=
array([ 0.,  1.,  2.,  3.,  4.,  5.,  6.,  7.,  8.,  9.,
10., 11.],
      dtype=float32)>
```

كل من هذه القيم تسمى عنصر من موتر element of the tensor. يحتوي الموتر x على 12 عنصرًا. يمكننا فحص العدد الإجمالي للعناصرفي موتر عبر دالة الحجم.

```
tf.size(x)
```

يمكننا الوصول إلى شكل الموتر tensor's shape (الطول على طول كل محور) من خلال فحص سمة الشكل الخاصة به. نظرًا لأننا نتعامل مع متجه هنا، فإن الشكل shape يحتوي على عنصر واحد فقط وهو مطابق للحجم.

```
x.shape
```

```
TensorShape([12])
```

يمكننا تغيير شكل الموتر دون تغيير حجمه أو قيمه، عن طريق استدعاء إعادة الشكل reshape. على سبيل المثال، يمكننا تحويل المتجه x الذي شكله (12,) إلى مصفوفة X بالشكل (3, 4). يحتفظ هذا الموتر الجديد بجميع العناصر ولكنه يعيد تكوينهافي مصفوفة. لاحظ أن عناصر المتجه الخاصة بنا يتم وضعهافي صف واحدفي كل مرة وبالتالي x[3] == X[0, 3].

```
X = tf.reshape(x, (3, 4))
X
```

```
<tf.Tensor: shape=(3, 4), dtype=float32, numpy=
array([[ 0.,  1.,  2.,  3.],
       [ 4.,  5.,  6.,  7.],
       [ 8.,  9., 10., 11.]], dtype=float32)>
```

لاحظ أن تحديد كل مكون من مكونات الشكل لإعادة تشكيله reshape أمر زائد. نظرًا لأننا نعرف بالفعل حجم الموتر الخاص بنا، فيمكننا إيجاد مكون واحد من الشكل بالنظر إلى الباقي. على سبيل المثال، بالنظر إلى موتر الحجم n والشكل المستهدف $(h، w)$، فإننا نعرف $w = n/h$. لاستنتاج مكون واحد للشكل تلقائيًا، يمكننا وضع -1 لمكون الشكل الذي يجب استنتاجه

تلقائيًا.في حالتنا، بدلاً من استدعاء `x.reshape(3, 4)`، كان بإمكاننا استدعاء `x.reshape(-1, 4)` أو `x.reshape(3, -1)`.

غالبًا ما يحتاج الممارسون إلى العمل مع الموترات المهيأة لاحتواء جميع الأصفار أو الآحاد. يمكننا بناء موتر مع ضبط جميع العناصر على الصفر وشكل (2, 3, 4) عبر دالة الأصفار `zeros`.

```
tf.zeros((2, 3, 4))
```

```
<tf.Tensor: shape=(2, 3, 4), dtype=float32, numpy=
array([[[0., 0., 0., 0.],
        [0., 0., 0., 0.],
        [0., 0., 0., 0.]],

       [[0., 0., 0., 0.],
        [0., 0., 0., 0.],
        [0., 0., 0., 0.]]], dtype=float32)>
```

وبالمثل، يمكننا إنشاء موتر مع كل الآحاد باستدعاء الآحاد `ones`.

```
tf.ones((2, 3, 4))
```

```
<tf.Tensor: shape=(2, 3, 4), dtype=float32, numpy=
array([[[1., 1., 1., 1.],
        [1., 1., 1., 1.],
        [1., 1., 1., 1.]],

       [[1., 1., 1., 1.],
        [1., 1., 1., 1.],
        [1., 1., 1., 1.]]], dtype=float32)>
```

غالبًا ما نرغبفي أخذ عينة من كل عنصر بشكل عشوائي (وبشكل مستقل) من توزيع احتمالي معين. على سبيل المثال، غالبًا ما تتم تهيئة معلمات الشبكات العصبية بشكل عشوائي. يُنشئ المقتطف التالي موترًا بعناصر مستمدة من توزيع غاوسي قياسي (عادي) بمتوسط 0 وانحراف معياري 1.

```
tf.random.normal(shape=[3, 4])
```

```
<tf.Tensor: shape=(3, 4), dtype=float32, numpy=
array([[ 1.5391479 , -1.7407725 ,  0.44389075,
0.8466314 ],
       [-0.486678  , -1.3573753 ,  0.09524103, -1.758265
],
       [ 0.7030494 ,  1.1621033 ,  0.98620087,
1.6612175 ]],
      dtype=float32)>
```

أخيرًا، يمكننا إنشاء الموترات من خلال توفير القيم الدقيقة لكل عنصر من خلال توفير (ربما تكون متداخلة) قائمة (قوائم) بايثون تحتوي على حرفية رقمية. هنا، نقوم ببناء مصفوفة بقائمة من القوائم، حيث تتوافق القائمة الخارجية مع المحور 0، والقائمة الداخلية مع المحور 1.

```
tf.constant([[2, 1, 4, 3], [1, 2, 3, 4], [4, 3, 2, 1]])
```

```
<tf.Tensor: shape=(3, 4), dtype=int32, numpy=
array([[2, 1, 4, 3],
       [1, 2, 3, 4],
       [4, 3, 2, 1]], dtype=int32)>
```

2.1.2. الفهرسة والتقطيع Indexing and Slicing

كما هو الحال مع قوائم بايثون، يمكننا الوصول إلى عناصر الموتر عن طريق الفهرسة indexing (بدءًا من 0). للوصول إلى عنصر بناءً على موضعه بالنسبة إلى نهاية القائمة، يمكننا استخدام الفهرسة السلبية negative indexing. أخيرًا، يمكننا الوصول إلى نطاقات كاملة من المؤشرات عبر التقطيع slicing (على سبيل المثال، `X[start:stop]`)، حيث تتضمن القيمة المُعادة الفهرس الأول (`start`) وليس الأخير (`stop`). أخيرًا، عندما يتم تحديد فهرس index واحد فقط (أو شريحة slice) لموتّر ترتيب (k^{th} – order tensor)، يتم تطبيقه على طول المحور 0. وهكذا،في الكود التالي، `[-1]` يحدد الصف الأخير و `[1:3]` يحدد الثاني والثالث صفوف.

```
X[-1], X[1:3]
```

```
(<tf.Tensor: shape=(4,), dtype=float32, numpy=array([
8.,  9., 10., 11.], dtype=float32)>,
 <tf.Tensor: shape=(2, 4), dtype=float32, numpy=
 array([[ 4.,  5.,  6.,  7.],
        [ 8.,  9., 10., 11.]], dtype=float32)>)
```

الموترات `Tensors` في TensorFlow غير قابلة للتغيير immutable ولا يمكن التخصيص لها. المتغيرات `Variables` في TensorFlow عبارة عن حاويات قابلة للتغيير mutable للحالة تدعم التعيينات assignments. ضع في اعتبارك أن التدرجات gradients في TensorFlow لا تتدفق للخلف من خلال المهام المتغيرة.

بالإضافة إلى تعيين قيمة للمتغير بأكمله، يمكننا كتابة عناصر المتغير `Variable` عن طريق تحديد المؤشرات.

```
X_var = tf.Variable(X)
X_var[1, 2].assign(9)
X_var
```

```
<tf.Variable 'Variable:0' shape=(3, 4) dtype=float32,
numpy=
array([[ 0.,  1.,  2.,  3.],
```

```
       [ 4.,  5.,  9.,  7.],
       [ 8.,  9., 10., 11.]], dtype=float32)>
```

إذا أردنا تعيين عناصر متعددة بنفس القيمة، فإننا نطبق الفهرسة على الجانب الأيسر من عملية الإسناد. على سبيل المثال، يصل `[:2,:]` إلى الصفين الأول والثاني، حيث: يأخذ جميع العناصر على طول المحور 1 (العمود). بينما ناقشنا فهرسة المصفوفات، فإن هذا يعمل أيضًا مع المتجهات والموترات التي تزيد عن بعدين.

```
X_var = tf.Variable(X)
X_var[:2, :].assign(tf.ones(X_var[:2,:].shape,
dtype=tf.float32) * 12)
X_var
```

```
<tf.Variable 'Variable:0' shape=(3, 4) dtype=float32,
numpy=
array([[12., 12., 12., 12.],
       [12., 12., 12., 12.],
       [ 8.,  9., 10., 11.]], dtype=float32)>
```

2.1.3. العمليات Operations

الآن بعد أن عرفنا كيفية بناء الموترات وكيفية القراءة من عناصرها والكتابة إليها، يمكننا البدءفي معالجتها بعمليات رياضية مختلفة. من بين الأدوات الأكثر فائدة هي عمليات العناصر elementwise operations. هذه تطبق عملية scalar قياسية على كل عنصر من عناصر الموتر. بالنسبة للدوال التي تأخذ موترتين كمدخلات، تطبق العمليات الأولية بعض العوامل الثنائية القياسية على كل زوج من العناصر المقابلة. يمكننا إنشاء دالة عنصرية elementwise function من أي دالة تقوم بتعيينها من عددي إلى عددي.

في التدوين الرياضي mathematical notation، نشير إلى هذه العوامل العددية الأحادية (مع إدخال مدخل واحد) من خلال التوقيع $f: \mathbb{R} \rightarrow \mathbb{R}$. هذا يعني فقط أن الدالة ترسم من أي رقم حقيقي إلى عدد حقيقي آخر. يمكن تطبيق معظم العوامل المعيارية بطريقة أساسية بمافي ذلك المشغلين الأحاديين مثل e^x.

```
tf.exp(x)
```

```
<tf.Tensor: shape=(12,), dtype=float32, numpy=
array([1.0000000e+00, 2.7182817e+00, 7.3890562e+00,
2.0085537e+01,
       5.4598148e+01, 1.4841316e+02, 4.0342877e+02,
1.0966332e+03,
       2.9809580e+03, 8.1030840e+03, 2.2026465e+04,
5.9874141e+04],
      dtype=float32)>
```

وبالمثل، فإننا نشير إلى العوامل العددية الثنائية، والتي تقوم بتعيين أزواج من الأرقام الحقيقية إلى رقم حقيقي (واحد) عبر التوقيع $f: \mathbb{R}, \mathbb{R} \rightarrow \mathbb{R}$. بالنظر إلى أي متجهين $\mathbf{u}$ و$\mathbf{v}$ من نفس الشكل، وعامل ثنائي f ، يمكننا إنتاج متجه $\mathbf{c} = F(\mathbf{u}, \mathbf{v})$ عن طريق تعيين عناصر المتجهات $c_i \leftarrow f(u_i, v_i)$ لكل i، وأين c_i, u_i وi^{th}عناصر المتجهات $\mathbf{c}, \mathbf{u}$، و. هنا، أنتجنا قيمة المتجه $F: \mathbb{R}^d, \mathbb{R}^d \rightarrow \mathbb{R}^d$ برفع الدالة العددية إلى عملية متجه عنصري. تم رفع جميع العوامل الحسابية القياسية الشائعة للجمع (+)، والطرح (-)، والضرب (*)، والقسمة (/)، والأس (**) إلى العمليات الأولية لموترات متطابقة الشكل ذات شكل عشوائي.

```
x = tf.constant([1.0, 2, 4, 8])
y = tf.constant([2.0, 2, 2, 2])
x + y, x - y, x * y, x / y, x ** y
```

```
(<tf.Tensor: shape=(4,), dtype=float32, numpy=array([
3.,  4.,  6., 10.], dtype=float32)>,
 <tf.Tensor: shape=(4,), dtype=float32, numpy=array([-
1.,  0.,  2.,  6.], dtype=float32)>,
 <tf.Tensor: shape=(4,), dtype=float32, numpy=array([
2.,  4.,  8., 16.], dtype=float32)>,
 <tf.Tensor: shape=(4,), dtype=float32,
numpy=array([0.5, 1. , 2. , 4. ], dtype=float32)>,
 <tf.Tensor: shape=(4,), dtype=float32, numpy=array([
1.,  4., 16., 64.], dtype=float32)>)
```

بالإضافة إلى الحسابات الأولية، يمكننا أيضًا إجراء عمليات الجبر الخطي linear algebra، مثل حاصل الضرب النقطي dot products وضرب المصفوفات matrix multiplications. سنشرح هذه الأمور بالتفصيل قريبًافي القسم 2.3.

يمكننا أيضًا ربط العديد من الموترات معًا، وتكديسها من طرف إلى طرف لتشكيل موتر أكبر. نحتاج فقط إلى تقديم قائمة بالموترات وإخبار النظام بالمحور المراد ربطه. يوضح المثال أدناه ما يحدث عندما نجمع مصفوفتين على طول الصفوف (المحور 0) مقابل الأعمدة (المحور 1). يمكننا أن نرى أن طول المحور 0 للمخرج الأول (6) هو مجموع أطوال المحور 0 لموتر الإدخال $(3 + 3)$؛ بينما طول المحور 1 للمخرج الثاني (8) هو مجموع أطوال محور 1 لموتر الإدخال $(4 + 4)$.

```
X = tf.reshape(tf.range(12, dtype=tf.float32), (3, 4))
Y = tf.constant([[2.0, 1, 4, 3], [1, 2, 3, 4], [4, 3, 2,
1]])
tf.concat([X, Y], axis=0), tf.concat([X, Y], axis=1)
```

```
(<tf.Tensor: shape=(6, 4), dtype=float32, numpy=
 array([[ 0.,  1.,  2.,  3.],
```

```
        [ 4.,  5.,  6.,  7.],
        [ 8.,  9., 10., 11.],
        [ 2.,  1.,  4.,  3.],
        [ 1.,  2.,  3.,  4.],
        [ 4.,  3.,  2.,  1.]], dtype=float32)>,
 <tf.Tensor: shape=(3, 8), dtype=float32, numpy=
 array([[ 0.,  1.,  2.,  3.,  2.,  1.,  4.,  3.],
        [ 4.,  5.,  6.,  7.,  1.,  2.,  3.,  4.],
        [ 8.,  9., 10., 11.,  4.,  3.,  2.,  1.]],
dtype=float32)>)
```

في بعض الأحيان، نريد بناء موتر ثنائي عبر البيانات المنطقية. خذ `X == Y` كمثال. لكل موضع `i, j` ، إذا كانت `X[i, j]` و `Y[i, j]` متساوية ، فإن الإدخال المقابلفي النتيجة يأخذ القيمة 1 ، وإلا فإنه يأخذ القيمة 0.

```
X == Y
```

```
<tf.Tensor: shape=(3, 4), dtype=bool, numpy=
array([[False,  True, False,  True],
       [False, False, False, False],
       [False, False, False, False]])>
```

يؤدي جمع كل العناصرفي الموتر إلى إنتاج موتر بعنصر واحد فقط.

```
tf.reduce_sum(X)
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=66.0>
```

2.1.4. البث Broadcasting

الآن، أنت تعرف كيفية إجراء عمليات ثنائية العناصر على موترين من نفس الشكل.في ظل ظروف معينة، حتى عندما تختلف الأشكال، لا يزال بإمكاننا إجراء عمليات ثنائية العناصر عن طريق استدعاء آلية البث Broadcasting. يعمل البث وفقًا للإجراء التالي المكون من خطوتين: (1) توسيع أحد المصفوفتين أو كليهما عن طريق نسخ العناصر على طول المحاور بطول 1 بحيث يكون للموترين نفس الشكل بعد هذا التحويل؛ (2) إجراء عملية عنصرية elementwise operation على المصفوفات الناتجة.

```
a = tf.reshape(tf.range(3), (3, 1))
b = tf.reshape(tf.range(2), (1, 2))
a, b
```

```
(<tf.Tensor: shape=(3, 1), dtype=int32, numpy=
 array([[0],
        [1],
        [2]], dtype=int32)>,
```

```
 <tf.Tensor: shape=(1, 2), dtype=int32, numpy=array([[0,
1]], dtype=int32)>)
```

بما أن a و b هما 1 × 3 و 2 × 1 مصفوفتان، على التوالي، فإن أشكالهما لا تتطابق. ينتج عن البث مصفوفة أكبر من خلال تكرار المصفوفة a على طول الأعمدة والمصفوفة b على طول الصفوف قبل إضافتها إلى العناصر.

```
a + b
```

```
<tf.Tensor: shape=(3, 2), dtype=int32, numpy=
array([[0, 1],
       [1, 2],
       [2, 3]], dtype=int32)>
```

2.1.5. حفظ الذاكرة Saving Memory

يمكن أن تؤدي العمليات الجارية إلى تخصيص ذاكرة جديدة لنتائج المضيف. على سبيل المثال، إذا كتبنا Y = X + Y، فإننا نلغي الإشارة إلى الموتر الذي استخدمه Y للإشارة إليه وبدلاً من ذلك نشير إلى Yفي الذاكرة المخصصة حديثًا. يمكننا توضيح هذه المشكلة باستخدام دالة id() في بايثون ، والتي تعطينا العنوان الدقيق للكائن المشار إليهفي الذاكرة. لاحظ أنه بعد تشغيل Y = Y + X, id(Y)، يشير المعرف (Y) إلى موقع مختلف. هذا لأن بايثون أول من يقيّم Y + X، ويخصص ذاكرة جديدة للنتيجة ثم يشير Y إلى هذا الموقع الجديدفي الذاكرة.

```
before = id(Y)
Y = Y + X
id(Y) == before
```

```
False
```

قد يكون هذا غير مرغوب فيه لسببين. أولاً، لا نريد الالتفاف حول تخصيص الذاكرة دون داعٍ طوال الوقت.في التعلم الآلي، غالبًا ما يكون لدينا مئات الميجابايت من المعلمات ونقوم بتحديثها جميعًا عدة مراتفي الثانية. كلما كان ذلك ممكنًا، نريد إجراء هذه التحديثاتفي مكانها الصحيح. ثانيًا، قد نشير إلى نفس المعلمات من متغيرات متعددة. إذا لم نقم بالتحديثفي مكانه الصحيح، فيجب أن نكون حريصين على تحديث كل هذه المراجع، لئلا نتسببفي تسرب للذاكرة أو نشير عن غير قصد إلى معلمات قديمة.

المتغيرات Variables عبارة عن حاويات قابلة للتغيير للحالةفي TensorFlow. أنها توفر طريقة لتخزين معلمات النموذج الخاص بك. يمكننا إسناد نتيجة العملية إلى متغير Variable مع تعيين assign. لتوضيح هذا المفهوم، قمنا بالكتابة فوق قيم Variable Z بعد تهيئته، باستخدام zeros_like، ليكون لها نفس شكل Y.

```
Z = tf.Variable(tf.zeros_like(Y))
print('id(Z):', id(Z))
```

```
Z.assign(X + Y)
print('id(Z):', id(Z))
```
```
id(Z): 140011833215008
id(Z): 140011833215008
```

حتى بعد تخزين الحالة باستمرارفي متغير Variable، قد ترغبفي تقليل استخدام الذاكرة بشكل أكبر عن طريق تجنب التخصيصات الزائدة لموترات ليست معلمات نموذجك. نظرًا لأن موترات TensorFlowغير قابلة للتغيير immutable ولا تتدفق التدرجات gradients من خلال التعيينات المتغيرة، لا يوفر TensorFlow طريقة واضحة لتشغيل عملية فرديةفي المكان.

ومع ذلك، يوفر TensorFlow مصمم tf.function لالتفاف الحساب داخل الرسم البياني TensorFlow الذي يتم تجميعه وتحسينه قبل التشغيل. يتيح ذلك لـ TensorFlow تقليم prune القيم غير المستخدمة وإعادة استخدام التخصيصات السابقة التي لم تعد مطلوبة. هذا يقلل من حمل الذاكرة لحسابات TensorFlow.

```
@tf.function
def computation(X, Y):
    Z = tf.zeros_like(Y)  # This unused value will be
pruned out
    A = X + Y  # Allocations will be reused when no
longer needed
    B = A + Y
    C = B + Y
    return C + Y

computation(X, Y)
```
```
<tf.Tensor: shape=(3, 4), dtype=float32, numpy=
array([[ 8.,  9., 26., 27.],
       [24., 33., 42., 51.],
       [56., 57., 58., 59.]], dtype=float32)>
```

2.1.6. التحويل إلى كائنات بايثون الأخرى

يعد التحويل إلى موتر NumPy (ndarray) أو العكس أمرًا سهلاً. النتيجة المحولة لا تشترك في الذاكرة. هذا الإزعاج البسيط مهم جدًافي الواقع: عند إجراء عمليات على وحدة المعالجة المركزية CPU أو على وحدات معالجة الرسومات GPUs، فأنت لا تريد إيقاف الحساب،في انتظار معرفة ما إذا كانت حزمة NumPy من بايثون قد ترغبفي القيام بشيء آخر بنفس جزء الذاكرة.

```
A = X.numpy()
B = tf.constant(A)
type(A), type(B)
```

```
(numpy.ndarray,
tensorflow.python.framework.ops.EagerTensor)
```

لتحويل موتر بحجم 1 إلى Python scalar، يمكننا استدعاء دالة العنصر `item` أو دوال بايثون المضمنة.

```
a = tf.constant([3.5]).numpy()
a, a.item(), float(a), int(a)
(array([3.5], dtype=float32), 3.5, 3.5, 3)
```

2.1.7. الملخص

- كلاس الموتر tensor class هي الواجهة الرئيسية لتخزين البيانات ومعالجتها في مكتبات التعلم العميق.
- توفر Tensors مجموعة متنوعة من الدوال بما في ذلك إجراءات البناء construction routines ؛ الفهرسة indexing والتقطيع slicing العمليات الرياضيات الأساسية ؛ البث broadcasting. التخصيص الفعال للذاكرة memory-efficient assignment ؛ والتحويل من وإلى كائنات بايثون الأخرى.

2.1.8. التمارين

- قم بتشغيل الكود في هذا القسم. قم بتغيير العبارة الشرطية `X == Y` إلى `X < Y` أو `X > Y` ، ثم انظر إلى نوع الموتر الذي يمكنك الحصول عليه.
- استبدل الموترتين اللتين تعملان بواسطة عنصر في آلية البث بأشكال أخرى ، على سبيل المثال ، موترات ثلاثية الأبعاد. هل النتيجة هي نفسها كما هو متوقع؟

2.2. معالجة البيانات Data Preprocessing

حتى الآن، كنا نعمل مع البيانات التركيبية التي وصلتفي موترات جاهزة. ومع ذلك، لتطبيق التعلم العميقفي البرية، يجب علينا استخراج البيانات الفوضوية messy data المخزنة بتنسيقات عشوائية، ومعالجتها مسبقًا لتناسب احتياجاتنا. لحسن الحظ، يمكن لمكتبة `pandas` القيام بالكثير من الرفع الثقيل. هذا القسم، على الرغم من عدم وجود بديل عن برنامج تعليمي مناسب لـ `pandas` ، سيمنحك دورة مكثفة حول بعض الإجراءات الروتينية الأكثر شيوعًا.

2.2.1. قراءة مجموعة البيانات Reading the Dataset

ملفات القيم المفصولة بفواصل (CSV) موجودةفي كل مكان لتخزين البيانات الجدولية (مثل جداول البيانات). هنا، يتوافق كل سطر مع سجل واحد ويتكون من عدة حقول (مفصولة بفواصل comma-separated)، على سبيل المثال، "ألبرت أينشتاين، 14 مارس 1879، أولم ، مدرسة الفنون التطبيقية الفيدرالية ، الإنجازاتفي مجال فيزياء الجاذبية". لتوضيح كيفية تحميل ملفات

CSV مع pandas، نقوم بإنشاء ملف CSV أدناه `../data/house_tiny.csv` يمثل هذا الملف مجموعة بيانات للمنازل، حيث يتوافق كل صف مع منزل مميز وتتوافق الأعمدة مع عدد الغرف (`NumRooms`) ونوع السقف (`RoofType`) والسعر (`Price`).

```
import os

os.makedirs(os.path.join('..', 'data'), exist_ok=True)
data_file = os.path.join('..', 'data', 'house_tiny.csv')
with open(data_file, 'w') as f:
    f.write('''NumRooms,RoofType,Price
NA,NA,127500
2,NA,106000
4,Slate,178100
NA,NA,140000''')
```

دعنا الآن نستورد `pandas` ونحمِّل مجموعة البيانات مع `read_csv`.

```
import pandas as pd

data = pd.read_csv(data_file)
print(data)
```

```
   NumRooms RoofType   Price
0       NaN      NaN  127500
1       2.0      NaN  106000
2       4.0    Slate  178100
3       NaN      NaN  140000
```

2.2.2. تحضير البيانات Data Preparation

في التعلم الخاضع للإشراف، نقوم بتدريب النماذج للتنبؤ بقيمة مستهدفة معينة، مع الأخذفي الاعتبار مجموعة معينة من قيم الإدخال. خطوتنا الأولىفي معالجة مجموعة البيانات هي فصل الأعمدة المقابلة للإدخال input مقابل القيم المستهدفة target values. يمكننا تحديد الأعمدة إما بالاسم أو عن طريق الفهرسة القائمة على الموقع الصحيح integer-location based indexing (`iloc`).

ربما لاحظت أن `pandas` استبدلت جميع إدخالات CSV بالقيمة `NA` بقيمة `NaN` خاصة (ليس رقمًا not a number). يمكن أن يحدث هذا أيضًا عندما يكون الإدخال فارغًا empty، على سبيل المثال، "3,,,270000" . تسمى هذه القيم المفقودة missing values وهي " bed bugs"في علم البيانات، وهو تهديد دائم ستواجهه طوال حياتك المهنية. اعتمادًا على السياق، يمكن معالجة القيم المفقودة إما عن طريق التضمين imputation أو الحذف deletion.

يستبدل التضمين Imputation القيم المفقودة بتقديرات لقيمها بينما يتجاهل الحذف deletion ببساطة إما تلك الصفوف أو تلك الأعمدة التي تحتوي على قيم مفقودة.

فيما يلي بعض أساليب التضمين الشائعة. بالنسبة لحقول الإدخال الفئوية categorical input fields، يمكننا التعامل مع `NaN` كفئة. نظرًا لأن العمود `RoofType` يأخذ القيم `Slate` و `NaN`، يمكن لـ `pandas` تحويل هذا العمود إلى عمودين `RoofType_Slate` و `RoofType_nan`. سيحدد الصف الذي يكون نوع زقاقه هو `Slate` قيم `RoofType_Slate` و `RoofType_nan` على 1 و 0 على التوالي. يحمل العكس لصف به قيمة `RoofType` مفقودة.

```
inputs, targets = data.iloc[:, 0:2], data.iloc[:, 2]
inputs = pd.get_dummies(inputs, dummy_na=True)
print(inputs)
```

```
NumRooms  RoofType_Slate  RoofType_nan
0       NaN              0             1
1       2.0              0             1
2       4.0              1             0
3       NaN              0             1
```

بالنسبة للقيم العددية المفقودة missing numerical values، يتمثل أحد الأساليب الإرشادية heuristic الشائعةفي استبدال إدخالات `NaN` بالقيمة المتوسطة للعمود المقابل.

```
inputs = inputs.fillna(inputs.mean())
print(inputs)
```

```
NumRooms  RoofType_Slate  RoofType_nan
0       3.0              0             1
1       2.0              0             1
2       4.0              1             0
3       3.0              0             1
```

2.2.3. التحويل إلى تنسيق Tensor

الآن بعد أن أصبحت جميع الإدخالاتفي المدخلات والأهداف رقمية، يمكننا تحميلهافي موتر (تذكر القسم 2.1).

```
import tensorflow as tf

X, y = tf.constant(inputs.values),
tf.constant(targets.values)
X, y
```

```
(<tf.Tensor: shape=(4, 3), dtype=float64, numpy=
 array([[3., 0., 1.],
```

```
        [2., 0., 1.],
        [4., 1., 0.],
        [3., 0., 1.]])>,
 <tf.Tensor: shape=(4,), dtype=int64,
numpy=array([127500, 106000, 178100, 140000])>)
```

2.2.4. المناقشة

أنت تعرف الآن كيفية تقسيم أعمدة البيانات، وإسناد المتغيرات المفقودة، وتحميل بيانات Pandas إلى موترات.في القسم 5.7، سوف تكتسب المزيد من مهارات معالجة البيانات.في حين أن هذه الدورة التدريبية المكثفة تبقي الأمور بسيطة، يمكن أن تصبح معالجة البيانات صعبة. على سبيل المثال، بدلاً من الوصول إلى ملف CSV واحد، قد تنتشر مجموعة البيانات الخاصة بنا عبر ملفات متعددة مستخرجة من قاعدة بيانات علائقية. على سبيل المثال،في تطبيق التجارة الإلكترونية e-commerce، قد تكون عناوين العملاء موجودةفي جدول وشراء البياناتفي جدول آخر. علاوة على ذلك، يواجه الممارسون أنواعًا لا تعد ولا تحصى من البيانات تتجاوز الفئوية والرقمية. تتضمن أنواع البيانات الأخرى سلاسل نصية وصور وبيانات صوتية وسُحب النقاط point clouds.في كثير من الأحيان، تكون الأدوات المتقدمة والخوارزميات الفعالة مطلوبة لمنع معالجة البيانات من أن تصبح أكبر عنق زجاجةفي خط أنابيب التعلم الآلي. ستظهر هذه المشاكل عندما نصل إلى الرؤية الحاسوبية ومعالجة اللغة الطبيعية. أخيرًا، يجب أن ننتبه إلى جودة البيانات data quality. غالبًا ما تعاني مجموعات البيانات الواقعية من القيم المتطرفة outliers، والقياسات الخاطئة من أجهزة الاستشعار sensors، وأخطاء التسجيل، والتي يجب معالجتها قبل تغذية البياناتفي أي نموذج. يمكن أن تساعدك أدوات تصور البيانات مثل seaborn أو Bokeh أو matplotlib على فحص البيانات يدويًا وتطوير حدس حول المشكلات التي قد تحتاج إلى معالجتها.

2.2.5. التمارين

1. حاول تحميل مجموعات البيانات datasets، على سبيل المثال، Abalone من مستودع UCI Machine Learning Repository وفحص خصائصها. أي جزء منهم يحتوي على قيم مفقودة missing values؟ ما هو جزء المتغيرات العددية numerical أو الفئوية categorical أو النصية text؟
2. جرب فهرسة واختيار أعمدة البيانات بالاسم بدلاً من رقم العمود. تحتوي وثائق Pandas الخاصة بالفهرسة على مزيد من التفاصيل حول كيفية القيام بذلك.
3. ما حجم مجموعة البيانات التي تعتقد أنه يمكنك تحميلها بهذه الطريقة؟ ما قد تكون القيود؟ تلميح: ضع في اعتبارك الوقت اللازم لقراءة البيانات والتمثيل والمعالجة

وبصمة الذاكرة. جرب هذا على الكمبيوتر المحمول الخاص بك. ما الذي يتغير إذا جربته على الخادم؟

4. كيف ستتعامل مع البيانات التي تحتوي على عدد كبير جدًا من الفئات categories؟ ماذا لو كانت تسميات الفئات كلها فريدة unique ؟ هل يجب عليك تضمين الأخير؟
5. ما هي بدائل الباندا Pandas التي يمكنك التفكير فيها؟ ماذا عن تحميل موترات NumPy من ملف؟ تحقق من Pillow ، مكتبة تصوير Python.

2.3 الجبر الخطي Linear Algebra

في الوقت الحالي، يمكننا تحميل مجموعات البيانات إلى موترات ومعالجة هذه الموترات من خلال العمليات الحسابية الأساسية. لبدء بناء نماذج متطورة، سنحتاج أيضًا إلى بعض الأدوات من الجبر الخطي linear algebra. يقدم هذا القسم مقدمة لطيفة لأهم المفاهيم، بدءًا من الحساب العددي scalar arithmetic والتكثيف ramping up وصولاً إلى ضرب المصفوفة matrix multiplication.

2.3.1. الكميات القياسية Scalars

تتكون معظم الرياضيات اليومية من معالجة الأرقام واحدًا تلو الآخر. رسميًا، نسمي هذه القيم الكميات القياسية Scalars. على سبيل المثال، درجة الحرارةفي بالو ألتو هي 72 درجات فهرنهايت معتدلة. إذا أردت تحويل درجة الحرارة إلى درجات سيليزية، فعليك تقييم التعبير $c = \frac{5}{9}(f - 32)$، وضبط f على 72.في هذه المعادلة، القيم 5 ، 9 و32 هي كميات قياسية. المتغيرات c و f تمثل الكميات القياسية غير المعروفة unknown scalars.

نشير إلى الكميات القياسية scalars بأحرف عادية صغيرة (على سبيل المثال،x وy وz) ومساحة جميع المقاييس ذات القيمة الحقيقية (المستمرة) بواسطة $\mathbb{R}$. من أجل المنفعة، سوف نتخطى التعريفات الصارمة للمساحات السابقة spaces. فقط تذكر أن التعبير $x \in \mathbb{R}$ هو طريقة رسمية للقول بأن هذا عدد حقيقي ذو قيمة x . يشير الرمز $\in$ (يُنطق "in") إلى العضويةفي مجموعة. على سبيل المثال،$x, y \in \{0,1\}$ يشير إلى أن والمتغيرات التي يمكن أن تأخذ فقط قيمًا 0 أو1 .

```
import tensorflow as tf

x = tf.constant(3.0)
y = tf.constant(2.0)

x + y, x * y, x / y, x**y
```

```
(<tf.Tensor: shape=(), dtype=float32, numpy=5.0>,
 <tf.Tensor: shape=(), dtype=float32, numpy=6.0>,
 <tf.Tensor: shape=(), dtype=float32, numpy=1.5>,
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=9.0>)
```

2.3.2. المتجهات Vectors

لأغراضنا، يمكنك التفكيرفي المتجهات Vectors على أنها مصفوفات ذات طول ثابت من الكميات القياسية scalars. كما هو الحال مع نظرائهمفي الكود، نسمي هذه القيم عناصر المتجه elements of the vector (المرادفات تشمل الإدخالات والمكونات). عندما تمثل المتجهات أمثلة من مجموعات بيانات من العالم الحقيقي، فإن قيمها تحمل بعض الأهميةفي العالم الحقيقي. على سبيل المثال، إذا كنا ندرب نموذجًا للتنبؤ بمخاطر التخلف عن سداد القرض loan defaulting، فقد نربط كل متقدم بمتجه تتطابق مكوناته مع كميات مثل دخله أو طول فترة التوظيف أو عدد حالات التخلف عن السداد السابقة. إذا كنا ندرس مخاطر النوبات القلبية heart attack risk، فقد يمثل كل متجه مريضًا وقد تتوافق مكوناته مع أحدث علاماته الحيوية ومستويات الكوليسترول ودقائق من التمارينفي اليوم وما إلى ذلك. $\mathbf{x}$ و $\mathbf{y}$ و $\mathbf{z}$).

يتم تنفيذ المتجهات كموترات ترتيب 1^{st} order tensors-. بشكل عام، يمكن أن يكون لمثل هذه الموترات أطوال عشوائية، تخضع لقيود الذاكرة. تحذير:في بايثون، كما هو الحالفي معظم لغات البرمجة، تبدأ مؤشرات المتجهات vector indices عند 0 ، والمعروفة أيضًا باسم الفهرسة الصفرية zero-based indexing، بينمافي الجبر الخطي، تبدأ نصوص الجبر الخطي من 1 (الفهرسة على أساس واحد one-based indexing).

```
x = tf.range(3)
x
```

```
<tf.Tensor: shape=(3,), dtype=int32, numpy=array([0, 1,
2], dtype=int32)>
```

يمكننا الإشارة إلى عنصر متجه باستخدام حرف منخفض subscript. على سبيل المثال،x_2 يشير إلى العنصر الثاني من $\mathbf{x}$. نظرًا لأنه قيمة قياسية scalar، فإننا لا نظهره بخط عريض. بشكل افتراضي، نحن نتخيل المتجهات عن طريق تكديس عناصرها عموديًا.

$$\mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix},$$

فيما يلي عناصر المتجه $x_1, \ldots, x_n$.في وقت لاحق، سوف نميز بين متجهات الأعمدة column vectors ومتجهات الصفوف row vectors التي يتم تكديس عناصرها أفقيًا. تذكر أننا نصل إلى عناصر الموتر عبر الفهرسة indexing.

```
x[2]
```

```
<tf.Tensor: shape=(), dtype=int32, numpy=2>
```

للإشارة إلى أن المتجه يحتوي على عناصر n ، نكتب $\mathbf{x} \in \mathbb{R}^n$. بشكل رسمي، نطلق n على أبعاد المتجه dimensionality of the vector.في الكود، هذا يتوافق مع طول الموتر، ويمكن الوصول إليه عبر دالة `len` المدمجةفي بايثون.

```
len(x)
```

```
3
```

يمكننا أيضًا الوصول إلى الطول عبر سمة الشكل `shape`. الشكل عبارة عن مجموعة تشير إلى طول الموتر على طول كل محور. الموترات التي لها محور واحد فقط لها أشكال تحتوي على عنصر واحد فقط.

```
x.shape
```

```
TensorShape([3])
```

في كثير من الأحيان، يتم تحميل كلمة "بُعد dimension " بشكل زائد لتعني كلاً من عدد المحاور والطول على طول محور معين. لتجنب هذا الالتباس، نستخدم الترتيب order للإشارة إلى عدد المحاور والأبعاد dimensionality حصريًا للإشارة إلى عدد المكونات.

2.3.3. المصفوفات Matrices

كما أن الكميات القياسية scalars هي موترات الترتيب `0th-order tensors` والمتجهات `vectors` هي `1st-order tensors` ، فإن المصفوفات `matrices` هي موترات ترتيب `2nd-order tensors`. نشير إلى المصفوفات بأحرف كبيرة غامقة (على سبيل المثال،$\mathbf{X}$ و$\mathbf{Y}$ و$\mathbf{Z}$)، ونمثلهافي رمز بواسطة موترات بمحورين. يشير التعبير $\mathbf{A} \in \mathbb{R}^{m \times n}$ إلى أن المصفوفة $\mathbf{A}$ تحتوي على قيم قياسية scalers حقيقية القيمة $m \times n$ ، مرتبةفي شكل m صفوف وn أعمدة. عندما $m = n$ نقول إن المصفوفة مربعة square. بصريا، يمكننا توضيح أي مصفوفة كجدول. للإشارة إلى عنصر فردي، نقوم بتدوين كل من فهارس الصفوف والأعمدة ، على سبيل المثال ،a_{ij} القيمة التي تنتمي إلى $\mathbf{A}'si^{\text{th}}$ صف وj^{th} عمود:

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix}.$$

في الكود، نحن نمثل مصفوفة $\mathbf{A} \in \mathbb{R}^{m \times n}$ بواسطة موتر الترتيب `2nd-order tensors` بالشكل $(m، n)$. يمكننا تحويل أي موتر بحجم مناسب $m \times n$ إلى مصفوفة $m \times n$ بتمرير الشكل المطلوب لإعادة تشكيله `reshape`:

```
A = tf.reshape(tf.range(6), (3, 2))
A
```

```
<tf.Tensor: shape=(3, 2), dtype=int32, numpy=
```

```
array([[0, 1],
       [2, 3],
       [4, 5]], dtype=int32)>
```

في بعض الأحيان، نريد قلب المحاور. عندما نتبادل صفوف وأعمدة المصفوفة، فإن النتيجة تسمى تبديلها transpose. بشكل رسمي، نشير إلى تبديل المصفوفة $\mathbf{A}$ بواسطة $\mathbf{A}^\top$ و اذا $\mathbf{B} = \mathbf{A}^\top$ ، ثم $b_{ij} = a_{ji}$ لجميع i وj. وبالتالي، فإن تبديل المصفوفة $n \times m$ عبارة عن مصفوفة $m \times n$:

$$\mathbf{A}^\top = \begin{bmatrix} a_{11} & a_{21} & \dots & a_{m1} \\ a_{12} & a_{22} & \dots & a_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1n} & a_{2n} & \dots & a_{mn} \end{bmatrix}.$$

في الكود، يمكننا الوصول إلى تبديل أي مصفوفة matrix's transpose على النحو التالي:

```
tf.transpose(A)
```

```
<tf.Tensor: shape=(2, 3), dtype=int32, numpy=
array([[0, 2, 4],
       [1, 3, 5]], dtype=int32)>
```

المصفوفات المتماثلة Symmetric matrices هي مجموعة فرعية من المصفوفات المربعة square matrices التي تساوي التبادلات الخاصة بها: $\mathbf{A} = \mathbf{A}^\top$. المصفوفة التالية متماثلة:

```
A = tf.constant([[1, 2, 3], [2, 0, 4], [3, 4, 5]])
A == tf.transpose(A)
```

```
<tf.Tensor: shape=(3, 3), dtype=bool, numpy=
array([[ True,  True,  True],
       [ True,  True,  True],
       [ True,  True,  True]])>
```

المصفوفات مفيدةفي تمثيل مجموعات البيانات. عادةً ما تتوافق الصفوف مع السجلات الفردية وتتوافق الأعمدة مع سمات مميزة.

2.3.4. الموترات Tensors

بينما يمكنك الذهاب بعيداًفي رحلة التعلم الآلي الخاصة بك باستخدام الكميات القياسية Scalarsوالمتجهات vectors والمصفوفات Matrices فقط، فقد تحتاجفي النهاية إلى العمل مع الموترات ذات الترتيب الأعلى higher-order tensors. تقدم لنا الموترات طريقة عامة لوصف الامتدادات لمصفوفات الترتيب n^{th}-order arrays . نحن نطلق على كلاسات البرامج من فئة الموتر "موترات tensors " على وجه التحديد لأنها يمكن أن تحتوي أيضًا على أعداد عشوائية من المحاور.في حين أنه قد يكون من المربك استخدام كلمة موتر لكل من الكائن الرياضي وإدراكهفي الكود، يجب أن يكون معنانا واضحًا من السياق. نشير إلى الموترات العامة بأحرف

كبيرة مع وجه خط خاص (على سبيل المثال،X ،Y وZ) وآلية الفهرسة الخاصة بهم (على سبيل المثال، x_{ijk} و$[X]_{1,2i-1,3}$) تتبع بشكل طبيعي من المصفوفات.

ستصبح الموترات أكثر أهمية عندما نبدأ العمل مع الصور. تصل كل صورة على هيئة موتر بترتيب 3rd-order tensor مع محاور مقابلة للارتفاع والعرض والقناة channel.في كل موقع مكاني، تتراكم شدة كل لون (أحمر وأخضر وأزرق) على طول القناة. علاوة على ذلك، يتم تمثيل مجموعة من الصورفي رمز بواسطة موتر ترتيب 4th-order tensor ، حيث يتم فهرسة الصور المميزة على طول المحور الأول. يتم إنشاء الموترات ذات الترتيب الأعلى بشكل مشابه للمتجهات والمصفوفات، من خلال زيادة عدد مكونات الشكل.

```
tf.reshape(tf.range(24), (2, 3, 4))
```

```
<tf.Tensor: shape=(2, 3, 4), dtype=int32, numpy=
array([[[ 0,  1,  2,  3],
        [ 4,  5,  6,  7],
        [ 8,  9, 10, 11]],

       [[12, 13, 14, 15],
        [16, 17, 18, 19],
        [20, 21, 22, 23]]], dtype=int32)>
```

2.3.5. الخصائص الأساسية لحساب الموتر

الكميات القياسية والمتجهات والمصفوفات والموترات ذات الترتيب الأعلى جميعها لها بعض الخصائص المفيدة. على سبيل المثال، تنتج عمليات elementwise مخرجات لها نفس شكل معاملاتها.

```
A = tf.reshape(tf.range(6, dtype=tf.float32), (2, 3))
B = A  # No cloning of `A` to `B` by allocating new
memory
A, A + B
```

```
(<tf.Tensor: shape=(2, 3), dtype=float32, numpy=
 array([[0., 1., 2.],
        [3., 4., 5.]], dtype=float32)>,
 <tf.Tensor: shape=(2, 3), dtype=float32, numpy=
 array([[ 0.,  2.,  4.],
        [ 6.,  8., 10.]], dtype=float32)>)
```

يسمى الضرب الأولي elementwise product لمصفوفتين ضرب Hadamard (يشار إليه $\odot$). أدناه، نوضح إدخالات منتج Hadamard لمصفوفتين $\mathbf{A}, \mathbf{B} \in \mathbb{R}^{m \times n}$:

$$\mathbf{A} \odot \mathbf{B} = \begin{bmatrix} a_{11}b_{11} & a_{12}b_{12} & \dots & a_{1n}b_{1n} \\ a_{21}b_{21} & a_{22}b_{22} & \dots & a_{2n}b_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1}b_{m1} & a_{m2}b_{m2} & \dots & a_{mn}b_{mn} \end{bmatrix}.$$

```
A * B
```

```
<tf.Tensor: shape=(2, 3), dtype=float32, numpy=
array([[ 0.,  1.,  4.],
       [ 9., 16., 25.]], dtype=float32)>
```

إضافة أو مضاعفة قيمة قياسية scalar وموتر tensor ينتج عنه نتيجة بنفس شكل الموتر الأصلي. هنا ، يضاف كل عنصر من عناصر الموتر إلى (أو يضرب في) القيمة القياسية.

```
a = 2
X = tf.reshape(tf.range(24), (2, 3, 4))
a + X, (a * X).shape
```

```
(<tf.Tensor: shape=(2, 3, 4), dtype=int32, numpy=
 array([[[ 2,  3,  4,  5],
         [ 6,  7,  8,  9],
         [10, 11, 12, 13]],

        [[14, 15, 16, 17],
         [18, 19, 20, 21],
         [22, 23, 24, 25]]], dtype=int32)>,
 TensorShape([2, 3, 4]))
```

2.3.6. الاختزال Reduction

في كثير من الأحيان، نرغبفي حساب مجموع عناصر الموتر. للتعبير عن مجموع العناصرفي متجه $\mathbf{x}$ الطول n ، نكتب x_i $\sum_{i=1}^{n}$. هناك دالة بسيطة لها:

```
x = tf.range(3, dtype=tf.float32)
x, tf.reduce_sum(x)
```

```
(<tf.Tensor: shape=(3,), dtype=float32, numpy=array([0.,
1., 2.], dtype=float32)>,
 <tf.Tensor: shape=(), dtype=float32, numpy=3.0>)
```

للتعبير عن المجاميع sums على عناصر الموترات ذات الشكل التعسفي arbitrary shape، فإننا ببساطة نجمع جميع محاورها. على سبيل المثال، يمكن كتابة مجموع عناصر $m \times n$ المصفوفة $\mathbf{A}$ كـ a_{ij} $\sum_{i=1}^{m}\sum_{j=1}^{n}$.

```
A.shape, tf.reduce_sum(A)
```

```
(TensorShape([2, 3]), <tf.Tensor: shape=(),
dtype=float32, numpy=15.0>)
```

بشكل افتراضي، يؤدي استدعاء دالة الجمع إلى تقليل الموتر على طول جميع محاوره، مما يؤديفي النهاية إلى إنتاج قيمة قياسية scalar. تتيح لنا مكتباتنا أيضًا تحديد المحاور التي يجب أن يتم تقليل الموتر على طولها. لتجميع جميع العناصر على طول الصفوف (المحور 0)، نحدد `axis=0` في `sum`. نظرًا لأن مصفوفة الإدخال تقلل على طول المحور 0 لتوليد متجه الإخراج، فإن هذا المحور مفقود من شكل المخرجات.

```
A.shape, tf.reduce_sum(A, axis=0).shape
```

```
(TensorShape([2, 3]), TensorShape([3]))
```

سيؤدي تحديد `axis=1` إلى تقليل بُعد العمود (المحور 1) عن طريق جمع عناصر جميع الأعمدة.

```
A.shape, tf.reduce_sum(A, axis=1).shape
```

```
(TensorShape([2, 3]), TensorShape([2]))
```

إن اختزال مصفوفة على طول كل من الصفوف والأعمدة عن طريق الجمع يعادل تلخيص كل عناصر المصفوفة.

```
tf.reduce_sum(A, axis=[0, 1]), tf.reduce_sum(A) # Same as `tf.reduce_sum(A)`
```

```
(<tf.Tensor: shape=(), dtype=float32, numpy=15.0>,
 <tf.Tensor: shape=(), dtype=float32, numpy=15.0>)
```

الكمية ذات الصلة هي المتوسط mean، وتسمى أيضًا average. نحسب المتوسط بقسمة المجموع على العدد الإجمالي للعناصر. نظرًا لأن حساب المتوسط شائع جدًا، فإنه يحصل على دالة مكتبة مخصصة تعمل بشكل مماثل للجمع `sum`.

```
tf.reduce_mean(A), tf.reduce_sum(A) / tf.size(A).numpy()
```

```
(<tf.Tensor: shape=(), dtype=float32, numpy=2.5>,
 <tf.Tensor: shape=(), dtype=float32, numpy=2.5>)
```

وبالمثل، يمكن لدالة حساب المتوسط أن تقلل من موتر على طول محاور معينة.

```
tf.reduce_mean(A, axis=0), tf.reduce_sum(A, axis=0) /
A.shape[0]
```

```
(<tf.Tensor: shape=(3,), dtype=float32,
numpy=array([1.5, 2.5, 3.5], dtype=float32)>,
 <tf.Tensor: shape=(3,), dtype=float32,
numpy=array([1.5, 2.5, 3.5], dtype=float32)>)
```

2.3.7. مجموع عدم الاختزال Non-Reduction Sum

قد يكون من المفيد أحيانًا الاحتفاظ بعدد المحاور دون تغيير عند استدعاء الدالة لحساب المجموع أو المتوسط. هذا مهم عندما نريد استخدام آلية البث broadcast mechanism.

```
sum_A = tf.reduce_sum(A, axis=1, keepdims=True)
sum_A, sum_A.shape
```

```
(<tf.Tensor: shape=(2, 1), dtype=float32, numpy=
 array([[ 3.],
        [12.]], dtype=float32)>,
 TensorShape([2, 1]))
```

على سبيل المثال، بما أن sum_A تحافظ على محوريها بعد جمع كل صف، يمكننا قسمة A على sum_A مع البث لإنشاء مصفوفة حيث يتم جمع كل صف الى 1.

```
A / sum_A
```

```
<tf.Tensor: shape=(2, 3), dtype=float32, numpy=
array([[0.        , 0.33333334, 0.6666667 ],
       [0.25      , 0.33333334, 0.41666666]],
dtype=float32)>
```

إذا أردنا حساب المجموع التراكمي cumulative sum لعناصر A على طول بعض المحاور، قل axis=0 (صف بصف)، يمكننا استدعاء دالة cumsum. حسب التصميم، لا تقلل هذه الدالة من موتر الإدخال على طول أي محور.

```
tf.cumsum(A, axis=0)
```

```
<tf.Tensor: shape=(2, 3), dtype=float32, numpy=
array([[0., 1., 2.],
       [3., 5., 7.]], dtype=float32)>
```

2.3.8. الضرب النقطي Dot Products

حتى الآن، قمنا فقط بإجراء العمليات الأولية، والمجموع، والمتوسطات. وإذا كان هذا هو كل ما يمكننا فعله، فلن يستحق الجبر الخطي قسمًا خاصًا به. لحسن الحظ، هذا هو المكان الذي تصبح فيه الأشياء أكثر إثارة للاهتمام. يعد حاصل الضرب النقطي Dot Products من أهم العمليات الأساسية. بالنظر إلى متجهين $\mathbf{x}, \mathbf{y} \in \mathbb{R}^d$ ، فإن حاصل الضرب النقطي $\mathbf{x}^\top \mathbf{y}$ (او$\langle \mathbf{x}, \mathbf{y} \rangle$) هو مجموع حاصل ضرب العناصرفي نفس الموضع: $\mathbf{x}^\top \mathbf{y} = \sum_{i=1}^{d} x_i y_i$.

```
y = tf.ones(3, dtype=tf.float32)
x, y, tf.tensordot(x, y, axes=1)
```

```
(<tf.Tensor: shape=(3,), dtype=float32, numpy=array([0.,
1., 2.], dtype=float32)>,
 <tf.Tensor: shape=(3,), dtype=float32, numpy=array([1.,
1., 1.], dtype=float32)>,
 <tf.Tensor: shape=(), dtype=float32, numpy=3.0>)
```

بالتساوي، يمكننا حساب حاصل الضرب النقطي لمتجهين عن طريق إجراء عملية ضرب عنصري elementwise multiplication متبوعة بمجموع sum:

```
tf.reduce_sum(x * y)
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=3.0>
```

يعتبر الضرب النقطي مفيدفي مجموعة واسعة من السياقات. على سبيل المثال، بالنظر إلى مجموعة من القيم، يُشار إليها بالمتجه $\mathbf{x} \in \mathbb{R}^n$ ومجموعة من الأوزان التي يُشار إليهافي $\mathbf{w} \in \mathbb{R}^n$ ، يمكن التعبير عن امجموع الاوزان للقيم وفقًا للأوزان $\mathbf{w}$ على أنها حاصل الضرب النقطي $\mathbf{x}^\top \mathbf{w}$. عندما تكون الأوزان غير سالبة ومجموعها واحد، مثل $(\sum_{i=1}^{n} w_i = 1)$، يعبر الضرب النقطي عن مجموع الاوزان weighted average. بعد تسوية متجهين بحيث يكون لهما طول الوحدة unit length، تعبر حاصل الضرب النقطي عن جيب التمام للزاوية بينهما. لاحقًافي هذا القسم، سنقدم رسميًا فكرة الطول length هذه.

2.3.9. ضرب Matrix-Vector

الآن بعد أن عرفنا كيفية حساب حاصل الضرب النقطي، يمكننا البدءفي فهم حاصل الضرب بين مصفوفة $m \times n$ $\mathbf{A}$ ومتجه الأبعاد $\mathbf{x}$. للبدء، نتخيل المصفوفة matrix بدلالة متجهات الصف row vectors :

$$\mathbf{A} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_m^\top \end{bmatrix},$$

حيث كل $\mathbf{a}_i^\top \in \mathbb{R}^n$ هو متجه صف يمثل i^{th} صف المصفوفة $\mathbf{A}$.

حاصل ضرب المصفوفة المتجه $\mathbf{Ax}$ هو ببساطة متجه طول العمود m ، الذي يكون عنصره i^{th} هو حاصل الضرب النقطي $\mathbf{a}_i^\top \mathbf{x}$:

$$\mathbf{Ax} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_m^\top \end{bmatrix} \mathbf{x} = \begin{bmatrix} \mathbf{a}_1^\top \mathbf{x} \\ \mathbf{a}_2^\top \mathbf{x} \\ \vdots \\ \mathbf{a}_m^\top \mathbf{x} \end{bmatrix}.$$

يمكننا أن نفكرفي الضرب بمصفوفة $\mathbf{A} \in \mathbb{R}^{m \times n}$ كتحويل يُسقط المتجهات منه $\mathbb{R}^n$ إلى $\mathbb{R}^m$. هذه التحولات مفيدة بشكل ملحوظ. على سبيل المثال، يمكننا تمثيل عمليات التدوير على أنها عمليات ضرب بواسطة مصفوفات مربعة معينة. تصف حاصل ضرب Matrix-vector أيضًا الحساب الأساسي المتضمنفي حساب مخرجات كل طبقةفي الشبكة العصبية بالنظر إلى مخرجات الطبقة السابقة.

للتعبير عن حاصل المصفوفة_المتجهفي الكود، نستخدم دالة `matvec`. لاحظ أن بُعد العمود `A` (طوله على طول المحور 1) يجب أن يكون هو نفسه بُعد `x` (طوله).

```
A.shape, x.shape, tf.linalg.matvec(A, x)
```

```
(TensorShape([2, 3]),
 TensorShape([3]),
 <tf.Tensor: shape=(2,), dtype=float32, numpy=array([
5., 14.], dtype=float32)>)
```

2.3.10. ضرب المصفوفة – المصفوفة Matrix–Matrix Multiplication

إذا كنت قد حصلت على تعليق حاصل الضرب النقطي وضرب المصفوفة–المتجه، فيجب أن يكون ضرب المصفوفة–المصفوفة أمرًا سهلاً.

قل إن لدينا مصفوفتين $\mathbf{A} \in \mathbb{R}^{n \times k}$ و $\mathbf{B} \in \mathbb{R}^{k \times m}$:

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1k} \\ a_{21} & a_{22} & \cdots & a_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nk} \end{bmatrix}, \mathbf{B} = \begin{bmatrix} b_{11} & b_{12} & \cdots & b_{1m} \\ b_{21} & b_{22} & \cdots & b_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ b_{k1} & b_{k2} & \cdots & b_{km} \end{bmatrix}.$$

افترض $\mathbf{a}_i^\top \in \mathbb{R}^k$ تشير إلى متجه الصف row vector الذي يمثل i^{th} صف المصفوفة $\mathbf{A}$ ودعنا $\mathbf{b}_j \in \mathbb{R}^k$ تشير إلى متجه العمود من j^{th} عمود المصفوفة $\mathbf{B}$:

$$\mathbf{A} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_n^\top \end{bmatrix}, \mathbf{B} = [\mathbf{b}_1 \quad \mathbf{b}_2 \quad \cdots \quad \mathbf{b}_m].$$

لإيجاد حاصل ضرب المصفوفة $\mathbf{C} \in \mathbb{R}^{n \times m}$، نقوم ببساطة بحساب كل عنصر c_{ij} على أنه حاصل الضرب النقطي بين i^{th} صف لـ $\mathbf{A}$ وصف j^{th} لـ $\mathbf{B}$، أي $\mathbf{a}_i^\top \mathbf{b}_j$:

$$\mathbf{C} = \mathbf{AB} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_n^\top \end{bmatrix} [\mathbf{b}_1 \quad \mathbf{b}_2 \quad \cdots \quad \mathbf{b}_m] = \begin{bmatrix} \mathbf{a}_1^\top \mathbf{b}_1 & \mathbf{a}_1^\top \mathbf{b}_2 & \cdots & \mathbf{a}_1^\top \mathbf{b}_m \\ \mathbf{a}_2^\top \mathbf{b}_1 & \mathbf{a}_2^\top \mathbf{b}_2 & \cdots & \mathbf{a}_2^\top \mathbf{b}_m \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}_n^\top \mathbf{b}_1 & \mathbf{a}_n^\top \mathbf{b}_2 & \cdots & \mathbf{a}_n^\top \mathbf{b}_m \end{bmatrix}.$$

يمكننا التفكير في ضرب المصفوفة–المصفوفة $\mathbf{AB}$ على أنه حاصل ضرب مصفوفة متجهية أو ضرب نقطي $m \times n$ وربط النتائج معًا لتشكيل مصفوفة $n \times m$. في المقتطف التالي، نقوم بضرب المصفوفة على A و B. هنا، A عبارة عن مصفوفة تتكون من صفين و3 أعمدة، و B عبارة عن مصفوفة مكونة من 3 صفوف و 4 أعمدة. بعد الضرب، نحصل على مصفوفة من صفين و4 أعمدة.

```
B = tf.ones((3, 4), tf.float32)
tf.matmul(A, B)
```

```
<tf.Tensor: shape=(2, 4), dtype=float32, numpy=
```

```
array([[ 3.,  3.,  3.,  3.],
       [12., 12., 12., 12.]], dtype=float32)>
```

غالبًا ما يتم تبسيط مصطلح ضرب المصفوفة–المصفوفة إلى ضرب المصفوفة matrix multiplication، ويجب عدم الخلط بينه وبين ضرب Hadamard.

2.3.11. المعيار Norms

بعض العوامل الأكثر فائدةفي الجبر الخطي هي المعيار Norm. بشكل غير رسمي، يخبرنا المعيار المتجه عن حجمه. على سبيل المثال، يقيس المعيار ell_2 الطول (الإقليدي) للمتجه. هنا، نحن نستخدم مفهوم الحجم size الذي يتعلق بحجم مكونات المتجه (وليس أبعاده).

المعيار هو دالة $\|\cdot\|$ تقوم بتعيين متجه vector إلى رقمي scalar وتفي بالخصائص الثلاث التالية:

1. بالنظر إلى أي متجه $\mathbf{x}$ ، إذا قمنا بقياس (جميع عناصر) المتجه بواسطة قيمة قياسية scalar، فسيتم قياس معياره وفقًا لذلك:

$$\|\alpha\mathbf{x}\| = |\alpha|\|\mathbf{x}\|.$$

2. لأي متجهات $\mathbf{x}$ و$\mathbf{y}$: المعايير norms ترضي متباينة المثلث triangle inequality:

$$\|\mathbf{x} + \mathbf{y}\| \leq \|\mathbf{x}\| + \|\mathbf{y}\|.$$

3. معيار المتجه norm of a vector غير سالب ويختفي فقط إذا كان المتجه صفرًا:

$$\|\mathbf{x}\| > 0 \text{ for all } \mathbf{x} \neq 0.$$

العديد من الدوال هي معايير صالحة ومعايير مختلفة تقوم بترميز مفاهيم مختلفة الحجم. المعيار الإقليدية Euclidean norm التي تعلمناها جميعًافي هندسة المدرسة الابتدائية عند حساب وتر المثلث الأيمن هي الجذر التربيعي لمجموع مربعات عناصر المتجه. رسميًا، هذا يسمى المعيار ℓ_2 ويتم التعبير عنه كـ:

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^{n} x_i^2}.$$

طريقة المعيار تحسب المعيار ℓ_2.

```
u = tf.constant([3.0, -4.0])
tf.norm(u)
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=5.0>
```

معيار ℓ_1 شائع أيضًا ويسمى المقياس المرتبط بمسافة مانهاتن Manhattan distance. بحكم التعريف، يجمع المعيار ℓ_1 القيم المطلقة لعناصر المتجه:

$$\|\mathbf{x}\|_1 = \sum_{i=1}^{n} |x_i|.$$

بالمقارنة مع المعيار ℓ_2 ، فهي أقل حساسية للقيم المتطرفة outliers. لحساب المعيار ℓ_1، نقوم بتكوين القيمة المطلقة باستخدام عملية الجمع.

```
tf.reduce_sum(tf.abs(u))
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=7.0>
```

كل من المعيار ℓ_2 والمعيار ℓ_1 هي حالات خاصة للمعايير الأكثر عمومية ℓ_p:

$$\|\mathbf{x}\|_p = \left(\sum_{i=1}^{n} |x_i|^p\right)^{\frac{1}{p}}.$$

في حالة المصفوفات، تكون الأمور أكثر تعقيداً. بعد كل شيء، يمكن النظر إلى المصفوفات كمجموعات من الإدخالات الفردية وككائنات تعمل على المتجهات وتحولها إلى متجهات أخرى. على سبيل المثال، يمكننا أن نسأل إلى أي مدى يمكن أن يكون حاصل ضرب المصفوفة ـ المتجه $\mathbf{Xv}$ مرتبط بـ $\mathbf{v}$. هذا الخط الفكري يؤدي إلى معيار يسمى المعيار الطيفي spectral norm.في الوقت الحالي، نقدم معيار Frobenius، والذي يسهل حسابه ويتم تعريفه على أنه الجذر التربيعي لمجموع مربعات عناصر المصفوفة:

$$\|\mathbf{X}\|_F = \sqrt{\sum_{i=1}^{m} \sum_{j=1}^{n} x_{ij}^2}.$$

يتصرف معيار Frobenius كما لو كان معيارًا ℓ_2 لمتجه على شكل مصفوفة. سيؤدي استدعاء الدالة التالية إلى حساب قاعدة Frobenius للمصفوفة.

```
tf.norm(tf.ones((4, 9)))
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=6.0>
```

بينما لا نريد أن نتقدم كثيرًا على أنفسنا، يمكننا زرع بعض الحدس بالفعل حول سبب فائدة هذه المفاهيم.في التعلم العميق، نحاول غالبًا حل مشكلات التحسين optimization problems: تعظيم maximize الاحتمال المخصص للبيانات المرصودة observed data؛ تعظيم الإيرادات المرتبطة بنموذج التوصية؛ تقليل المسافة بين التنبؤات وأرصاد القيم الحقيقية ground-truth ؛ تقليل minimize المسافة بين تمثيلات صور الشخص نفسه مع تعظيم المسافة بين تمثيلات الصور لأشخاص مختلفين. غالبًا ما يتم التعبير عن هذه المسافات، التي تشكل أهداف خوارزميات التعلم العميق، كمعايير norms.

2.3.12. المناقشة

في هذا القسم، راجعنا جميع الجبر الخطي الذي ستحتاجه لفهم جزء كبير من التعلم العميق الحديث. هناك الكثير من الجبر الخطي والكثير منه مفيد للتعلم الآلي. على سبيل المثال، يمكن أن تتحلل المصفوفات إلى عوامل factors، ويمكن أن تكشف هذه التحليلات عن بنية منخفضة الأبعادفي مجموعات البيانات الواقعية. هناك حقول فرعية كاملة للتعلم الآلي تركز على استخدام تحليلات المصفوفة وتعميماتها على الموترات عالية الترتيب لاكتشاف البنيةفي مجموعات البيانات وحل مشاكل التنبؤ. لكن هذا الكتاب يركز على التعلم العميق. ونعتقد أنك ستكون أكثر ميلًا لتعلم المزيد من الرياضيات بمجرد أن تتسخ يديك عند تطبيق التعلم الآلي على مجموعات بيانات حقيقية. لذلك بينما نحتفظ بالحقفي تقديم المزيد من الرياضيات لاحقًا، فإننا نختتم هذا القسم هنا.

إذا كنت حريصًا على تعلم المزيد من الجبر الخطي، فهناك العديد من الكتب والموارد الممتازة عبر الإنترنت. للحصول على دورة مكثفة أكثر تقدمًا ، ضعفي اعتبارك التحقق (Kolter, 2008, Petersen *et al.*, 2008, Strang, 1993)

الخلاصة:

- القيم القياسية scalars والمتجهات vectors والمصفوفات matrices والموترات tensors هي الكائنات الرياضية الأساسية المستخدمةفي الجبر الخطي ولها عدد من المحاور صفر وواحد واثنان وعدد عشوائي من المحاور، على التوالي.
- يمكن تقطيع أو تقليل الموترات على طول محاور محددة من خلال الفهرسة، أو عمليات مثل المجموع والمتوسط، على التوالي.
- تسمى حاصل الضرب الأولي Elementwise products حاصل ضرب Hadamard. على النقيض من ذلك، فإن الضرب النقطي وحاصل ضرب المصفوفة–المتجه وضرب المصفوفة–المصفوفة ليست عمليات عنصرية elementwise operations وفي العموم تُرجع الكائنات التي لها أشكال مختلفة عن المعاملات.
- مقارنة بحاصل ضرب Hadamard، يستغرق ضرب المصفوفة–المصفوفة وقتًا أطول بكثير للحساب (الوقت المكعب بدلاً من الوقت التربيعي).
- تلتقط المعايير Norms المفاهيم المختلفة لحجم المتجه magnitude of a vector، ويتم تطبيقها بشكل شائع على الفرق بين متجهين لقياس المسافة بينهما.
- تتضمن معايير المتجه الشائعة المعيار ℓ_1 والمعيار ℓ_2 ، وتشمل معايير المصفوفة المشتركة المعايير الطيفية ومعايير Frobenius.

2.3.13. التمارين

1. اثبت أن مدور transpose لمدور المصفوفة هو المصفوفة نفسها: $(\mathbf{A}^\top)^\top = \mathbf{A}$.
2. بالنظر إلى مصفوفتين $\mathbf{A}$ و $\mathbf{B}$، اثبت ان sum وcommute transposition: $\mathbf{A}^\top + \mathbf{B}^\top = (\mathbf{A} + \mathbf{B})^\top$.
3. بالنظر إلى أي مصفوفة مربعة $\mathbf{A}$، هل $\mathbf{A} + \mathbf{A}^\top$ دائمًا متماثل symmetric؟ هل يمكنك إثبات النتيجة باستخدام نتيجة التمرينين السابقين فقط؟
4. حددنا موتر X للشكل (2, 3, 4)في هذا القسم. ما هو خرج `len(X)`اكتب إجابتك دون تنفيذ أي كود، ثم تحقق من إجابتك باستخدام الكود.
5. بالنسبة للموتر X ذي الشكل التعسفي، هل يتوافق `len(X)` دائمًا مع طول محور معين من X؟ ما هذا المحور؟
6. قم بتنفيذ `A / A.sum(axis=1)` وشاهد ما سيحدث. هل يمكنك تحليل السبب؟
7. عند السفر بين نقطتينفي وسط مانهاتن، ما هي المسافة التي يتعين عليك قطعها من حيث الإحداثيات، أي من حيث السبل والشوارع؟ هل يمكنك السفر قطريا؟
8. ضعفي اعتبارك موتر ذو شكل (2, 3, 4). ما هي أشكال مخرجات الجمع على طول المحور 0 و 1 و 2؟
9. قم بتغذية موتر بثلاثة محاور أو أكثر لدالة `linalg.norm` وراقب ناتجها. ماذا تحسب هذه الدالة لموترات الشكل التعسفي؟
10. حدد ثلاث مصفوفات كبيرة، على سبيل المثال $\mathbf{A} \in \mathbb{R}^{2^{10} \times 2^{16}}$، $\mathbf{B} \in \mathbb{R}^{2^{16} \times 2^5}$و $\mathbf{C} \in \mathbb{R}^{2^5 \times 2^{14}}$ على سبيل المثال تم تهيئتها باستخدام متغيرات عشوائية غاوسية Gaussian random variables. تريد حساب المنتج $\mathbf{ABC}$. هل هناك أي اختلاففي مساحة الذاكرة وسرعتها، اعتمادًا على ما إذا كنت تقوم بحساب $(\mathbf{AB})\mathbf{C}$ أم $\mathbf{A}(\mathbf{BC})$. لماذا؟
11. حدد ثلاث مصفوفات كبيرة، على سبيل المثال $\mathbf{A} \in \mathbb{R}^{2^{10} \times 2^{16}}$، $\mathbf{B} \in \mathbb{R}^{2^{16} \times 2^5}$و $\mathbf{C} \in \mathbb{R}^{2^5 \times 2^{16}}$. هل هناك أي اختلاففي السرعة حسب ما إذا كنت تقوم بحساب $\mathbf{AB}$ أم $\mathbf{AC}^\top$؟ لماذا ا؟ ما الذي يتغير إذا قمت بتهيئة $\mathbf{C} = \mathbf{B}^\top$ بدون استنساخ الذاكرة cloning memory؟ لماذا؟
12. حدد ثلاث مصفوفات، على سبيل المثال $\mathbf{A}, \mathbf{B}, \mathbf{C} \in \mathbb{R}^{100 \times 200}$. تشكيل موتر مع 3 محاور عن طريق تكديس $[\mathbf{A}, \mathbf{B}, \mathbf{C}]$. ما هي الأبعاد؟ اقطع Slice الإحداثي الثاني للمحور الثالث لاسترجاع $\mathbf{B}$. تحقق من صحة إجابتك.

2.4 التفاضل والتكامل Calculus

لفترة طويلة، ظلت كيفية حساب مساحة الدائرة لغزاً. بعد ذلك، جاء عالم الرياضيات اليوناني القديم أرخميدس بفكرة ذكية لتسجيل سلسلة من المضلعات مع زيادة أعداد الرؤوس داخل دائرة (الشكل 2.4.1). بالنسبة إلى المضلع ذي الرؤوس n، نحصل على مثلثات n. يقترب ارتفاع كل مثلث من نصف القطر r لأننا نقسم الدائرة بشكل أكثر دقة.في نفس الوقت، تقترب قاعدتها $\frac{2\pi r}{n}$، لأن النسبة بين القوس والقاطع تقترب من 1 لعدد كبير من الرؤوس. وبالتالي، فإن مساحة المثلث تقترب $n \cdot r \cdot \frac{1}{2}\left(\frac{2\pi r}{n}\right) = \pi r^2$.

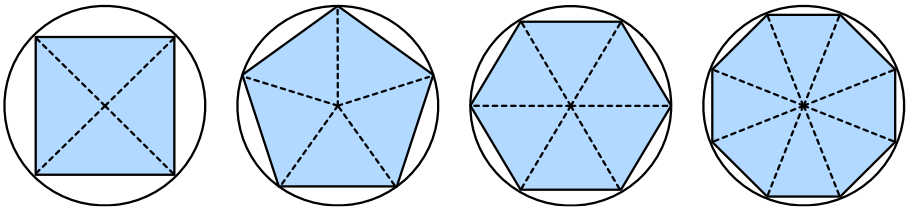

الشكل 2.4.1 إيجاد مساحة الدائرة كإجراء نهائي.

يؤدي هذا الإجراء المحدد إلى حساب التفاضل والتكامل التفاضلي (القسم 19.5). يمكن أن يخبرنا الأول عن كيفية زيادة قيمة دالة أو إنقاصها من خلال معالجة وسيطاتها. يكون هذا مفيداً لمشاكل التحسين التي نواجههافي التعلم العميق، حيث نقوم بتحديث معلماتنا بشكل متكرر لتقليل دالة الخطأ. يعالج التحسين كيفية ملاءمة (fit) نماذجنا لبيانات التدريب، وحساب التفاضل والتكامل calculus هو شرطه الأساسي. ومع ذلك، لا تنس أن هدفنا النهائي هو الأداء الجيد على البيانات غير المرئية من قبل unseen data. هذه المشكلة تسمى التعميم generalization وستكون محور التركيز الرئيسي للفصول الأخرى.

2.4.1. المشتقات والتفاضل Derivatives and Differentiation

ببساطة، المشتق derivative هو معدل التغييرفي دالة فيما يتعلق بالتغيراتفي مدخلاتها arguments. يمكن للمشتقات أن تخبرنا عن مدى سرعة زيادة دالة الخطأ أو نقصانها إذا قمنا بزيادة أو تقليل كل معلمة بمقدار ضئيل للغاية. بشكل رسمي، بالنسبة للدوال $f: \mathbb{R} \to \mathbb{R}$، تلك الخريطة من القيم القياسية scalars إلى القيم القياسية scalars، يتم تعريف مشتق f عند نقطة xعلى أنه

$$f'(x) = \lim_{h \to 0} \frac{f(x+h) - f(x)}{h}.$$

يسمى هذا المصطلح الموجود على الجانب الأيمن بالغاية limit ويخبرنا بما يحدث لقيمة التعبير عندما يقترب المتغير المحدد من قيمة معينة. يخبرنا هذا الحد بما تتقارب فيه النسبة بين الاضطراب h والتغيرفي قيمة الدالة $f(x+h)-f(x)$ كلما قلصنا حجمها إلى الصفر.

عندما يكون $f'(x)$ موجودًا، يُقال إنه قابل للتفاضل differentiable عند x؛ وعندما $f'(x)$ يكون موجودًا لجميع xفي مجموعة، على سبيل المثال، الفترة $[a,b]$ ، نقول أن fهذا قابل للتفاضلفي هذه المجموعة. ليست كل الدوال قابلة للتفاضل، بمافي ذلك العديد من الدوال التي نرغبفي تحسينها، بمافي ذلك الدقة والمنطقة الواقعة تحت خاصية التشغيل المستقبلة (AUC). ومع ذلك، نظرًا لأن حساب مشتق الخسارة يعد خطوة حاسمةفي جميع الخوارزميات تقريبًا لتدريب الشبكات العصبية العميقة، فإننا غالبًا ما نقوم بتحسين بديل قابل للتفاضل بدلاً من ذلك.

يمكننا تفسير المشتق $f'(x)$ على أنه معدل اللحظي instantaneous rate للتغير بالنسبة لـ $f(x)$. دعونا نطور بعض الحدس بمثال. حدد $u=f(x)=3x^2-4x$.

```
%matplotlib inline
import numpy as np
from matplotlib_inline import backend_inline
from d2l import tensorflow as d2l


def f(x):
    return 3 * x ** 2 - 4 * x
```

ضبط $\frac{f(x+h)-f(x)}{h}$ ، النهج 2 كنهج 0. بينما تفتقر هذه التجربة إلى صرامة إثبات رياضي، سنرى ذلك قريبًا بالفعل $f'(1)=2$.

```
for h in 10.0**np.arange(-1, -6, -1):
    print(f'h={h:.5f}, numerical limit={(f(1+h)-
f(1))/h:.5f}')
```

```
h=0.10000, numerical limit=2.30000
h=0.01000, numerical limit=2.03000
h=0.00100, numerical limit=2.00300
h=0.00010, numerical limit=2.00030
h=0.00001, numerical limit=2.00003
```

هناك العديد من الاصطلاحات الترميزية المكافئة للمشتقات. معطى$y=f(x)$ ، العبارات التالية متكافئة:

$$f'(x)=y'=\frac{dy}{dx}=\frac{df}{dx}=\frac{d}{dx}f(x)=Df(x)=D_xf(x),$$

حيث الرموز $\frac{d}{dx}$ و D هم عوامل التفاضل differentiation operators. أدناه، نقدم مشتقات بعض الدوال الشائعة:

$$\begin{aligned}
\frac{d}{dx}C &= 0 && \text{for any constant } C \\
\frac{d}{dx}x^n &= nx^{n-1} && \text{for } n \neq 0 \\
\frac{d}{dx}e^x &= e^x \\
\frac{d}{dx}\ln x &= x^{-1}
\end{aligned}$$

غالبًا ما تكون الدوال المكونة من دوال قابلة للتفاضل قابلة للتفاضل. القواعد التالية مفيدة للعمل مع تراكيب أي دوال قابلة للتفاضل f و g وثابت C.

$$\begin{aligned}
\frac{d}{dx}[Cf(x)] &= C\frac{d}{dx}f(x) && \text{Constant multiple rule} \\
\frac{d}{dx}[f(x)+g(x)] &= \frac{d}{dx}f(x)+\frac{d}{dx}g(x) && \text{Sum rule} \\
\frac{d}{dx}[f(x)g(x)] &= f(x)\frac{d}{dx}g(x)+g(x)\frac{d}{dx}f(x) && \text{Product rule} \\
\frac{d}{dx}\frac{f(x)}{g(x)} &= \frac{g(x)\frac{d}{dx}f(x)-f(x)\frac{d}{dx}g(x)}{g^2(x)} && \text{Quotient rule}
\end{aligned}$$

باستخدام هذا، يمكننا تطبيق القواعد لإيجاد مشتقة $3x^2-4x$ عبر:

$$\frac{d}{dx}[3x^2-4x] = 3\frac{d}{dx}x^2-4\frac{d}{dx}x = 6x-4.$$

يُظهر التوصيل $x=1$ أن المشتق 2 موجود بالفعل في هذا المكان. لاحظ أن المشتقات تخبرنا عن ميل slope الدالة في موقع معين.

2.4.2. أدوات الرسم Visualization Utilities

يمكننا رسم ميل الدوال باستخدام مكتبة `matplotlib`. نحن بحاجة إلى تحديد بعض الدوال. كما يشير اسمه، فإن `use_svg_display` تخبر `matplotlib` بإخراج الرسومات بتنسيق SVG للحصول على صور أكثر وضوحًا. التعليق `#@save` هو مُعدِّل modifier خاص يسمح لنا بحفظ أي دالة أو فئة أو كتلة رمز أخرى في حزمة `d2l` حتى نتمكن من استدعاؤها لاحقًا دون تكرار الكود ، على سبيل المثال ، عبر `d2l.use_svg_display()`.

```
def use_svg_display():  #@save
    """Use the svg format to display a plot in
Jupyter."""
    backend_inline.set_matplotlib_formats('svg')
```

بشكل ملائم، يمكننا تعيين أحجام الشكل باستخدام set_figsize. نظرًا لأن بيان الاستيراد import من matplotlib import pyplot as plt حيث تم تمييز plt عبر #@save via في حزمة d2l، يمكننا استدعاء d2l.plt.

```
def set_figsize(figsize=(3.5, 2.5)):  #@save
    """Set the figure size for matplotlib."""
    use_svg_display()
    d2l.plt.rcParams['figure.figsize'] = figsize
```

يمكن أن تربط الدالة set_axes المحاور بالخصائص، بمافي ذلك التسميات labels والنطاقات ranges والمقاييس scales.

```
#@save
def set_axes(axes, xlabel, ylabel, xlim, ylim, xscale,
yscale, legend):
    """Set the axes for matplotlib."""
    axes.set_xlabel(xlabel), axes.set_ylabel(ylabel)
    axes.set_xscale(xscale), axes.set_yscale(yscale)
    axes.set_xlim(xlim),     axes.set_ylim(ylim)
    if legend:
        axes.legend(legend)
    axes.grid()
```

باستخدام هذه الدوال الثلاث، يمكننا تحديد دالة الرسم plot لتراكب منحنيات متعددة. جزء كبير من الكود هنا هو مجرد ضمان تطابق أحجام وأشكال المدخلات.

```
#@save
def plot(X, Y=None, xlabel=None, ylabel=None, legend=[],
xlim=None,
         ylim=None, xscale='linear', yscale='linear',
         fmts=('-', 'm--', 'g-.', 'r:'), figsize=(3.5,
2.5), axes=None):
    """Plot data points."""

    def has_one_axis(X):  # True if `X` (tensor or list)
has 1 axis
        return (hasattr(X, "ndim") and X.ndim == 1 or
isinstance(X, list)
                and not hasattr(X[0], "__len__"))
```

```
    if has_one_axis(X): X = [X]
    if Y is None:
        X, Y = [[]] * len(X), X
    elif has_one_axis(Y):
        Y = [Y]
    if len(X) != len(Y):
        X = X * len(Y)

    set_figsize(figsize)
    if axes is None: axes = d2l.plt.gca()
    axes.cla()
    for x, y, fmt in zip(X, Y, fmts):
        axes.plot(x,y,fmt) if len(x) else
axes.plot(y,fmt)
    set_axes(axes, xlabel, ylabel, xlim, ylim, xscale,
yscale, legend)
```

الآن يمكننا رسم الدالة $u = f(x)$ وخط المماس tangent line الخاص بها $y = 2x - 3$ عند $x = 1$، حيث المعامل هو ميل خط المماس slope of the tangent line.

```
x = np.arange(0, 3, 0.1)
plot(x, [f(x), 2 * x - 3], 'x', 'f(x)', legend=['f(x)',
'Tangent line (x=1)'])
```

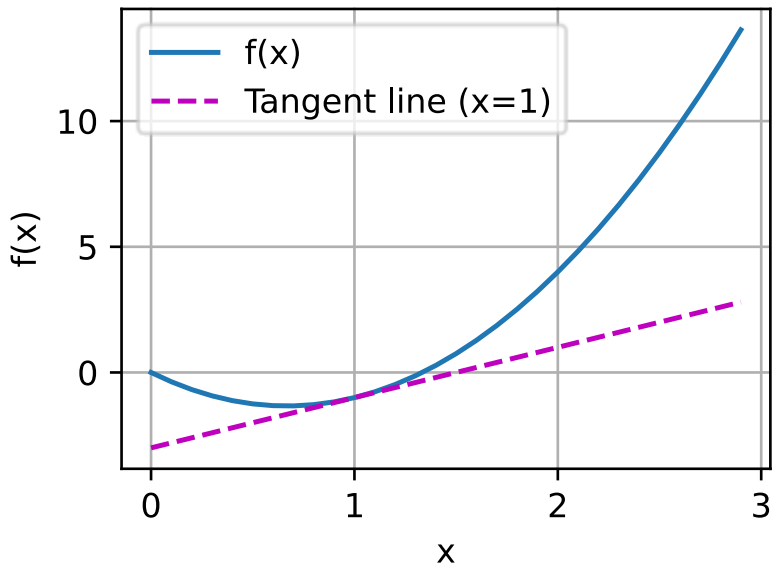

2.4.3. المشتقات الجزئية والتدرجات Partial Derivatives and Gradients

حتى الآن، كنا نفرق بين دوال متغير واحد فقط. في التعلم العميق، نحتاج أيضًا إلى العمل مع دوال العديد من المتغيرات. نقدم بإيجاز مفاهيم المشتق التي تنطبق على مثل هذه الدوال متعددة المتغيرات multivariate functions.

لتكن $y = f(x_1, x_2, \ldots, x_n)$ ان تكون دالة مع n من المتغيرات. المشتق الجزئي partial derivative لـ y فيما يتعلق بمعاملته i^{th} هو

$$\frac{\partial y}{\partial x_i} = \lim_{h \to 0} \frac{f(x_1, \ldots, x_{i-1}, x_i + h, x_{i+1}, \ldots, x_n) - f(x_1, \ldots, x_i, \ldots, x_n)}{h}.$$

لحساب $\frac{\partial y}{\partial x_i}$، يمكننا التعامل مع $x_1, \ldots, x_{i-1}, x_{i+1}, \ldots, x_n$ على أنها ثوابت ونحسب مشتقة y بالنسبة إلى x. تعد اصطلاحات الترميز التالية للمشتقات الجزئية شائعة وكلها تعني نفس الشيء:

$$\frac{\partial y}{\partial x_i} = \frac{\partial f}{\partial x_i} = \partial_{x_i} f = \partial_i f = f_{x_i} = f_i = D_i f = D_{x_i} f.$$

يمكننا ربط المشتقات الجزئية partial derivatives لدالة متعددة المتغيرات multivariate فيما يتعلق بجميع متغيراتها للحصول على متجه يسمى تدرج الدالة gradient of the function. لنفترض أن مدخلات الدالة $f: \mathbb{R}^n \to \mathbb{R}$ عبارة عن متجه ذي أبعاد $\mathbf{x} = [x_1, x_2, \ldots, x_n]^\top$ وأن الناتج عبارة عن قيمة قياسية scalar. انحدار الدالة f بالنسبة إلى $\mathbf{x}$ متجه للمشتقات الجزئية:

$$\nabla_{\mathbf{x}} f(\mathbf{x}) = \left[\partial_{x_1} f(\mathbf{x}), \partial_{x_2} f(\mathbf{x}), \ldots \partial_{x_n} f(\mathbf{x})\right]^\top.$$

عندما لا يكون هناك غموض no ambiguity، $\nabla_{\mathbf{x}} f(\mathbf{x})$ عادة ما يتم استبداله بـ $\nabla f(\mathbf{x})$. القواعد التالية مفيدة للتمييز بين الدوال متعددة المتغيرات:

- لكل $\mathbf{A} \in \mathbb{R}^{m \times n}$ ما لدينا $\nabla_{\mathbf{x}} \mathbf{A}\mathbf{x} = \mathbf{A}^\top$ و $\nabla_{\mathbf{x}} \mathbf{x}^\top \mathbf{A} = \mathbf{A}$.
- بالنسبة للمصفوفات المربعة $\mathbf{A} \in \mathbb{R}^{n \times n}$ ، لدينا ذلك $\nabla_{\mathbf{x}} \mathbf{x}^\top \mathbf{A}\mathbf{x} = (\mathbf{A} + \mathbf{A}^\top)\mathbf{x}$ وعلى وجه الخصوص $\nabla_{\mathbf{x}} \|\mathbf{x}\|^2 = \nabla_{\mathbf{x}} \mathbf{x}^\top \mathbf{x} = 2\mathbf{x}$.

وبالمثل، لدينا $\nabla_{\mathbf{X}} \|\mathbf{X}\|_F^2 = 2\mathbf{X}$ لأي مصفوفة $\mathbf{X}$.

2.4.4. قاعدة السلسلة Chain Rule

في التعلم العميق، غالبًا ما يصعب حساب التدرجات gradients ذات الاهتمام لأننا نعمل مع دوال متداخلة بعمق (دوال (دوال ...)). لحسن الحظ، تهتم قاعدة السلسلة Chain Rule بهذا الأمر. بالعودة إلى دوال متغير واحد، افترض أن $y = f(g(x))$ والدوال الأساسية $y = f(u)$ و$u = g(x)$ كلاهما قابل للتفاضل. تنص قاعدة السلسلة على ذلك

$$\frac{dy}{dx} = \frac{dy}{du}\frac{du}{dx}.$$

بالعودة إلى الدوال متعددة المتغيرات multivariate functions، افترض أن $y = f(\mathbf{u})$ لها متغيرات $u_1, u_2, \ldots, u_m$ ، حيث لكل $u_i = g_i(\mathbf{x})$ منها متغيرات $x_1, x_2, \ldots, x_n$ ، أي. ثم تنص قاعدة السلسلة على ذلك

$$\frac{\partial y}{\partial x_i} = \frac{\partial y}{\partial u_1}\frac{\partial u_1}{\partial x_i} + \frac{\partial y}{\partial u_2}\frac{\partial u_2}{\partial x_i} + \cdots + \frac{\partial y}{\partial u_m}\frac{\partial u_m}{\partial x_i} \text{ and thus } \nabla_{\mathbf{x}} y = \mathbf{A}\nabla_{\mathbf{u}} y,$$

حيث $\mathbf{A} \in \mathbb{R}^{n \times m}$ هي مصفوفة تحتوي على مشتق المتجه $\mathbf{u}$ فيما يتعلق بالمتجه $\mathbf{x}$. وبالتالي، فإن تقييم التدرج يتطلب حساب ضرب المصفوفة ـ المتجه. هذا هو أحد الأسباب الرئيسية التي تجعل الجبر الخطي لبنة أساسيةفي بناء أنظمة التعلم العميق.

2.4.5. المناقشة

على الرغم من أننا قد خدشنا للتو سطح موضوع عميق، فقد تم التركيز بالفعل على عدد من المفاهيم: أولاً، يمكن تطبيق قواعد تكوين التفاضل rules for differentiation بلا تفكير، مما يمكننا من حساب التدرجات gradients تلقائيًا. لا تتطلب هذه المهمة إبداعًا، وبالتالي يمكننا تركيز قوتنا المعرفيةفي مكان آخر. ثانيًا، يتطلب حساب مشتقات الدوال ذات القيمة المتجهية vector-valued functions مضاعفة المصفوفات بينما نتتبع الرسم البياني للتبعية للمتغيرات من المخرجات إلى المدخلات. على وجه الخصوص، يتم اجتياز هذا الرسم البياني في اتجاه أمامي عندما نقوم بتقييم دالة وفي اتجاه عكسي عندما نحسب التدرجات. ستقدم الفصول اللاحقة بشكل رسمي الانتشار الخلفي backpropagation، وهو إجراء حسابي لتطبيق قاعدة السلسلة chain rule.

من وجهة نظر التحسين optimization، تسمح لنا التدرجات gradients بتحديد كيفية تحريك معلمات النموذج لتقليل الخطأ، وستتطلب كل خطوة من خوارزميات التحسين المستخدمةفي هذا الكتاب حساب التدرج.

2.4.6. التمارين

1. حتى الآن أخذنا قواعد المشتقات كأمر مسلم به. باستخدام التعريف والغايات اثبت خصائص $f(x) = c$ (i) و $f(x) = x^n$ (ii) و $f(x) = e^x$ (iii) و $f(x) = \log x$ (iv).
2. على نفس المنوال، قم بإثبات قاعدة الضرب، المجموع، وحاصل القسمة من المبادئ الأولى.
3. إثبت أن قاعدة المضاعفات الثابتة constant multiple rule تتبع كحالة خاصة لقاعدة حاصل الضرب.
4. احسب مشتق $f(x) = x^x$.
5. ماذا يعني ذلك $f'(x) = 0$ بالنسبة لبعض x ؟ أعط مثالاً عن دالة f وموقع x قد يكون هذا مناسبًا لهما.
6. ارسم الدالة $y = f(x) = x^3 - \frac{1}{x}$ وارسم خط المماس الخاص بها عند $x = 1$.
7. أوجد انحدار (تدرج) الدالة $f(\mathbf{x}) = 3x_1^2 + 5e^{x_2}$.
8. هل يمكنك كتابة قاعدة السلسلة chain rule للحالة حيث $u = f(x, y, z)$ و $x = x(a, b)$ و $y = y(a, b)$ و $z = z(a, b)$ ؟
9. بالنظر إلى دالة $f(x)$ قابلة للعكس invertible، احسب مشتق معكوسها $f^{-1}(x)$. هنا لدينا ذلك $f^{-1}(f(x)) = x$ والعكس $f(f^{-1}(y)) = y$. تلميح: استخدم هذه الخصائص في اشتقاقك.

2.5 التفاضل التلقائي Automatic Differentiation

تذكر من القسم 2.4 أن حساب المشتقات هو الخطوة الحاسمة في جميع خوارزميات التحسين التي سنستخدمها لتدريب الشبكات العميقة. في حين أن الحسابات واضحة ومباشرة، إلا أن حسابها يدويًا يمكن أن يكون مملاً وعرضة للخطأ، وتزداد هذه المشكلة فقط عندما تصبح نماذجنا أكثر تعقيدًا.

لحسن الحظ، تعمل جميع أطر التعلم العميق الحديثة على إخراج هذا العمل من لوحاتنا من خلال تقديم التفاضل التلقائي Automatic Differentiation (غالبًا ما يتم اختصاره إلى autograd). بينما نقوم بتمرير البيانات عبر كل دالة متتالية، يقوم إطار العمل ببناء رسم بياني حسابي يتتبع كيف تعتمد كل قيمة على الآخرين. لحساب المشتقات، تعمل حزم التفاضل التلقائية في الاتجاه المعاكس من خلال هذا الرسم البياني بتطبيق قاعدة السلسلة. الخوارزمية الحسابية لتطبيق قاعدة السلسلة بهذه الطريقة تسمى الانتشار الخلفي backpropagation.

بينما أصبحت مكتبات autograd مصدر قلق ساخن خلال العقد الماضي، إلا أنها تتمتع بتاريخ طويل.في الواقع، تعود أقدم الإشارات إلى autograd إلى أكثر من نصف قرن (Wengert، 1964). تعود الأفكار الأساسية الكامنة وراء الانتشار الخلفي backpropagation الحديث إلى أطروحة دكتوراه من عام 1980 (Speelpenning، 1980) وتم تطويرها بشكل أكبرفي أواخر الثمانينيات (Griewank، 1989). بينما أصبح الانتشار الخلفي هو الأسلوب الافتراضي لحساب التدرجات gradients، فإنه ليس الخيار الوحيد. على سبيل المثال، تستخدم لغة برمجة جوليا Julia الانتشار الأمامي (Revels et al.، 2016). قبل استكشاف الطرق، دعنا نتقن أولاً استخدام حزمة autograd.

2.5.1. دالة بسيطة A Simple Function

لنفترض أننا مهتمون بالتفاضل بين الدالة $y = 2\mathbf{x}^\top\mathbf{x}$ فيما يتعلق بمتجه العمود $\mathbf{x}$. للبدء، نحدد `x` قيمة أولية.

```
import tensorflow as tf
```

```
x = tf.range(4, dtype=tf.float32)
x
```

```
<tf.Tensor: shape=(4,), dtype=float32, numpy=array([0.,
1., 2., 3.], dtype=float32)>
```

قبل أن نحسب الانحدار بالنسبة لـ y ، نحتاج إلى مكان لتخزين $\mathbf{x}$. بشكل عام، نتجنب تخصيص ذاكرة جديدةفي كل مرة نأخذ فيها أحد المشتقات لأن التعلم العميق يتطلب مشتقات حوسبية متتالية فيما يتعلق بنفس المعلمات آلاف أو ملايين المرات، وقد نخاطر بنفاد الذاكرة. لاحظ أن تدرج دالة ذات قيمة رقمية فيما يتعلق بالمتجه $\mathbf{x}$ لها قيمة متجهة ولها نفس الشكل $\mathbf{x}$.

```
x = tf.Variable(x)
```

نحسب الآن دالة `x` ونحسب النتيجة لـ `y`.

```
# Record all computations onto a tape
with tf.GradientTape() as t:
    y = 2 * tf.tensordot(x, x, axes=1)
y
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=28.0>
```

يمكننا الآن حساب انحدار `y` بالنسبة إلى `x` باستدعاء دالة الانحدار `gradient`.

```
x_grad = t.gradient(y, x)
x_grad
```

```
<tf.Tensor: shape=(4,), dtype=float32, numpy=array([ 0.,
4.,  8., 12.], dtype=float32)>
```

نحن نعلم بالفعل أن تدرج الدالة $y = 2\mathbf{x}^{\top}\mathbf{x}$ بالنسبة $\mathbf{x}$ إلى يجب أن يكون $4\mathbf{x}$. يمكننا الآن التحقق من تطابق حساب التدرج والنتيجة المتوقعة.

```
x_grad == 4 * x
```

```
<tf.Tensor: shape=(4,), dtype=bool, numpy=array([ True,
True,  True,  True])>
```

دعونا الآن نحسب دالة أخرى لـ x ونأخذ انحدارها. لاحظ أن TensorFlow يعيد تعيين المخزن المؤقت للتدرج كلما سجلنا تدرجًا جديداً.

```
with tf.GradientTape() as t:
    y = tf.reduce_sum(x)
t.gradient(y, x)  # Overwritten by the newly calculated
gradient
```

```
<tf.Tensor: shape=(4,), dtype=float32, numpy=array([1.,
1., 1., 1.], dtype=float32)>
```

2.5.2. عكسياً بالنسبة للمتغيرات غير العددية Backward for Non-Scalar Variables

عندما تكون y متجهًا، فإن التفسير الأكثر طبيعية لمشتق y بالنسبة إلى المتجه x هو مصفوفة تسمى Jacobian تحتوي على المشتقات الجزئية لكل مكون من y بالنسبة إلى كل مكون من مكونات x. وبالمثل، بالنسبة إلى y و x ذات الترتيب الأعلى، يمكن أن تكون نتيجة الاشتقاق موترًا أعلى رتبة higher-order tensor.

بينما يظهر Jacobian في بعض تقنيات التعلم الآلي المتقدمة ، فإننا نريد بشكل أكثر شيوعًا تلخيص تدرجات كل مكون من مكونات y فيما يتعلق بالمتجه الكامل x ، مما ينتج عنه متجه من نفس الشكل مثل x. على سبيل المثال ، غالبًا ما يكون لدينا متجه يمثل قيمة دالة الخطأ لدينا محسوبة بشكل منفصل لكل مجموعة من أمثلة التدريب. هنا، نريد فقط تلخيص التدرجات المحسوبة بشكل فردي لكل مثال.

بشكل افتراضي، يُرجع TensorFlow تدرج المجموع. بمعنى آخر، بدلاً من إرجاع Jacobian $\partial_{\mathbf{x}}\mathbf{y}$ ، فإنه يُرجع تدرج المجموع $\partial_{\mathbf{x}}\sum_i y_i$.

```
with tf.GradientTape() as t:
    y = x * x
t.gradient(y, x)  # Same as `y = tf.reduce_sum(x * x)`
```

```
<tf.Tensor: shape=(4,), dtype=float32, numpy=array([0.,
2., 4., 6.], dtype=float32)>
```

2.5.3. فصل الحساب Detaching Computation

في بعض الأحيان، نرغب في نقل بعض الحسابات خارج الرسم البياني الحسابي المسجل. على سبيل المثال، لنفترض أننا نستخدم المدخلات لإنشاء بعض المصطلحات الوسيطة المساعدة التي لا نريد حساب التدرج لها. في هذه الحالة، نحتاج إلى فصل detach الرسم البياني للتأثير الحسابي عن النتيجة النهائية. يوضح مثال اللعبة التالي هذا الأمر بشكل أوضح: افترض أن لدينا y = x * x و z = x * y لكننا نريد التركيز على التأثير المباشر لـ x على z بدلاً من التأثير المنقول عبر y. في هذه الحالة، يمكننا إنشاء متغير جديد u يأخذ نفس قيمة y ولكن مصدره (كيف تم إنشاؤه) قد تم محوه. وبالتالي، ليس لدى u أسلاف في الرسم البياني والتدرجات لا تتدفق عبر u إلى x. على سبيل المثال، سيؤدي أخذ التدرج لـ z = x * u إلى الحصول على النتيجة x، (وليس 3 * x * x كما كنت تتوقع منذ z = x * x * x).

```
# Set `persistent=True` to preserve the compute graph.
# This lets us run `t.gradient` more than once
with tf.GradientTape(persistent=True) as t:
    y = x * x
    u = tf.stop_gradient(y)
    z = u * x

x_grad = t.gradient(z, x)
x_grad == u
```

```
<tf.Tensor: shape=(4,), dtype=bool, numpy=array([ True,
True,  True,  True])>
```

2.5.4. التدرجات وتدفق التحكم في بايثون Gradients and Python Control Flow

لقد راجعنا حتى الآن الحالات التي تم فيها تحديد المسار من الإدخال إلى المخرجات بشكل جيد عبر دالة مثل z = x * x * x. تمنحنا البرمجة مزيداً من الحرية في كيفية حساب النتائج. على سبيل المثال، يمكننا جعلها تعتمد على المتغيرات المساعدة أو اختيارات الشرط على النتائج الوسيطة. تتمثل إحدى فوائد استخدام التفاضل التلقائي في أنه حتى إذا كان إنشاء الرسم البياني الحسابي لدالة ما يتطلب المرور عبر متاهة من تدفق التحكم control flow في بايثون (على سبيل المثال، الشرطية والحلقات واستدعاءات الدوال التعسفية)، فلا يزال بإمكاننا حساب التدرج للمتغير الناتج. لتوضيح ذلك، ضع في اعتبارك مقتطف الشفرة التالي حيث يعتمد عدد مرات تكرار حلقة while وتقييم جملة if على قيمة الإدخال a.

```
def f(a):
    b = a * 2
```

```
    while tf.norm(b) < 1000:
        b = b * 2
    if tf.reduce_sum(b) > 0:
        c = b
    else:
        c = 100 * b
    return c
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=1024.0>
```

أدناه، نستدعي هذه الدالة، ونمرر قيمة عشوائية كمدخلات. نظرًا لأن الإدخال متغير عشوائي، فإننا لا نعرف الشكل الذي سيتخذه الرسم البياني الحسابي computational graph. ومع ذلك، عندما ننفذ `f(a)` على إدخال معين، فإننا ندرك رسمًا بيانيًا حسابيًا محددًا ويمكننا بعد ذلك الذهاب للخلف `backward`.

```
a = tf.Variable(tf.random.normal(shape=()))
with tf.GradientTape() as t:
    d = f(a)
d_grad = t.gradient(d, a)
d_grad
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=1024.0>
```

على الرغم من أن دالتنا `f` مصممة قليلاً لأغراض توضيحية، إلا أن اعتمادها على المدخلات بسيط للغاية: إنها دالة خطية linear function بمقياس محدد متعدد التعريف piecewise defined scale. على هذا النحو، فإن `f(a) / a` عبارة عن متجه للمدخلات الثابتة، علاوة على ذلك، تحتاج `f(a) / a` إلى مطابقة تدرج `f(a)` فيما يتعلق بـ `a`.

```
d_grad == d / a
```

```
<tf.Tensor: shape=(), dtype=bool, numpy=True>
```

تدفق التحكم الديناميكي Dynamic control flow شائع جدًافي التعلم العميق. على سبيل المثال، عند معالجة النص، يعتمد الرسم البياني الحسابي على طول المدخلات.في هذه الحالات، يصبح التفاضل التلقائي أمرًا حيويًا للنمذجة الإحصائية لأنه من المستحيل حساب التدرج مسبقًا.

2.5.5. المناقشة

لقد اكتسبت الآن طعمًا لقوة التفاضل التلقائي. لقد كان تطوير المكتبات لحساب المشتقات تلقائيًا وفعالًا بمثابة معزز كبير للإنتاجية لممارسي التعلم العميق، مما أتاح لهم التركيز على اهتمامات أعلى. علاوة على ذلك، يسمح لنا برنامج autograd بتصميم نماذج ضخمة تكون حسابات التدرج بالقلم والورق لها مضيعة للوقت. ومن المثير للاهتمام، أنه بينما نستخدم autograd لتحسين النماذج (بالمعنى الإحصائي)، فإن تحسين مكتبات autograd نفسها

(بالمعنى الحسابي) يعد موضوعًا غنيًا ذا أهمية حيوية لمصممي إطار العمل. هنا، يتم الاستفادة من الأدوات من المجمعين ومعالجة الرسم البياني لحساب النتائج بالطريقة الأكثر ملاءمة وفعالية للذاكرة.

في الوقت الحالي، حاول أن تتذكر هذه الأساسيات: (1) إرفاق التدرجات بتلك المتغيرات التي نرغبفي المشتقات فيما يتعلق بها؛ (2) تسجيل حساب القيمة المستهدفة؛ (3) تنفيذ دالة الانتشار الخلفي backpropagation؛ و (4) الوصول إلى التدرج الناتج.

2.5.6. التمارين

1. لماذا يكون حساب المشتق الثاني أكثر تكلفة بكثير من المشتق الأول؟
2. بعد تشغيل دالة backpropagation، قم بتشغيلها على الفور مرة أخرى وشاهد ما سيحدث. لماذا؟
3. في مثال تدفق التحكم control flow حيث نحسب مشتق `d` بالنسبة إلى `a`، ماذا سيحدث إذا غيرنا المتغير `a` إلى متجه عشوائي أو مصفوفة؟في هذه المرحلة، لم تعد نتيجة الحساب `f(a)` عددًا قياسيًا. ماذا يحدث للنتيجة؟ كيف نحلل هذا؟
4. لتكن $f(x) = \sin(x)$. ارسم الرسم البياني لـ f ومشتقاته f'. لا تستغل حقيقة ذلك $f'(x) = \cos(x)$ بل استخدم التفاضل التلقائي للحصول على النتيجة.
5. لتكن $f(x) = \left((\log x^2) \cdot \sin x\right) + x^{-1}$. اكتب نتائج تتبع الرسم البياني للتبعية من x إلى $f(x)$.
6. استخدم قاعدة السلسلة chain rule لحساب المشتق $\frac{df}{dx}$ من الدالة المذكورة أعلاه، مع وضع كل مصطلح على الرسم البياني للتبعية الذي قمت بإنشائه مسبقًا.
7. بالنظر إلى الرسم البياني ونتائج المشتقات الوسيطة، لديك عدد من الخيارات عند حساب التدرج. قم بتقييم النتيجة بمجرد البدء من x إلى f ومرة واحدة من f التتبع إلى الخلف x. يُعرف المسار من x إلى f بشكل عام باسم التفاضل الأمامي forward differentiation، بينما يُعرف المسار من f إلى x باسم التمايز الخلفي backward differentiation.
8. متى قد ترغبفي استخدام التفاضل الأمامي ومتى التفاضل الخلفي؟ تلميح: ضعفي اعتبارك مقدار البيانات الوسيطة المطلوبة، والقدرة على موازاة الخطوات، وحجم المصفوفات والمتجهات المعنية.

2.6. الاحتمال والاحصاء Probability and Statistics

بطريقة أو بأخرى، يدور التعلم الآلي حول عدم اليقين uncertainty.في التعلم الخاضع للإشراف، نريد أن نتنبأ بشيء غير معروف (الهدف target) بالنظر إلى شيء معروف (الميزات

features). اعتمادًا على هدفنا، قد نحاول توقع القيمة الأكثر احتمالًا للهدف. أو قد نتوقع القيمة بأقل مسافة متوقعة من الهدف. وأحيانًا لا نرغب فقطفي التنبؤ بقيمة معينة ولكن تحديد عدم اليقين لدينا quantify our uncertainty. على سبيل المثال، بالنظر إلى بعض الميزات التي تصف المريض، قد نرغبفي معرفة مدى احتمالية تعرضه لأزمة قلبيةفي العام المقبل.في التعلم غير الخاضع للإشراف، غالبًا ما نهتم بعدم اليقين. لتحديد ما إذا كانت مجموعة القياسات شاذة anomalous، من المفيد معرفة مدى احتمالية ملاحظة القيمفي المجتمع محل الاهتمام. علاوة على ذلك،في التعلم المعزز reinforcement learning، نرغبفي تطوير عوامل تعمل بذكاءفي بيئات مختلفة. يتطلب هذا التفكيرفي كيفية توقع تغير البيئة والمكافآت التي قد يتوقع المرء مواجهتها استجابة لكل من الإجراءات المتاحة.

الاحتمالية Probability هو المجال الرياضي المعني بالاستدلال reasoningفي ظل عدم اليقين. بالنظر إلى نموذج احتمالي لبعض العمليات، يمكننا التفكيرفي احتمال وقوع أحداث مختلفة. إن استخدام الاحتمالات لوصف تكرار الأحداث القابلة للتكرار (مثل رمي العملات المعدنية coin tosses) غير مثير للجدل إلى حد ما.في الواقع، يلتزم العلماء frequentist scholars بتفسير الاحتمال الذي ينطبق فقط على مثل هذه الأحداث القابلة للتكرار. على النقيض من ذلك، يستخدم علماء بايز Bayesian scholarsلغة الاحتمال على نطاق أوسع لإضفاء الطابع الرسمي على تفكيرنافي ظل عدم اليقين. يتميز احتمالية بايز Bayesian probability بميزتين فريدتين: (1) تعيين درجات من الاعتقاد للأحداث غير القابلة للتكرار، على سبيل المثال، ما هو احتمال أن يكون القمر مصنوعًا من الجبن؟ و (2) الذاتية subjectivity– بينما يوفر احتمالية بايز قواعد لا لبس فيها لكيفية تحديث المرء لمعتقداتهفي ضوء أدلة جديدة، فإنه يسمح للأفراد المختلفين بالبدء بمعتقدات سابقة مختلفة. تساعدنا الإحصائيات على التفكير بشكل عكسي، بدءًا من جمع البيانات وتنظيمها والتراجع عن الاستنتاجات التي قد نستخلصها حول العملية التي أنتجت البيانات. عندما نحلل مجموعة بيانات، ونبحث عن الأنماط التي نأمل أن تميز مجموعة أكبر من السكان، فإننا نستخدم التفكير الإحصائي. تم تخصيص معظم الدورات والتخصصات والأطروحات والمهن والإدارات والشركات والمؤسسات لدراسة الاحتمالات والإحصاءات.في حين أن هذا القسم يخدش السطح فقط، فإننا سنوفر الأساس الذي تحتاجه لبدء بناء النماذج.

2.6.1. مثال بسيط: رمي العملات المعدنية Tossing Coins

تخيل أننا نخطط لرمي عملة معدنية ونريد تحديد مدى احتمالية رؤية الرؤوس heads (مقابل ذيول tails). إذا كانت العملة عادلة، فإن كلا النتيجتين (الرأس والذيل) متساويانفي الاحتمال. علاوة على ذلك، إذا كنا نخطط لإلقاء n مرات العملة، فيجب أن يتطابق الجزء الذي نتوقع رؤيته من الرؤوس تمامًا مع الكسر المتوقع من ذيول. إحدى الطرق البديهية لرؤية ذلك هي من خلال

التناسق symmetry: لكل نتيجة محتملة مع n_h رؤوس و$n_t = (n - n_h)$ ذيول، هناك نتيجة محتملة متساوية مع n_t رؤوس وn_h ذيول. لاحظ أن هذا ممكن فقط إذا كنا نتوقعفي المتوسط رؤية $\frac{1}{2}$ الرميات تظهر على الرؤوس و$\frac{1}{2}$ تظهر على الذيول. بالطبع، إذا أجريت هذه التجربة عدة مرات مع كل $n = 1000000$ رميات، فقد لا ترى تجربةفي أي $n_h = n_t$بالضبط.

رسميًا، تسمى الكمية $\frac{1}{2}$ بالاحتمالية probability وهي هنا تلتقط اليقين الذي ستظهر به أي رمية. تقوم الاحتمالات بتعيين درجات بين 0 و1 نتائج الاهتمام outcomes of interest، تسمى الأحداث events. هنا حدث الاهتمام بالرأس heads ونشير إلى الاحتمال المقابل $P(\text{heads})$. يشير احتمال 1 اليقين المطلق (تخيل عملة خدعة حيث كان كلا الجانبين رؤوسًا) واحتمال 0 يشير إلى استحالة (على سبيل المثال، إذا كان كلا الجانبين ذيول). الترددات $\frac{n_h}{n}$ و$\frac{n_t}{n}$ ليست احتمالات بل إحصائيات statistics. الاحتمالات هي الكميات النظرية التي تقوم عليها عملية توليد البيانات. هنا، الاحتمال $\frac{1}{2}$ هو خاصية للعملة نفسها. على النقيض من ذلك، الإحصائيات هي كميات تجريبية يتم حسابها كدوال للبيانات المرصودة. تتشابك اهتماماتنافي الكميات الاحتمالية والإحصائية بشكل لا ينفصم. غالبًا ما نصمم إحصائيات خاصة تسمى المقدرات estimators التي،في ضوء مجموعة بيانات، تنتج تقديرات لمعلمات النموذج مثل الاحتمالات. علاوة على ذلك، عندما تحقق تلك المقدرات خاصية لطيفة تسمى الاتساق consistency، فإن تقديراتنا ستتقارب مع الاحتمال المقابل. بدورها، تخبرنا هذه الاحتمالات المستنتجة عن الخصائص الإحصائية المحتملة للبيانات من نفس المجتمع والتي قد نواجههافي المستقبل.

لنفترض أننا عثرنا على عملة حقيقية لم نكن نعرف حقيقة وجودها $P(\text{heads})$. للتحقق من هذه الكمية بالطرق الإحصائية، نحتاج إلى (1) جمع بعض البيانات؛ و (2) تصميم مقدر estimator. الحصول على البيانات هنا سهل؛ يمكننا رمي العملة عدة مرات وتسجيل جميع النتائج. رسميًا، يُطلق على استخلاص الإنجازات من بعض العمليات العشوائية الأساسية أخذ العينات sampling. كما قد تكون خمنت، أحد المقدر الطبيعي natural estimator هو الكسر fraction بين عدد الرؤوس المرصودة observed heads بالعدد الإجمالي للرمي number of tosses.

```
%matplotlib inline
import random
import tensorflow as tf
from tensorflow_probability import distributions as tfd
from d2l import tensorflow as d2l
```

الآن، افترض أن العملة كانتفي الواقع عادلة، أي $P(\text{heads}) = 0.5$. لمحاكاة رميات عملة عادلة، يمكننا استدعاء أي مولد أرقام عشوائي. بعض الطرق السهلة لرسم عينات من حدث ذي احتمالية. على سبيل المثال، ينتج `random.random`في بايثون أرقامًافي الفترة $[0,1]$ حيث يكون احتمال الكذبفي أي فترة فرعية $[a, b] \subset [0,1]$ مساويًا $b - a$. وبالتالي يمكننا الخروج من `0` و `1` باحتمال `0.5` لكل منهما باختبار ما إذا كان الطفو المرتجع أكبر من `0.5`

```
num_tosses = 100
heads = sum([random.random() > 0.5 for _ in range(100)])
tails = num_tosses - heads
print("heads, tails: ", [heads, tails])
```

```
<tf.Tensor: shape=(2,), dtype=float32, numpy=array([45.,
55.], dtype=float32)>
```

هنا، على الرغم من أن عملتنا المحاكاة عادلة (قمنا بتعيين الاحتمالات `[0.5, 0.5]` بأنفسنا)، قد لا تكون تعدادات الرأس والذيول متطابقة. ذلك لأننا رسمنا عددًا محدودًا فقط من العينات. إذا لم ننفذ المحاكاة بأنفسنا، ورأينا النتيجة فقط، فكيف لنا أن نعرف ما إذا كانت العملة غير عادلة إلى حد ما أو إذا كان الانحراف المحتمل عنها $\frac{1}{2}$ مجرد قطعة أثرية من حجم العينة الصغير؟ دعونا نرى ما يحدث عندما نقوم بمحاكاة `10000`رمية.

```
counts = tfd.Multinomial(10000, fair_probs).sample()
counts / 10000
```

```
<tf.Tensor: shape=(2,), dtype=float32,
numpy=array([0.5056, 0.4944], dtype=float32)>
```

بشكل عام، بالنسبة لمتوسطات الأحداث المتكررة (مثل رمي العملات المعدنية)، مع تزايد عدد التكرارات، نضمن أن تتقارب تقديراتنا مع الاحتمالات الأساسية الحقيقية. يُطلق على الدليل الرياضي لهذه الظاهرة اسم قانون الأعداد الكبيرة law of large numbers وتخبرنا نظرية الحد المركزي central limit theorem أنهفي العديد من المواقف، مع نمو حجم العينة n، يجب أن تنخفض هذه الأخطاء بمعدل $\left(\frac{1}{\sqrt{n}}\right)$. دعنا نحصل على مزيد من الحدس من خلال دراسة كيفية تطور تقديراتنا مع زيادة عدد الرميات من `1` إلى `10000`.

```
counts = tfd.Multinomial(1, fair_probs).sample(10000)
cum_counts = tf.cumsum(counts, axis=0)
estimates = cum_counts / tf.reduce_sum(cum_counts,
axis=1, keepdims=True)
estimates = estimates.numpy()

d2l.set_figsize((4.5, 3.5))
```

```
d2l.plt.plot(estimates[:, 0], label=("P(coin=heads)"))
d2l.plt.plot(estimates[:, 1], label=("P(coin=tails)"))
d2l.plt.axhline(y=0.5, color='black',
linestyle='dashed')
d2l.plt.gca().set_xlabel('Samples')
d2l.plt.gca().set_ylabel('Estimated probability')
d2l.plt.legend();
```

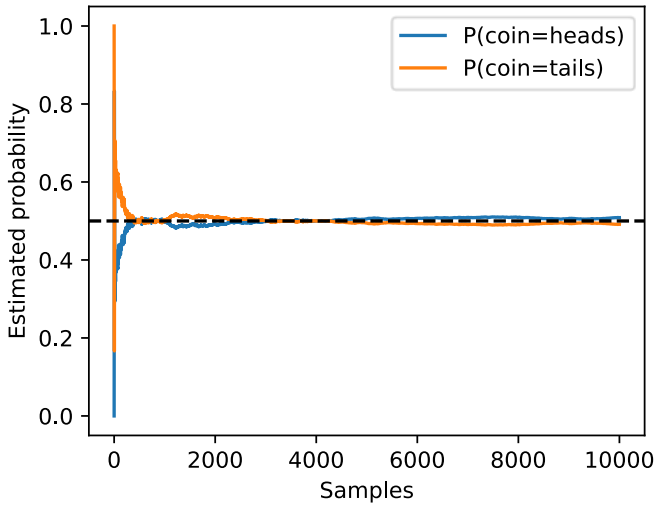

يتوافق كل منحنى صلب مع إحدى قيمتي العملة المعدنية ويعطي الاحتمالية المقدرة لعملة العملة هذه بعد كل مجموعة من التجارب. يعطي الخط الأسود المتقطع الاحتمال الأساسي الحقيقي. مع حصولنا على المزيد من البيانات من خلال إجراء المزيد من التجارب، تتقارب المنحنيات نحو الاحتمال الحقيقي. قد تبدأ بالفعلفي رؤية شكل بعض الأسئلة الأكثر تقدمًا التي تشغل بال الإحصائيين: ما مدى سرعة حدوث هذا التقارب convergence؟ إذا كنا قد اختبرنا بالفعل العديد من العملات المعدنية المصنعةفي نفس المصنع، فكيف يمكننا دمج هذه المعلومات؟

2.6.2. معاملة رسمية أكثر A More Formal Treatment

لقد وصلنا بالفعل إلى حد بعيد: طرح نموذج احتمالي، وإنشاء بيانات تركيبية، وتشغيل مقدر إحصائي، وتقييم التقارب بشكل تجريبي، والإبلاغ عن مقاييس الخطأ (التحقق من الانحراف deviation). ومع ذلك، للمضي قدمًا، سنحتاج إلى أن نكون أكثر دقة.

عند التعامل مع العشوائية randomness، فإننا نشير إلى مجموعة النتائج المحتملة $\mathcal{S}$ ونطلق عليها مساحة العينة sample space أو مساحة النتيجة outcome space. هنا، كل عنصر هو

نتيجة ممكنة مميزة.في حالة دحرجة عملة واحدة،$\mathcal{S} = \{heads,tails\}$. لنرد واحد $\mathcal{S} = \{1,2,3,4,5,6\}$. عند قلب عملتين، يكون لدينا أربع نتائج محتملة:

$$\{(heads,heads), (heads,tails), (tails,heads), (tails,tails)\}$$

الأحداث هي مجموعات فرعية من مساحة العينة. على سبيل المثال، حدث "ظهور أول رمية عملة على الرأس" يتوافق مع المجموعة $\{(heads,heads), (heads,tails)\}$. كلما كانت نتيجة zالتجربة العشوائية تحقق $z \in \mathcal{A}$، $\mathcal{A}$ حدث ذلك. بالنسبة إلى لفة واحدة من النرد، يمكننا تحديد الأحداث "رؤية 5" ($\mathcal{A} = \{5\}$) و "رؤية رقم فردي" ($\mathcal{B} = \{1,3,5\}$).في هذه الحالة، إذا جاء النرد 5، فسنقول أن كلاهما A و B حدث. من ناحية أخرى، إذا $z = 3$, اذن $\mathcal{A}$ لم يحدث بل $\mathcal{B}$ حدث.

تقوم دالة الاحتمال بتعيين الأحداث على قيم حقيقية $P: \mathcal{A} \subseteq \mathcal{S} \to [0,1]$. يفي احتمال وقوع حدث $\mathcal{A}$في مساحة العينة المحددة $\mathcal{S}$، $P(\mathcal{A})$بالخصائص التالية:

- احتمال حدوث أي حدث $\mathcal{A}$ هو رقم حقيقي غير سالب، أي $P(\mathcal{A}) \geq 0$ ؛
- احتمال مساحة العينة بأكملها هو 1 ، أي $P(\mathcal{S}) = 1$؛
- بالنسبة لأي تسلسل قابل للعد من الأحداث $\mathcal{A}_1, \mathcal{A}_2, \ldots$ التي تكون متنافية mutually exclusive ($\mathcal{A}_i \cap \mathcal{A}_j = \emptyset$ لكل $i \neq j$)، فإن احتمال حدوث أي منها يساوي مجموع احتمالاتها الفردية، أي $P(\mathcal{A}_i)$ $P\left(\bigcup_{i=1}^{\infty} \mathcal{A}_i\right) = \sum_{i=1}^{\infty}$.

يمكن تطبيق بديهيات نظرية الاحتمالات، التي اقترحها كولموغوروف (1933)، لاشتقاق عدد من النتائج المهمة بسرعة. على سبيل المثال، يترتب على ذلك على الفور أن احتمال حدوث أي حدث $\mathcal{A}$ أو مكمل حدوثه $\mathcal{A}'$ يحدثانفي وقت واحد هو $P(\mathcal{A} \cap \mathcal{A}') = 0$. بشكل غير رسمي، يخبرنا هذا أن الأحداث المستحيلة ليس لها أي احتمال لحدوثها.

2.6.3. المتغيرات العشوائية Random Variables

عندما تحدثنا عن أحداث مثل ظهور احتمالات ظهور النرد أو ظهور أول عملة معدنية، كنا نستدعي فكرة المتغير العشوائي random variable. بشكل رسمي، المتغيرات العشوائية عبارة عن تعيينات من مساحة عينة أساسية إلى مجموعة من (ربما العديد) من القيم. قد تتساءل كيف يختلف المتغير العشوائي عن مساحة العينة، لأن كلاهما عبارة عن مجموعة من النتائج. الأهم من ذلك، يمكن أن تكون المتغيرات العشوائية أكثر خشونة much coarser من مساحة العينة الأولية. يمكننا تحديد متغير عشوائي ثنائي مثل "أكبر من 0.5" حتى عندما تكون مساحة العينة الأساسية لانهائية، على سبيل المثال، المقطع الخطي بين 0و 1. بالإضافة إلى ذلك، يمكن للمتغيرات العشوائية المتعددة أن تشتركفي نفس مساحة العينة الأساسية. على سبيل المثال، "ما

إذا كان إنذار منزلي ينطلق" و "ما إذا كان منزلي قد تعرض للسطو" كلاهما متغيرين عشوائيين يشتركانفي مساحة عينة أساسية. وبالتالي، فإن معرفة القيمة المأخوذة بواسطة متغير عشوائي واحد يمكن أن يخبرنا شيئًا عن القيمة المحتملة لمتغير عشوائي آخر. مع العلم أن جهاز الإنذار قد انطلق، قد نشكفي احتمال تعرض المنزل للسطو.

تتوافق كل قيمة مأخوذة بواسطة متغير عشوائي مع مجموعة فرعية من مساحة العينة الأساسية. وبالتالي فإن الحدوث الذي يأخذ فيه المتغير العشوائي X قيمة v، يُرمز إليه بـ $P(X = v)$، هو حدث ويشير إلى احتماله.في بعض الأحيان، يمكن أن يصبح هذا الترميز غير مؤكد، ويمكننا إساءة استخدام التدوين عندما يكون السياق واضحًا. على سبيل المثال، قد نستخدم $P(X)$ للإشارة على نطاق واسع إلى توزيع X ، أي الدالة التي تخبرنا بالاحتمال الذي X يأخذ أي قيمة معينة.في أحيان أخرى نكتب تعبيرات مثل $P(X,Y) = P(X)P(Y)$، كاختصار للتعبير عن عبارة صحيحة لجميع القيم التي يمكن أن تأخذها المتغيرات العشوائية X و Y، أي لكل i, j ما تحمله $P(X = i \text{ and } Y = j) = P(X = i)P(Y = j)$.في أوقات أخرى، نسيء استخدام التدوين عن طريق الكتابة عندما يكون المتغير العشوائي واضحًا من السياق. نظرًا لأن الحدثفي نظرية الاحتمالات هو مجموعة من النتائج من مساحة العينة، يمكننا تحديد نطاق من القيم لمتغير عشوائي ليأخذها. على سبيل المثال، يدل $P(1 \leq X \leq 3)$ على احتمال وقوع الحدث $\{1 \leq X \leq 3\}$.

لاحظ أن هناك فرقًا طفيفًا بين المتغيرات العشوائية المتقطعة discrete random variables، مثل تقليب عملة معدنية أو رمي نرد، والمتغيرات المستمرة continuous، مثل وزن وطول الشخص المأخوذ عشوائيًا من السكان.في هذه الحالة نادرًا ما نهتم حقًا بالطول الدقيق لشخص ما. علاوة على ذلك، إذا أخذنا قياسات دقيقة كافية، فسنجد أنه لا يوجد شخصان على الكوكب لهما نفس الارتفاع بالضبط.في الواقع، مع قياسات دقيقة كافية، لن يكون لديك نفس الارتفاع عند الاستيقاظ وعندما تنام. ليس هناك فائدة تذكرفي السؤال عن الاحتمال الدقيق أن يبلغ طول شخص ما 1.801392782910287192 مترًا. بدلاً من ذلك، نهتم عادةً أكثر بالقدرة على تحديد ما إذا كان ارتفاع شخص ما يقعفي فترة زمنية معينة، لنقل بين 1.79 و1.81 مترًا.في هذه الحالات، نتعامل مع كثافات الاحتمالات. لا يوجد احتمال لارتفاع 1.80 متر بالضبط، لكن كثافة غير صفرية nonzero density. لإخراج الاحتمال المخصص لفترة ما، يجب أن نأخذ جزءًا لا يتجزأ من الكثافة على تلك الفترة.

2.6.4. متغيرات عشوائية متعددة Multiple Random Variables

ربما لاحظت أنه لا يمكننا حتى تجاوز القسم الأخير دون الإدلاء بعبارات تتضمن تفاعلات بين متغيرات عشوائية متعددة (استدعاء $P(X,Y) = P(X)P(Y)$). يهتم معظم التعلم الآلي بمثل

هذه العلاقات. هنا، ستكون مساحة العينة هي الفئة المستهدفة، كما يقول العملاء الذين يتعاملون مع شركة، أو صور فوتوغرافية على الإنترنت، أو بروتينات معروفة لعلماء الأحياء. يمثل كل متغير عشوائي القيمة (غير المعروفة) لسمة مختلفة. عندما نقوم بأخذ عينة من فرد من السكان، نلاحظ تحقيق كل من المتغيرات العشوائية. نظرًا لأن القيم المأخوذة بواسطة المتغيرات العشوائية تتوافق مع مجموعات فرعية من مساحة العينة التي يمكن أن تكون متداخلة أو متداخلة جزئيًا أو منفصلة تمامًا، فإن معرفة القيمة المأخوذة بواسطة متغير عشوائي واحد يمكن أن تجعلنا نقوم بتحديث معتقداتنا حول القيم المحتملة لمتغير عشوائي آخر. إذا دخل المريض إلى المستشفى ولاحظنا أنه يعاني من صعوبةفي التنفس وفقد حاسة الشم، فإننا نعتقد أنه من المرجح أن يكون مصابًا بـ COVID-19 أكثر مما قد يكون عليه الحال إذا لم يكن لديه مشكلةفي التنفس وكان عاديًا تمامًا. حاسة الشم.

عند العمل مع متغيرات عشوائية متعددة، يمكننا إنشاء أحداث تتوافق مع كل مجموعة من القيم التي يمكن أن تأخذها المتغيرات بشكل مشترك. تسمى دالة الاحتمال التي تعين الاحتمالات لكل من هذه المجموعات (على سبيل المثال $A = a$ و $B = b$) دالة الاحتمال المشترك joint probability function وترجع ببساطة الاحتمال المعين لتقاطع المجموعات الفرعية المقابلة من مساحة العينة. الاحتمال المشترك المخصص للحدث حيث يتم الإشارة إلى المتغيرات العشوائية A وB القيم a وb ، على التوالي، حيث تشير $P(A = a, B = b)$ والفاصلة إلى "and". لاحظ أنه بالنسبة لأية قيم a وb ، فهي تحمل ذلك $P(A = a, B = b) \leq P(A = a)$، ومنذ حدوث $A = a$ و $B = b$ ، يجب أن يحدث $A = a$ يجب أن يحدث و$B = b$ يحدث أيضًا. ومن المثير للاهتمام أن الاحتمال المشترك يخبرنا بكل ما يمكننا معرفته عن هذه المتغيرات العشوائية بالمعنى الاحتمالي، ويمكن استخدامه لاشتقاق العديد من الكميات المفيدة الأخرى، بمافي ذلك استعادة التوزيعات الفردية $P(A)$ و $P(B)$. لاسترداد $P(A = a)$ ، نجمع ببساطة $P(A = a, B = v)$ جميع القيم v التي يمكن أن يأخذها المتغير العشوائي B: $P(A = a) = \sum_v \quad P(A = a, B = v)$.

النسبة $1 \leq \frac{P(A=a,B=b)}{P(A=a)}$ تبين أنها مهمة للغاية. يطلق عليه الاحتمال الشرطي conditional probability,ويُشار إليه بالرمز "|". يخبرنا الاحتمال الجديد المرتبط بالحدث $B = b$ ، بمجرد أن نشتركفي حقيقة حدوثه $A = a$. يمكننا أن نفكرفي هذا الاحتمال الشرطي على أنه يقيد الانتباه فقط إلى المجموعة الفرعية من مساحة العينة المرتبطة بـ $A = a$ ثم إعادة التسوية renormalizing بحيث تصل جميع الاحتمالات إلى 1. الاحتمالات الشرطية هيفي الواقع احتمالات، وبالتالي نحترم جميع البديهيات axioms، طالما أننا شرط جميع المصطلحاتفي نفس الحدث وبالتالي قصر الانتباه على نفس مساحة العينة. على سبيل المثال، بالنسبة للأحداث

المنفصلة $\mathcal{B}$ و$\mathcal{B}'$ لدينا ذلك $P(\mathcal{B} \cup \mathcal{B}' \mid A = a) = P(\mathcal{B} \mid A = a) + P(\mathcal{B}' \mid A = a)$.

باستخدام تعريف الاحتمالات الشرطية conditional probabilities، يمكننا اشتقاق النتيجة الشهيرة المسماة نظرية بايز Bayes' theorem. من خلال البناء، لدينا ذلك $P(A, B) = P(B \mid A)P(A)$ و $P(A, B) = P(A \mid B)P(B)$. الجمع بين كلا المعادلتين ينتج $P(B \mid A)P(A) = P(A \mid B)P(B)$ وبالتالي

$$P(A \mid B) = \frac{P(B \mid A)P(A)}{P(B)}.$$

هذه المعادلة البسيطة لها آثار عميقة لأنها تسمح لنا بعكس ترتيب الشرط. إذا عرفنا كيف نقدر $P(B \mid A)$ ، ثم يمكننا أن نقدر $P(A \mid B)$. غالبًا ما نجد أنه من الأسهل تقدير مصطلح واحد بشكل مباشر ولكن ليس الآخر ويمكن أن تنقذ نظرية بايز Bayes' theorem هنا. على سبيل المثال، إذا عرفنا مدى انتشار أعراض مرض معين، والانتشار العام للمرض والأعراض، على التوالي، يمكننا تحديد مدى احتمالية إصابة شخص ما بالمرض بناءً على أعراضه.في بعض الحالات، قد لا يكون لدينا وصول مباشر لـ $P(B)$ ، مثل انتشار الأعراض.في هذه الحالة، تكون النسخة المبسطة من نظرية بايز مفيدة:

$$P(A \mid B) \propto P(B \mid A)P(A).$$

بما أننا نعلم أن $P(A \mid B)$ يجب تسويته الى 1 ، أي $\sum_a P(A = a \mid B) = 1$ يمكننا استخدامه لحساب:

$$P(A \mid B) = \frac{P(B \mid A)P(A)}{\sum_b P(B = b \mid A)P(A)}.$$

في إحصائيات بايز Bayesian statistics، نعتقد أن المراقب observer يمتلك بعض المعتقدات السابقة (الذاتية subjective) حول معقولية الفرضيات المتاحة المشفرةفي السابق $P(H)$ ، ودالة احتمالية توضح مدى احتمالية ملاحظة أي قيمة للأدلة التي تم جمعها لكل من الفرضياتفي الفئة $P(E \mid H)$. ثم يتم تفسير نظرية بايز على أنها تخبرنا بكيفية تحديث السابقة الأولية initial prior في ضوء الأدلة المتاحة E لإنتاج معتقدات لاحقة $P(H \mid E) = \frac{P(E|H)P(H)}{P(E)}$. بشكل غير رسمي، يمكن ذكر ذلك على أنه "لاحقًا يساوي احتمالية الأوقات السابقة prior times likelihood، مقسومًا على الدليل evidence". الآن، نظرًا لأن الدليل $P(E)$ هو نفسه بالنسبة لجميع الفرضيات، يمكننا التخلص ببساطة من تسوية الفرضيات.

لاحظ أن $P(A = a \mid B) = 1$ $\sum_a$ يسمح لنا أيضًا بالتهميش marginalize على المتغيرات العشوائية. وهذا يعني أنه يمكننا إسقاط المتغيرات من التوزيع المشترك مثل $P(A, B)$. بعد كل شيء، لدينا ذلك

$$\sum_a P(A = a, B) = P(B) \sum_a P(A = a \mid B) = P(B).$$

الاستقلال Independence هو مفهوم آخر مهم بشكل أساسي يشكل العمود الفقري للعديد من الأفكار المهمةفي الإحصاء. باختصار، يكون متغيرين مستقلين إذا كان التكييف conditioning على قيمة A لا يسبب أي تغييرفي توزيع الاحتمالات المرتبط بـ B والعكس صحيح. بشكل رسمي أكثر، الاستقلال، والمشار إليه $A \perp B$ ، يتطلب ذلك $P(A \mid B) = P(A)$ ، وبالتالي، ذلك $P(A, B) = P(A \mid B)P(B) = P(A)P(B)$. غالبًا ما يكون الاستقلال افتراضًا مناسبًا. على سبيل المثال، إذا كان المتغير العشوائي A يمثل النتيجة من رمي عملة عادلة ويمثل المتغير العشوائي B النتيجة من رمي عملة أخرى، فإن معرفة ما إذا كان المتغير العشوائي A لا يجب أن يؤثر على احتمالية B ظهور الرأس.

يكون الاستقلال مفيدًا بشكل خاص عندما يكون بين السحوبات draws المتتالية لبياناتنا من بعض التوزيعات الأساسية (مما يسمح لنا بعمل استنتاجات إحصائية قوية) أو عندما يكون بين المتغيرات المختلفةفي بياناتنا، مما يسمح لنا بالعمل مع نماذج أبسط ترميز بنية الاستقلال هذه. من ناحية أخرى، غالبًا ما يكون تقدير التبعيات بين المتغيرات العشوائية هو الهدف الأساسي للتعلم. نحن نهتم بتقدير احتمالية المرض نظرًا للأعراض على وجه التحديد لأننا نعتقد أن الأمراض والأعراض ليست مستقلة.

لاحظ أنه نظرًا لأن الاحتمالات الشرطية هي احتمالات مناسبة، فإن مفاهيم الاستقلال independence والاعتماد dependence تنطبق عليها أيضًا. متغيرين عشوائيين A وB مستقلان بشكل مشروط مع الأخذفي الاعتبار متغير ثالث C إذا وفقط إذا $P(A, B \mid C) = P(A \mid C)P(B \mid C)$. ومن المثير للاهتمام، أن متغيرين يمكن أن يكونا مستقلين بشكل عام ولكنهما يعتمدان عند التكييف على متغير ثالث. يحدث هذا غالبًا عندما يتوافق المتغيران العشوائيان A وB مع أسباب متغير ثالث C. على سبيل المثال، قد تكون العظام المكسورة وسرطان الرئة مستقلينفي عموم السكان، ولكن إذا شرطنا وجودنافي المستشفى، فقد نجد أن العظام المكسورة مرتبطة سلبًا بسرطان الرئة. وذلك لأن العظم المكسور يفسر سبب وجود شخص مافي المستشفى وبالتالي يقلل من احتمالية إصابته بسرطان الرئة.

وعلى العكس من ذلك، يمكن أن يصبح متغيرين عشوائيين مستقلين عند التكييف على متغير ثالث. يحدث هذا غالبًا عندما يكون لحدثين غير مرتبطين سببًا مشتركًا. يرتبط حجم الحذاء

ومستوى القراءة ارتباطًا وثيقًا بين طلاب المدارس الابتدائية، لكن هذا الارتباط يختفي إذا شرطنا في العمر.

2.6.5. مثال

دعونا نختبر مهاراتنا. افترض أن الطبيب يقوم بإجراء اختبار فيروس نقص المناعة البشرية HIV على المريض. هذا الاختبار دقيق إلى حد ما ولا يفشل إلا مع احتمال 1٪ إذا كان المريض يتمتع بصحة جيدة ولكنه يبلغ عن إصابته بالمرض. علاوة على ذلك، فإنه لا يفشل أبدًافي اكتشاف فيروس نقص المناعة البشرية إذا كان المريض مصابًا به بالفعل. نستخدم $D_1 \in \{0,1\}$ للإشارة إلى التشخيص (0 إذا كان سلبياً و1 إذا كان إيجابياً) و$H \in \{0,1\}$ للإشارة إلى حالة فيروس نقص المناعة البشرية.

Conditional probability	$H = 1$	$H = 0$
$P(D_1 = 1 \mid H)$	1	0.01
$P(D_1 = 0 \mid H)$	0	0.99

لاحظ أن مجاميع الأعمدة كلها 1 (لكن مجاميع الصفوف ليست كذلك)، لأنها احتمالات مشروطة. دعونا نحسب احتمال إصابة المريض بفيروس نقص المناعة البشرية إذا كانت نتيجة الاختبار إيجابية، أي $P(H = 1 \mid D_1 = 1)$. حدسيًا، سيعتمد هذا على مدى انتشار المرض، لأنه يؤثر على عدد الإنذارات الكاذبة. افترض أن السكان يتمتعون بصحة جيدة إلى حد ما، على سبيل المثال،$P(H = 1) = 0.0015$. لتطبيق نظرية بايز، نحتاج إلى تطبيق التهميش marginalization لتحديد

$$\begin{aligned} P(D_1 = 1) &= P(D_1 = 1, H = 0) + P(D_1 = 1, H = 1) \\ &= P(D_1 = 1 \mid H = 0)P(H = 0) + P(D_1 = 1 \mid H = 1)P(H = 1) \\ &= 0.011485. \end{aligned}$$

هذا يقودنا إلى

$$P(H = 1 \mid D_1 = 1) = \frac{P(D_1 = 1 \mid H = 1)P(H = 1)}{P(D_1 = 1)} = 0.1306.$$

بمعنى آخر، هناك احتمال بنسبة 13.06٪ فقط أن يكون المريض مصابًا بالفعل بفيروس نقص المناعة البشرية، على الرغم من استخدام اختبار دقيق للغاية. كما نرى، يمكن أن يكون الاحتمال مخالفًا للحدس. ماذا يفعل المريض عند تلقي مثل هذه الأخبار المرعبة؟ من المحتمل أن يطلب

المريض من الطبيب إجراء اختبار آخر لتوضيح الأمر. الاختبار الثاني له خصائص مختلفة وهو ليس بنفس جودة الاختبار الأول.

Conditional probability	$H = 1$	$H = 0$
$P(D_2 = 1 \mid H)$	0.98	0.03
$P(D_2 = 0 \mid H)$	0.02	0.97

لسوء الحظ، الاختبار الثاني يأتي إيجابيًا أيضًا. دعونا نحسب الاحتمالات المطلوبة لاستدعاء نظرية بايز بافتراض الاستقلال الشرطي conditional independence:

$$\begin{aligned} P(D_1 = 1, D_2 = 1 \mid H = 0) &= P(D_1 = 1 \mid H = 0) P(D_2 = 1 \mid H = 0) = 0.0003, \\ P(D_1 = 1, D_2 = 1 \mid H = 1) &= P(D_1 = 1 \mid H = 1) P(D_2 = 1 \mid H = 1) = 0.98. \end{aligned}$$

يمكننا الآن تطبيق التهميش marginalization للحصول على احتمالية أن كلا الاختبارين يأتي بنتائج إيجابية:

$$\begin{aligned} P(D_1 = 1, D_2 = 1) &= P(D_1 = 1, D_2 = 1, H = 0) + P(D_1 = 1, D_2 = 1, H = 1) \\ &= P(D_1 = 1, D_2 = 1 \mid H = 0) P(H = 0) + P(D_1 = 1, D_2 = 1 \mid H = 1) P(H = 1) \\ &= 0.00176955. \end{aligned}$$

أخيرًا، فإن احتمال إصابة المريض بفيروس نقص المناعة البشرية مع إعطاء كلا الاختبارين إيجابيًا

$$\begin{aligned} P(H = 1 \mid D_1 = 1, D_2 = 1) &= \frac{P(D_1 = 1, D_2 = 1 \mid H = 1) P(H = 1)}{P(D_1 = 1, D_2 = 1)} \\ &= 0.8307. \end{aligned}$$

أي أن الاختبار الثاني سمح لنا باكتساب ثقة أعلى بكثير من أن ليس كل شيء على ما يرام. على الرغم من أن الاختبار الثاني أقل دقة بكثير من الاختبار الأول، إلا أنه لا يزال يحسن تقديرنا بشكل كبير. كان افتراض أن كلا الاختبارين مستقلين عن بعضهما البعض مشروطًا أمرًا حاسمًا لقدرتنا على إنشاء تقدير أكثر دقة. خذ الحالة القصوى حيث نجري نفس الاختبار مرتين.في هذه الحالة، نتوقع نفس النتيجةفي كلتا المرتين، وبالتالي لا يتم اكتساب رؤية إضافية من إجراء نفس الاختبار مرة أخرى. ربما لاحظ القارئ الذكي أن التشخيص تصرف كمصنف يختبئ على مرأى من الجميع حيث تزيد قدرتنا على تقرير ما إذا كان المريض يتمتع بصحة جيدة مع حصولنا على المزيد من الميزات (نتائج الاختبار).

2.6.6. التوقعات Expectations

في كثير من الأحيان، لا يتطلب اتخاذ القرارات مجرد النظر إلى الاحتمالات المخصصة للأحداث الفردية، بل تجميعها معًافي مجاميع مفيدة يمكن أن تزودنا بالإرشادات. على سبيل المثال، عندما تأخذ المتغيرات العشوائية قيمًا عددية مستمرة، فإننا غالبًا ما نهتم بمعرفة القيمة التي نتوقعهافي المتوسط. تسمى هذه الكمية رسميًا بالتوقع expectation. إذا كنا نقوم باستثمارات، فقد تكون الكمية الأولى من الفائدة هي العائد الذي يمكن أن نتوقعه، بمتوسط جميع النتائج المحتملة (والترجيح حسب الاحتمالات المناسبة). على سبيل المثال، لنفترض أنه مع وجود احتمال بنسبة 50٪، قد يفشل الاستثمار تمامًا، مع احتمال 40٪ أنه قد يوفر عائدًا × 2، ومع احتمال 10٪ قد يوفر عائد × 10. لحساب العائد المتوقع، نقوم بتجميع الكل العوائد، وضرب كل منهافي احتمال حدوثها. هذا ينتج التوقع $0.5 \cdot 0 + 0.4 \cdot 2 + 0.1 \cdot 10 = 1.8$. ومن ثم فإن العائد المتوقع هو 1.8.

بشكل عام، يتم تعريف توقع (أو متوسط) المتغير العشوائي X على أنه

$$E[X] = E_{x \sim P}[x] = \sum_x xP(X = x).$$

وبالمثل، بالنسبة للكثافات التي نحصل عليها $E[X] = \int xdp(x)$.في بعض الأحيان نحن مهتمون بالقيمة المتوقعة لبعض دوال x. يمكننا حساب هذه التوقعات على أنها

$$E_{x \sim P}[f(x)] = \sum_x f(x)P(x) \text{ and } E_{x \sim P}[f(x)] = \int f(x)p(x)dx$$

للاحتمالات والكثافات المتقطعة، على التوالي. بالعودة إلى مثال الاستثمار أعلاه، قد تكون المنفعة (السعادة) المرتبطة بالعائد. لاحظ الاقتصاديون السلوكيون منذ فترة طويلة أن الناس يربطون بين عدم الكفاءة وخسارة الأموال أكثر من المنفعة المكتسبة من كسب دولار واحد مقارنة بخط الأساس. علاوة على ذلك، تميل قيمة النقود إلى أن تكون دون خطية sublinear. يمكن لامتلاك 100 ألف دولار مقابل صفر دولار أن يحدث فرقًا بين دفع الإيجار وتناول الطعام الجيد والتمتع بالرعاية الصحية الجيدة مقابل المعاناة من التشرد. من ناحية أخرى، فإن المكاسب الناتجة عن امتلاك 200 ألف مقابل 100 ألف أقل دراماتيكية. مثل هذا الاستدلال يحفز الكليشيهات القائلة بأن "منفعة المال لوغاريتمية the utility of money is logarithmic ".

إذا كانت المنفعة المرتبطة بخسارة إجمالية هي 1-، وكانت المرافق المرتبطة بعائدات 1 و2 و10 هي 1 و2 و4 على التوالي، فإن السعادة المتوقعة للاستثمار ستكون $0.5 \cdot (-1) + 0.4 \cdot 2 +$

$0.1 \cdot 4 = 0.7$ (خسارة فائدة متوقعة قدرها 30 ٪). إذا كانت هذه هي بالفعل دالة المنفعة utility function الخاصة بك، فقد يكون من الأفضل لك الاحتفاظ بالمالفي البنك.

بالنسبة للقرارات المالية، قد نرغب أيضًافي قياس مدى خطورة risky الاستثمار. هنا، لا نهتم فقط بالقيمة المتوقعة ولكن إلى أي مدى تميل القيم الفعلية إلى الاختلاف بالنسبة إلى هذه القيمة. لاحظ أنه لا يمكننا أن نأخذ فقط توقع الفرق بين القيم الفعلية والمتوقعة. وذلك لأن توقع الاختلاف هو اختلاف التوقعات، وبالتالي $E[X - E[X]] = E[X] - E[E[X]] = 0$. ومع ذلك، يمكننا أن ننظر إلى توقع أي دالة غير سلبية لهذا الاختلاف. يتم حساب التباينفي المتغير العشوائي من خلال النظر إلى القيمة المتوقعة للانحرافات التربيعية squared deviations:

$$\mathrm{Var}[X] = E[(X - E[X])^2] = E[X^2] - E[X]^2.$$

هنا تأتي المساواة من خلال توسيع $(X - E[X])^2 = X^2 - 2XE[X] + E[X]^2$ وأخذ التوقعات لكل مصطلح. الجذر التربيعي للتباين variance هو كمية مفيدة أخرى تسمى الانحراف المعياري standard deviation. بينما ينقل التباين والانحراف المعياري نفس المعلومات (يمكن حساب أي منهما من الآخر)، فإن الانحراف المعياري له خاصية لطيفة التي يتم التعبير عنهافي نفس الوحدات مثل الكمية الأصلية التي يمثلها المتغير العشوائي.

أخيرًا، يتم تعريف تباين دالة المتغير العشوائي بشكل مشابه

$$\mathrm{Var}_{x\sim P}[f(x)] = E_{x\sim P}[f^2(x)] - E_{x\sim P}[f(x)]^2.$$

بالعودة إلى مثالنا الاستثماري، يمكننا الآن حساب تباين الاستثمار. أعطيت $0.5 \cdot 0 + 0.4 \cdot 2^2 + 0.1 \cdot 10^2 - 1.8^2 = 8.36$. لجميع المقاصد والأغراض، هذا استثمار محفوف بالمخاطر. لاحظ أنه من خلال الاصطلاح الرياضي، غالبًا ما يشار إلى المتوسط والتباين كـ μ و σ^2. هذا شائع بشكل خاص عندما نستخدمه لتحديد توزيع غاوسي.

بنفس الطريقة التي قدمنا بها التوقعات والتباين للمتغيرات العشوائية العددية، يمكننا القيام بذلك للمتغيرات ذات القيمة المتجهية vector-valued ones. التوقعات سهلة، حيث يمكننا تطبيقها بطريقة أساسية. على سبيل المثال،$\boldsymbol{\mu} \stackrel{\mathrm{def}}{=} E_{\mathbf{x}\sim P}[\mathbf{x}]$ لديه إحداثيات $\mu_i = E_{\mathbf{x}\sim P}[x_i]$. التغايرات Covariances أكثر تعقيدًا. نقوم بحل المشكلة بأخذ توقعات الناتج الخارجي للفرق بين المتغيرات العشوائية ومتوسطها.

$$\boldsymbol{\Sigma} \stackrel{\mathrm{def}}{=} \mathrm{Cov}_{\mathbf{x}\sim P}[\mathbf{x}] = E_{\mathbf{x}\sim P}[(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^\top].$$

يشار إلى هذه المصفوفة بمصفوفة التغاير covariance matrix. طريقة سهلة لمعرفة تأثيرها هي النظرفي بعض المتجهات $\mathbf{v}$ بنفس حجم $\mathbf{x}$. إنه يتبع هذا

$$\mathbf{v}^\top \boldsymbol{\Sigma} \mathbf{v} = E_{\mathbf{x}\sim P}[\mathbf{v}^\top (\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^\top \mathbf{v}] = \mathrm{Var}_{x\sim P}[\mathbf{v}^\top \mathbf{x}].$$

على هذا النحو، $\boldsymbol{\Sigma}$ يسمح لنا بحساب التباين لأي دالة خطية لـ $\mathbf{x}$ من خلال ضرب مصفوفة بسيط. تخبرنا العناصر خارج القطر عن مدى ارتباط الإحداثيات: القيمة 0 تعني عدم وجود ارتباط no correlation، حيث تعني القيمة الإيجابية الأكبر أنها أكثر ارتباطًا strongly correlated.

2.6.7. المناقشة

في التعلم الآلي، هناك العديد من الأشياء التي يجب عدم التأكد بشأنها! يمكن أن نكون غير متأكدين من قيمة التسميةفي ضوء المدخلات. يمكن أن نكون غير متأكدين من القيمة المقدرة للمعلمة. يمكننا حتى أن نكون غير متأكدين مما إذا كانت البيانات التي تصل إلى النشر هي حتى من نفس التوزيع مثل بيانات التدريب.

من خلال عدم اليقين المتكرر aleatoric uncertainty، نشير إلى أن عدم اليقين المتأصلفي المشكلة، وبسبب العشوائية الحقيقية التي لا تحسبها المتغيرات المرصودة. من خلال عدم اليقين المعرفي epistemic uncertainty، نشير إلى عدم اليقين بشأن معلمات النموذج، وهو نوع عدم اليقين الذي نأملفي تقليله من خلال جمع المزيد من البيانات. قد يكون لدينا حالة من عدم اليقين المعرفي فيما يتعلق باحتمالية ظهور عملة ما، ولكن حتى بمجرد أن نعرف هذا الاحتمال، فإننا نشكفي عدم يقين دائم بشأن نتيجة أي رمية مستقبلية. بغض النظر عن المدة التي نشاهد فيها شخصًا ما يرمي عملة عادلة، فلن نكون أبدًا أكثر أو أقل من 50٪ على يقين من أن القرعة التالية ستظهر رأساً. تدين هذه المصطلحات إلى الأدبياتفي النمذجة الميكانيكية mechanical modeling (انظر على سبيل المثال، Der Kiureghian وDitlevsen (2009) لمراجعة هذا الجانب من عدم اليقين الكمي uncertainty quantification). من الجدير بالذكر أن هذه المصطلحات تشكل إساءة طفيفة للغة. يشير المصطلح المعرفي إلى أي شيء يتعلق بالمعرفة knowledge، وبالتالي بالمعنى الفلسفي، فإن كل عدم اليقين هو معرفي epistemic.

لقد رأينا أن أخذ العينات للبيانات من توزيع احتمالي غير معروف يمكن أن يزودنا بمعلومات يمكن استخدامها لتقدير معلمات توزيع توليد البيانات. ومع ذلك، فإن المعدل الذي يمكن به هذا يمكن أن يكون بطيئًا للغايةفي مثالنا لرمي العملات (والعديد من الأمثلة الأخرى) لا يمكننا أن نفعل أفضل من تصميم المقدّرات التي تتقارب بمعدل $1/\sqrt{n}$ حيث n حجم العينة (على سبيل المثال، عدد الرميات). هذا يعني أنه بالانتقال من 10 إلى 1000 ملاحظة (عادة ما تكون مهمة قابلة للتحقيق للغاية)، نرى انخفاضًا بمقدار عشرة أضعاففي عدم اليقين uncertainty، في حين أن الملاحظات الألف التالية تساعد قليلاً نسبيًا، حيث تقدم فقط تقليلًا بمقدار 1.41 مرة. هذه ميزة دائمة للتعلم الآلي:في حين أن هناك غالبًا مكاسب سهلة، فإنها تتطلب قدرًا كبيرًا جدًا من البيانات، وغالبًا ما تكون معها قدرًا هائلاً من الحسابات لتحقيق المزيد من المكاسب.

للحصول على مراجعة تجريبية لهذه الحقيقة لنماذج اللغة واسعة النطاق، انظر Revels et al. (2016).

كما شحذنا لغتنا وأدواتنا للنمذجة الإحصائية.في هذه العملية، تعلمنا عن الاحتمالات الشرطية وحول واحدة من أهم المعادلاتفي الإحصاء ـ نظرية بايز. إنها أداة فعالة لفصل المعلومات التي تنقلها البيانات من خلال مصطلح الاحتمالية $P(B \mid A)$ الذي يتناول مدى مطابقة الملاحظات B مع اختيار المعلمات A ، والاحتمال السابق $P(A)$ الذي يحكم مدى معقولية اختيار معين A كانفي المقام الأول. على وجه الخصوص، رأينا كيف يمكن تطبيق هذه القاعدة لتعيين الاحتمالات للتشخيص، بناءً على فعالية الاختبار وانتشار المرض نفسه (أي سابقنا).

أخيرًا، قدمنا مجموعة أولى من الأسئلة غير التافهة حول تأثير توزيع احتمالي محدد، وهي التوقعات expectations والتباينات variances.في حين أن هناك أكثر من مجرد توقعات خطية وتربيعية لتوزيع الاحتمالات، فإن هذين الأمرين يوفران بالفعل قدرًا جيدًا من المعرفة حول السلوك المحتمل للتوزيع. على سبيل المثال، تنص عدم المساواة Chebyshev's inequality على $P(|X - \mu| \geq k\sigma) \leq 1/k^2$ حيث μ هو التوقع،σ^2 هو تباين التوزيع،$k > 1$ وهو معيار ثقة من اختيارنا. يخبرنا أن السحب من التوزيع يكمنفي احتمال 50٪ على الأقل خلال فترة تتمحور حول التوقع $[-\sqrt{2}\sigma, \sqrt{2}\sigma]$.

2.6.8. التمارين

1. أعط مثالاً حيث يمكن أن تؤدي مراقبة المزيد من البيانات إلى تقليل مقدار عدم اليقين بشأن النتيجة إلى مستوى منخفض بشكل تعسفي.
2. أعط مثالاً حيث ستؤدي مراقبة المزيد من البيانات إلى تقليل مقدار عدم اليقين فقط إلى حد ما ثم لا أكثر. اشرح سبب حدوث ذلك وأين تتوقع حدوث هذه النقطة.
3. لقد أثبتنا تجريبياً التقارب مع متوسط رمي عملة معدنية. احسب التباينفي تقدير الاحتمال الذي نراه بعد سحب n من العينات.
    1. كيف يتناسب التباين مع عدد الملاحظات number of observations؟
    2. استخدم عدم المساواةفي Chebyshev للحد من الانحراف عن التوقع.
    3. كيف تتصل بنظرية الحد المركزي central limit theorem؟

2.7. التوثيق Documentation

بينما لا يمكننا تقديم كل دالة وفئة TensorFlow فردية (وقد تصبح المعلومات قديمة بسرعة)، توفر وثائق API والبرامج التعليمية والأمثلة الإضافية مثل هذا التوثيق documentation. يقدم هذا القسم بعض الإرشادات حول كيفية استكشاف TensorFlow API.

2.7.1. دوال وفئات في الوحدة المنطية Functions and Classes in a Module

من أجل معرفة الدوال والفئات التي يمكن استدعاؤهافي وحدة نمطية، نستدعي الدالة `dir`. على سبيل المثال، يمكننا الاستعلام عن جميع الخصائصفي الوحدة لتوليد أرقام عشوائية:

```
['Algorithm', 'Generator', '__builtins__', '__cached__',
'__doc__', '__file__', '__loader__', '__name__',
'__package__', '__path__', '__spec__', '_sys',
'all_candidate_sampler', 'categorical',
'create_rng_state', 'experimental',
'fixed_unigram_candidate_sampler', 'gamma',
'get_global_generator',
'learned_unigram_candidate_sampler',
'log_uniform_candidate_sampler', 'normal', 'poisson',
'set_global_generator', 'set_seed', 'shuffle',
'stateless_binomial', 'stateless_categorical',
'stateless_gamma', 'stateless_normal',
'stateless_parameterized_truncated_normal',
'stateless_poisson', 'stateless_truncated_normal',
'stateless_uniform', 'truncated_normal', 'uniform',
'uniform_candidate_sampler']
```

بشكل عام، يمكننا تجاهل الدوال التي تبدأ وتنتهي بـ __ (كائنات خاصةفي بايثون) أو الدوال التي تبدأ بـ _ (عادةً دوال داخلية). استنادًا إلى أسماء الدوال أو السمات المتبقية، قد نخاطر بتخمين أن هذه الوحدة تقدم طرقًا مختلفة لتوليد أرقام عشوائية، بمافي ذلك أخذ العينات من التوزيع المنتظم (`uniform`) والتوزيع الطبيعي (`normal`) والتوزيع متعدد الحدود (`multinomial`).

2.7.2. دوال وفئات محددة Specific Functions and Classes

لمزيد من الإرشادات المحددة حول كيفية استخدام دالة أو فئة معينة، يمكننا استدعاء دالة `help`. كمثال، دعنا نستكشف تعليمات الاستخدام لدالة موترات `ones`.

```
ones
```

```
Help on function ones in module
tensorflow.python.ops.array_ops:

ones(shape, dtype=tf.float32, name=None)
    Creates a tensor with all elements set to one
(1).

    See also tf.ones_like, tf.zeros, tf.fill,
tf.eye.

    This operation returns a tensor of type dtype
with shape shape and
    all elements set to one.

    >>> tf.ones([3, 4], tf.int32)
    <tf.Tensor: shape=(3, 4), dtype=int32, numpy=
    array([[1, 1, 1, 1],
           [1, 1, 1, 1],
           [1, 1, 1, 1]], dtype=int32)>

    Args:
      shape: A list of integers, a tuple of
integers, or
        a 1-D Tensor of type int32.
      dtype: Optional DType of an element in the
resulting Tensor. Default is
        tf.float32.
      name: Optional string. A name for the
operation.

    Returns:
      A Tensor with all elements set to one (1).
```

من الوثائق documentation، يمكننا أن نرى أن الدالة one تنشئ موترًا جديدًا بالشكل المحدد وتضبط جميع العناصر على القيمة 1. كلما أمكن، يجب عليك إجراء اختبار سريع لتأكيد التفسير الخاص بك:

```
tf.ones(4)
```

```
<tf.Tensor: shape=(4,), dtype=float32, numpy=array([1.,
1., 1., 1.], dtype=float32)>
```

في نوتبوك Jupyter، يمكننا استخدام `?` لعرض المستندفي نافذة أخرى. على سبيل المثال، `list?` سيُنشئ محتوى مطابقًا تقريبًا لـ `help(list)`، ويعرضهفي نافذة متصفح جديدة.

بالإضافة إلى ذلك، إذا استخدمنا علامتي استفهام، مثل `list??`، فسيتم أيضًا عرض كود بايثون الذي ينفذ الدالة.

يوفر التوثيق الرسمي الكثير من الأوصاف والأمثلة التي تتجاوز هذا الكتاب. ينصب تركيزنا على تغطية حالات الاستخدام المهمة التي ستتيح لك البدء بسرعةفي المشكلات العملية، بدلاً من اكتمال التغطية. نشجعك أيضًا على دراسة الكود المصدري للمكتبات لمشاهدة أمثلة على تطبيقات عالية الجودة لكود الإنتاج. من خلال القيام بذلك، ستصبح مهندسًا أفضل بالإضافة إلى أن تصبح عالماً أفضل.

3

الشبكات العصبية الخطية للانحدار

3. الشبكات العصبية الخطية للانحدار Linear Neural Networks for Regression

قبل أن نقلق بشأن جعل شبكاتنا العصبية عميقة deep، سيكون من المفيد تنفيذ بعض الشبكات العصبية الضحلة shallow neural networks، والتي تتصل مدخلاتها مباشرة بالمخرجات. سيثبت هذا أهميته لعدة أسباب. أولاً، بدلاً من تشتيت الانتباه بسبب البنى المعقدة، يمكننا التركيز على أساسيات تدريب الشبكة العصبية، بمافي ذلك تحديد معلمات طبقة الإخراج، ومعالجة البيانات، وتحديد دالة الخطأ، وتدريب النموذج. ثانيًا، تتكون هذه الفئة من الشبكات الضحلة لتشمل مجموعة من النماذج الخطية، والتي تشمل العديد من الطرق الكلاسيكية للتنبؤ الإحصائي، بمافي ذلك الانحدار الخطي linear regression وانحدار Softmax. يعد فهم هذه الأدوات الكلاسيكية أمرًا محوريًا لأنها تُستخدم على نطاق واسعفي العديد من السياقات وسنحتاج غالبًا إلى استخدامها كخطوط أساسية عند تبرير استخدام معماريات مختلفة. سيركز هذا الفصل بشكل ضيق على الانحدار الخطي وسيعمل الفصل التالي على توسيع مجموعة النمذجة لدينا من خلال تطوير شبكات عصبية خطية من أجل التصنيف classification.

3.1. الانحدار الخطي Linear Regression

تظهر مشاكل الانحدار Regression problems كلما أردنا توقع قيمة عددية. تشمل الأمثلة الشائعة التنبؤ بالأسعار (للمنازل، والمخزون، وما إلى ذلك)، والتنبؤ بطول الإقامة (للمرضىفي المستشفى)، والتنبؤ بالطلب (لمبيعات التجزئة)، من بين أمور أخرى لا حصر لها. ليست كل مشكلة تنبؤ مشكلة انحدار كلاسيكية.في وقت لاحق، سوف نقدم مشاكل التصنيف classification problems، حيث الهدف هو التنبؤ بالعضوية بين مجموعة من الفئات.

كمثال جار، لنفترض أننا نرغبفي تقدير أسعار المنازل (بالدولار) بناءً على مساحتها (بالأقدام المربعة) والعمر (بالسنوات). لتطوير نموذج للتنبؤ بأسعار المنازل، نحتاج إلى الحصول على بيانات تتكون من المبيعات، بمافي ذلك سعر البيع والمساحة والعمر لكل منزل.في مصطلحات التعلم الآلي، تسمى مجموعة البيانات dataset مجموعة بيانات التدريب training dataset أو مجموعة التدريب training set، ويسمى كل صف (يحتوي على البيانات المقابلة لعملية بيع واحدة) بمثال (أو نقطة بيانات data point ، مثال instance ، عينة sample). الشيء الذي نحاول توقعه (السعر) يسمى التسمية label (أو الهدف target). تسمى المتغيرات (العمر والمنطقة) التي تستند إليها التنبؤات الميزات (أو المتغيرات المشتركة covariates).

3.1.1. الأساسيات Basics

قد يكون الانحدار الخطي Linear regression هو الأبسط والأكثر شيوعًا بين الأدوات القياسية لمعالجة مشاكل الانحدار. يعود تاريخ الانحدار الخطي إلى فجر القرن التاسع عشر (Gauss، 1809، Legendre، 1805)، ويتدفق الانحدار الخطي من بعض الافتراضات البسيطة. أولاً، نفترض أن العلاقة بين الميزات $\mathbf{x}$ والهدف y خطية تقريبًا، أي أنه يمكن التعبير عن المتوسط الشرطي $E[Y \mid X = \mathbf{x}]$ كمجموع وزني للسمات $\mathbf{x}$. يسمح هذا الإعداد بأن القيمة المستهدفة قد لا تزال تنحرف عن قيمتها المتوقعة بسبب ضوضاء المراقبة observation noise. بعد ذلك، يمكننا فرض افتراض أن أي ضوضاء من هذا القبيل حسن التصرف، بعد توزيع غاوسي. عادة، سنستخدم n للإشارة إلى عدد الأمثلةفي مجموعة البيانات الخاصة بنا. نحن نستخدم النصوص الفوقية superscripts لتعداد العينات والأهداف، والنصوص التحتية subscripts لفهرسة الإحداثيات. بشكل ملموس،$\mathbf{x}^{(i)}$ يشير إلى العينة ith و $x_j^{(i)}$ يدل على إحداثياتها jth.

3.1.1.1. النموذج Model

يوجدفي قلب كل حل نموذج يصف كيف يمكن تحويل الميزات إلى تقدير للهدف. يعني افتراض الخطية أنه يمكن التعبير عن القيمة المتوقعة للهدف target (السعر) كمجموع اوزان للسمات features (المنطقة والعمر):

$$\text{price} = w_{\text{area}} \cdot \text{area} + w_{\text{age}} \cdot \text{age} + b. \qquad 3.1.1$$

هنا w_{area} وw_{age} تسمى الأوزان weights، وتسمى b التحيز bias (أو الإزاحة offset أو التقاطع intercept). تحدد الأوزان تأثير كل ميزة على تنبؤاتنا. يحدد التحيز قيمة التقدير عندما تكون جميع الميزات صفرية. على الرغم من أننا لن نرى أبدًا أي منازل مبنية حديثًا بمساحة صفر بالضبط، إلا أننا ما زلنا بحاجة إلى التحيز لأنه يسمح لنا بالتعبير عن جميع الدوال الخطية لميزاتنا (مقابل تقييدنا بالخطوط التي تمر عبر الأصل). بالمعنى الدقيق للكلمة، عبارة عن تحويل أفيني لميزات الإدخال، والتي تتميز بتحويل خطي للميزات عبر مجموع الاوزان، جنبًا إلى جنب مع الترجمة عبر التحيز الإضافي. بالنظر إلى مجموعة البيانات، فإن هدفنا هو اختيار الأوزان $\mathbf{w}$ والانحياز b ،في المتوسط، يجعل توقعات نموذجنا تتناسب مع الأسعار الحقيقية التي لوحظت في البيانات بأكبر قدر ممكن.

في التخصصات التي يكون من الشائع فيها التركيز على مجموعات البيانات مع بعض الميزات فقط، والتعبير الواضح عن النماذج طويلة الشكل، كمافي (3.1.1)، أمر شائع.في التعلم الآلي، نعمل عادةً مع مجموعات البيانات عالية الأبعاد high-dimensional datasets، حيث يكون من الملائم استخدام تدوين الجبر الخطي المدمج. عندما تتكون مدخلاتنا من d ميزات، يمكننا

تعيين فهرس لكل منها (بين 1 و d) والتعبير عن توقعاتنا $\hat{y}$ (بشكل عام، يشير رمز "القبعة hat" إلى تقدير estimate)

$$\hat{y} = w_1 x_1 + \cdots + w_d x_d + b. \qquad 3.1.2$$

بتجميع كل الميزاتفي متجه $\mathbf{x} \in \mathbb{R}^d$ وجميع الأوزانفي متجه $\mathbf{w} \in \mathbb{R}^d$، يمكننا التعبير عن نموذجنا بشكل مضغوط عبر الضرب النقطي بين $\mathbf{w}$ و $\mathbf{x}$:

$$\hat{y} = \mathbf{w}^\top \mathbf{x} + b. \qquad 3.1.3$$

في (3.1.3)، يتوافق المتجه $\mathbf{x}$ مع ميزات مثال واحد. غالبًا ما نجد أنه من الملائم الرجوع إلى ميزات مجموعة البيانات الكاملة للأمثلة n عبر مصفوفة التصميم $\mathbf{X} \in \mathbb{R}^{n \times d}$. هنا،$\mathbf{X}$ يحتوي على صف واحد لكل مثال وعمود واحد لكل ميزة. لمجموعة من الميزات $\mathbf{X}$ والتنبؤات $\hat{\mathbf{y}} \in \mathbb{R}^n$ يمكن التعبير عنها عبر حاصل ضرب المصفوفة–المتجه matrix-vector product:

$$\hat{y} = \mathbf{X}\mathbf{w} + b, \qquad 3.1.4$$

حيث يتم تطبيق البث broadcasting (القسم 2.1.4) أثناء عملية الجمع. بالنظر إلى ميزات مجموعة بيانات التدريب $\mathbf{X}$ والتسميات المقابلة (المعروفة) $\mathbf{y}$، فإن الهدف من الانحدار الخطي هو العثور على متجه الوزن $\mathbf{w}$ ومصطلح التحيز b الذي يعطى ميزات لمثال بيانات جديد مأخوذ من نفس التوزيع مثل $\mathbf{X}$، فإن تسمية المثال الجديد سوف (في التوقع) يتوقع بأقل خطأ.

حتى إذا كنا نعتقد أن أفضل نموذج للتنبؤ بـ y معطى $\mathbf{x}$ هو خطي، فإننا لا نتوقع العثور على مجموعة بيانات حقيقية من الأمثلة n حيث $y^{(i)}$ تساوي تمامًا $\mathbf{w}^\top \mathbf{x}^{(i)} + b$ لكل $1 \leq i \leq n$. على سبيل المثال، أيا كانت الأدوات التي نستخدمها لمراقبة الميزات $\mathbf{X}$ والتسميات $\mathbf{y}$ قد تعاني من قدر ضئيل من أخطاء القياس measurement error. وبالتالي، حتى عندما نكون واثقين من أن العلاقة الأساسية خطية، فسنقوم بتضمين مصطلح ضوضاء noise لتفسير مثل هذه الأخطاء.

قبل أن نتمكن من البحث عن أفضل المعلمات parameters (أو معلمات النموذج model parameters) $\mathbf{w}$ و b، سنحتاج إلى شيئين آخرين: (1) مقياس جودة لبعض النماذج المحددة؛ و (2) إجراء لتحديث النموذج لتحسين جودته.

3.1.1.2. دالة الخطأ Loss Function

بطبيعة الحال، يتطلب ملاءمة fitting نموذجنا للبيانات أن نتفق على بعض مقاييس الملاءمة fitness (أو، على نحو مكافئ، عدم اللياقة unfitness). تحدد دوال الخطأ Loss functions

المسافة بين القيم الحقيقية real والمتوقعة predicted للهدف. ستكون الخسارة (الخطأ) عادةً رقمًا غير سالب حيث تكون القيم الأصغر أفضل وتتحمل التنبؤات الكاملة خسارة قدرها 0. بالنسبة لمشاكل الانحدار، فإن دالة الخسارة الأكثر شيوعًا هي الخطأ التربيعي squared error. عندما يكون توقعنا للحصول على مثال i هو $\hat{y}^{(i)}$ والتسمية الحقيقية المقابلة هي $y^{(i)}$، الخطأ التربيعي مُعطى بواسطة:

$$l^{(i)}(\mathbf{w}, b) = \frac{1}{2}(\hat{y}^{(i)} - y^{(i)})^2. \qquad 3.1.5$$

لا يُحدث الثابت $\frac{1}{2}$ فرقًا حقيقيًا ولكنه يثبت أنه ملائم من الناحية المعيارية، لأنه يُلغى عندما نأخذ مشتق الخطأ. نظرًا لأن مجموعة بيانات التدريب تُمنح لنا، وبالتالي فهي خارجة عن سيطرتنا، فإن الخطأ التجريبي ليس سوى دالة لمعلمات النموذج. أدناه، نتخيل ملاءمة نموذج الانحدار الخطيفي مشكلة ذات مدخلات أحادية البعد (الشكل 3.1.1).

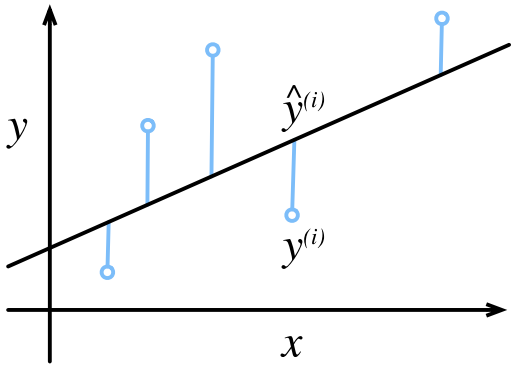

الشكل 3.1.1 ملائمة نموذج الانحدار الخطي لبيانات أحادية البعد.

لاحظ أن الفروق الكبيرة بين التقديرات $\hat{y}^{(i)}$ والأهداف $y^{(i)}$ تؤدي إلى مساهمات أكبرفي الخسارة، بسبب الشكل التربيعي quadratic form للخسارة (يمكن أن يكون هذا سيفًا مزدوج الحافة. بينما يشجع النموذج على تجنب الأخطاء الكبيرة، فإنه يمكن أن يؤدي أيضًا إلى حساسية مفرطة للبيانات الشاذة anomalous data). لقياس جودة نموذجفي مجموعة البيانات الكاملة ل n من الأمثلة، نقوم ببساطة بمتوسط (أو بشكل مكافئ، جمع) الخسائرفي مجموعة التدريب:

$$L(\mathbf{w}, b) = \frac{1}{n}\sum_{i=1}^{n} l^{(i)}(\mathbf{w}, b) = \frac{1}{n}\sum_{i=1}^{n} \frac{1}{2}(\mathbf{w}^\top \mathbf{x}^{(i)} + b - y^{(i)})^2.$$

عند تدريب النموذج، نريد العثور على المعلمات $(\mathbf{w}^*, b^*)$ التي تقلل الخسارة الإجمالية عبر جميع أمثلة التدريب:

$$\mathbf{w}^*, b^* = \underset{\mathbf{w},b}{\operatorname{argmin}}\, L(\mathbf{w}, b).$$

3.1.1.3. الحل التحليلي Analytic Solution

على عكس معظم النماذج التي سنغطيها، يقدم لنا الانحدار الخطي مشكلة تحسين سهلة بشكل مدهش. على وجه الخصوص، يمكننا العثور على المعلمات المثلى (كما تم تقييمهافي بيانات التدريب) بشكل تحليلي من خلال تطبيق صيغة بسيطة على النحو التالي. أولاً، يمكننا تضمين التحيز b في المعلمة $\mathbf{w}$ من خلال إلحاق عمود بمصفوفة التصميم المكونة من جميع العناصر. إذن مشكلة التنبؤ لدينا هي تقليل $\|\mathbf{y} - \mathbf{X}\mathbf{w}\|^2$. طالما أن مصفوفة التصميم $\mathbf{X}$ لها رتبة كاملة (لا توجد ميزة تعتمد خطيًا على العناصر الأخرى)، عندئذٍ ستكون هناك نقطة حرجة واحدة فقط على سطح الخسارة وتتوافق مع الحد الأدنى من الخسارة على المجال بأكمله. أخذ مشتق الخسارة فيما يتعلق بـ $\mathbf{w}$ وجعله يساوي صفر عوائد:

$$\partial_{\mathbf{w}}\|\mathbf{y} - \mathbf{X}\mathbf{w}\|^2 = 2\mathbf{X}^\top(\mathbf{X}\mathbf{w} - \mathbf{y}) = 0 \text{ and hence } \mathbf{X}^\top\mathbf{y} = \mathbf{X}^\top\mathbf{X}\mathbf{w}.$$

يوفر لنا حل $\mathbf{w}$ الحل الأمثل لمشكلة التحسين optimization problem. لاحظ أن هذا الحل

$$\mathbf{w}^* = (\mathbf{X}^\top\mathbf{X})^{-1}\mathbf{X}^\top\mathbf{y}$$

ستكون فريدة فقط عندما تكون المصفوفة $\mathbf{X}^\top\mathbf{X}$ قابلة للعكس invertible، أي عندما تكون أعمدة مصفوفة التصميم مستقلة خطيًا (Golub and Van Loan، 1996).

في حين أن المشكلات البسيطة مثل الانحدار الخطي قد تقبل حلولًا تحليلية، يجب ألا تعتاد على مثل هذا الحظ الجيد. على الرغم من أن الحلول التحليلية تسمح بتحليل رياضي لطيف، إلا أن متطلبات الحل التحليلي مقيدة للغاية بحيث تستبعد تقريبًا جميع الجوانب المثيرة للتعلم العميق.

3.1.1.4. الانحدار التدريجي العشوائي ذو الدفعات الصغيرة Minibatch Stochastic Gradient Descent

لحسن الحظ، حتىفي الحالات التي لا يمكننا فيها حل النماذج بشكل تحليلي، لا يزال بإمكاننا تدريب النماذج بفعاليةفي الممارسة العملية. علاوة على ذلك، بالنسبة للعديد من المهام، يتبين أن تلك النماذج التي يصعب تحسينها أفضل بكثير لدرجة أن اكتشاف كيفية تدريبها ينتهي به الأمر يستحق العناء.

تتمثل التقنية الرئيسية لتحسين أي نموذج تعلم عميق تقريبًا، والتي سوف ندعو إليها خلال هذا الكتاب،في تقليل الخطأ بشكل متكرر عن طريق تحديث المعلماتفي الاتجاه الذي يقلل بشكل تدريجي من دالة الخسارة. هذه الخوارزمية تسمى التدرج الاشتقاقي (الانحدار الاشتقاقي) gradient descent.

يتمثل التطبيق الأكثر سذاجة للتدرج الاشتقاقيفي أخذ مشتق دالة الخسارة، وهو متوسط الخسائر المحسوبةفي كل مثال فرديفي مجموعة البيانات. من الناحية العملية، يمكن أن يكون هذا بطيئًا للغاية: يجب أن نمرر مجموعة البيانات بأكملها قبل إجراء تحديث واحد، حتى لو كانت خطوات التحديث قوية جدًا (Liu and Nocedal، 1989). والأسوأ من ذلك، إذا كان هناك الكثير من التكرارفي بيانات التدريب، فإن فائدة التحديث الكامل تكون أقل.

الطرف الآخر هو النظرفي مثال واحد فقطفي كل مرة واتخاذ خطوات التحديث بناءً على ملاحظة واحدةفي كل مرة. يمكن أن تكون الخوارزمية الناتجة، التدرج الاشتقاقي العشوائي stochastic gradient descent (SGD) استراتيجية فعالة (Bottou، 2010)، حتى بالنسبة لمجموعات البيانات الكبيرة. لسوء الحظ، فإن SGD لها عيوب، حسابية وإحصائية. تنشأ مشكلة واحدة من حقيقة أن المعالجات تضرب وتضيف الأرقام أسرع بكثير مما هي عليهفي نقل البيانات من الذاكرة الرئيسية إلى ذاكرة التخزين المؤقت للمعالج. الأمر الذي يصل إلى مرتبة المقدار order of magnitude هو أكثر كفاءة لإجراء عملية ضرب المصفوفة_المتجه مقارنة بعدد مماثل من عمليات ضرب المتجه_المتجه. هذا يعني أن معالجة عينة واحدةفي كل مرة قد تستغرق وقتًا أطول بكثير مقارنة بالدفعة الكاملة. المشكلة الثانية هي أن بعض الطبقات، مثل تسوية الدُفعات batch normalization (سيتم وصفهافي القسم 8.5)، تعمل بشكل جيد فقط عندما يكون لدينا وصول إلى أكثر من ملاحظة واحدةفي كل مرة.

الحل لكلتا المشكلتين هو اختيار استراتيجية وسيطة: بدلاً من أخذ دفعة كاملة أو عينة واحدة فقط في كل مرة، نأخذ دفعة صغيرة minibatch من الملاحظات (Li et al.، 2014). يعتمد الاختيار المحدد لحجم الدفعة الصغيرة المذكور على العديد من العوامل، مثل مقدار الذاكرة وعدد المعجلات واختيار الطبقات وإجمالي حجم مجموعة البيانات. على الرغم من كل ذلك، فإن الرقم بين 32 و256، ويفضل أن يكون مضاعفًا لقوة كبيرة، يعد بداية جيدة. هذا يقودنا إلى الانحدار التدريجي العشوائي ذو الدفعات الصغيرة minibatch stochastic gradient descent.

في أبسط أشكالها،في كل تكرار t ، نقوم أولاً بأخذ عينة عشوائية من الدفعات الصغيرة $\mathcal{B}_t$ يتكون من عدد ثابت $|\mathcal{B}|$ من أمثلة التدريب. نقوم بعد ذلك بحساب مشتق (التدرج او الانحدار gradient) لمتوسط الخسارة على minibatch فيما يتعلق بمعلمات النموذج. أخيرًا، نضرب

التدرجفي قيمة موجبة صغيرة محددة مسبقًا η ، تسمى معدل التعلم learning rate، ونطرح المصطلح الناتج من قيم المعلمة الحالية. يمكننا التعبير عن التحديث على النحو التالي:

$$(\mathbf{w}, b) \leftarrow (\mathbf{w}, b) - \frac{\eta}{|\mathcal{B}|}\sum_{i\in\mathcal{B}_t} \partial_{(\mathbf{w},b)} l^{(i)}(\mathbf{w}, b).$$

باختصار، يتم تنفيذ minibatch SGD على النحو التالي: (1) تهيئة قيم معلمات النموذج، عادةً بشكل عشوائي؛ (2) أخذ عينات متكررة من الدفعات الصغيرة العشوائية من البيانات، وتحديث المعلماتفي اتجاه التدرج السالب. بالنسبة للخسائر التربيعية والتحولات المرتبطة، فإن هذا له توسع مغلق الشكل:

$$\begin{aligned}
\mathbf{w} &\leftarrow \mathbf{w} - \frac{\eta}{|\mathcal{B}|}\sum_{i\in\mathcal{B}_t} \partial_{\mathbf{w}} l^{(i)}(\mathbf{w}, b) &&= \mathbf{w} - \frac{\eta}{|\mathcal{B}|}\sum_{i\in\mathcal{B}_t} \mathbf{x}^{(i)}(\mathbf{w}^\top \mathbf{x}^{(i)} + b - y^{(i)}) \\
b &\leftarrow b - \frac{\eta}{|\mathcal{B}|}\sum_{i\in\mathcal{B}_t} \partial_b l^{(i)}(\mathbf{w}, b) &&= b - \frac{\eta}{|\mathcal{B}|}\sum_{i\in\mathcal{B}_t} (\mathbf{w}^\top \mathbf{x}^{(i)} + b - y^{(i)}).
\end{aligned}$$

نظرًا لأننا نختار دفعات صغيرة $\mathcal{B}$، فنحن بحاجة إلى التسوية normalize من خلال حجمه $|\mathcal{B}|$. في كثير من الأحيان يتم تحديد حجم الدفعات الصغيرة ومعدل التعلم من قبل المستخدم. تسمى هذه المعلمات القابلة للضبط التي لم يتم تحديثهافي حلقة التدريب بالمعلمات الفائقة hyperparameters. يمكن ضبطها تلقائيًا من خلال عدد من التقنيات، مثل تحسين بايزي Bayesian optimization (Frazier، 2018)في النهاية، يتم تقييم جودة الحل عادةً على مجموعة بيانات تحقق منفصلة separate validation dataset (أو مجموعة التحقق من الصحة validation set).

بعد التدريب على عدد محدد مسبقًا من التكرارات iterations (أو حتى يتم استيفاء معيار إيقاف آخر)، نسجل معلمات النموذج المقدرة، المشار إليها $\hat{\mathbf{w}}, \hat{b}$. لاحظ أنه حتى لو كانت دالتنا خطية حقًا وبدون ضوضاء، فلن تكون هذه المعلمات هي الحد الأدنى الدقيق للخسارة، أو حتى حتمية. على الرغم من أن الخوارزمية تتقارب ببطء نحو المصغرات minimizers، إلا أنها لا تستطيع تحقيقها بالضبطفي عدد محدود من الخطوات. علاوة على ذلك، يتم اختيار الدفعات الصغيرة $\mathcal{B}$ المستخدمة لتحديث المعلمات عشوائيًا. هذا يكسر الحتمية determinism.

يحدث الانحدار الخطي ليكون مشكلة تعليمية بحد أدنى عالمي (كلما كانت $\mathbf{X}$ ذات رتبة كاملة، أو ما يعادلها، كلما كان $\mathbf{X}^\top\mathbf{X}$ قابلاً للعكس). ومع ذلك، فإن الأسطح الخاسرة للشبكات العميقة تحتوي على العديد من نقاط السرج saddle points والحد الأدنى minima. لحسن الحظ، لا نهتم عادةً بإيجاد مجموعة محددة من المعلمات ولكن فقط أي مجموعة من المعلمات تؤدي إلى تنبؤات دقيقة (وبالتالي خطأ منخفض). من الناحية العملية، نادرًا ما يكافح ممارسو التعلم العميق للعثور على معايير تقلل من الخطأفي مجموعات التدريب (Frankle and Carbin،

2018، Izmailov et al.، 2018). المهمة الأكثر صعوبة هي العثور على المعلمات التي تؤدي إلى تنبؤات دقيقة حول البيانات غير المرئية من قبل unseen data، وهو تحد يسمى التعميم generalization. نعود إلى هذه المواضيع في جميع أنحاء الكتاب.

3.1.1.5. التنبؤات Predictions

بالنظر إلى النموذج $\hat{\mathbf{w}}^\top \mathbf{x} + \hat{b}$، يمكننا الآن عمل تنبؤات لمثال جديد، على سبيل المثال، للتنبؤ بسعر بيع منزل لم يسبق رؤيته في ضوء مساحته وعمره. اعتاد ممارسو التعلم العميق على استدعاء استدلال inference مرحلة التنبؤ ولكن هذا نوع من التسمية الخاطئة misnomer – يشير الاستدلال على نطاق واسع إلى أي استنتاج تم التوصل إليه على أساس الأدلة، بما في ذلك قيم المعلمات والتسمية المحتملة لمثيل غير مرئي. إذا كان هناك أي شيء، في كثير من الأحيان يشير الاستدلال في الأدبيات الإحصائية إلى استدلال المعلمات وهذا التحميل الزائد للمصطلحات يخلق ارتباكًا غير ضروري عندما يتحدث ممارسو التعلم العميق إلى الإحصائيين. فيما يلي سوف نتمسك بالتنبؤ كلما أمكن ذلك.

3.1.2. التوجيه من أجل السرعة Vectorization for Speed

عند تدريب نماذجنا، نريد عادةً معالجة مجموعات صغيرة كاملة من الأمثلة في وقت واحد. يتطلب القيام بذلك بكفاءة أن نقوم بتوجيه vectorize الحسابات والاستفادة من مكتبات الجبر الخطية السريعة بدلاً من كتابة الحلقات المكلفة في بايثون.

```
%matplotlib inline
import math
import time
import numpy as np
import tensorflow as tf
from d2l import tensorflow as d2l
```

لتوضيح سبب أهمية هذا كثيرًا، يمكننا التفكير في طريقتين لإضافة المتجهات. للبدء، نقوم بإنشاء مثيل لمتجهين كل منهما 10,000 بعد يحتويان على جميع المتجهات. في إحدى الطرق، نقوم بعمل حلقة فوق المتجهات باستخدام Python for-loop. في الطريقة الأخرى، نعتمد على استدعاء واحد لـ +.

```
n = 10000
a = tf.ones(n)
b = tf.ones(n)
```

الآن يمكننا قياس أعباء العمل. أولاً، نضيفهم، إحداثي واحد في كل مرة، باستخدام حلقة for-loop.

```
c = tf.Variable(tf.zeros(n))
t = time.time()
for i in range(n):
    c[i].assign(a[i] + b[i])
f'{time.time() - t:.5f} sec'
```

```
'9.45401 sec'
```

بدلاً من ذلك، نعتمد على العامل + المعاد تحميله لحساب مجموع العناصر.

```
t = time.time()
d = a + b
f'{time.time() - t:.5f} sec'
```

```
'0.00031 sec'
```

الطريقة الثانية أسرع بشكل كبير من الطريقة الأولى. غالبًا ما ينتج عن التعليمات البرمجية الموجهية Vectorizing code تسريع من حيث الحجم. علاوة على ذلك، نقوم بدفع المزيد من الرياضيات إلى المكتبة دون الحاجة إلى كتابة أكبر عدد من العمليات الحسابية بأنفسنا، مما يقلل من احتمالية حدوث أخطاء ويزيد من إمكانية نقل الشفرة.

3.1.3. التوزيع الطبيعي ومربع الخطأ The Normal Distribution and Squared Loss

لقد قدمنا حتى الآن حافزًا وظيفيًا إلى حد ما لهدف الخطأ التربيعية: تعيد المعلمات المثلى التوقع الشرطي $E[Y \mid X]$ عندما يكون النمط الأساسي خطيًا حقًا، وتعين الخطأ عقوبات كبيرة للقيم المتطرفة outliers. يمكننا أيضًا توفير دافع رسمي أكثر لهدف الخطأ التربيعية من خلال وضع افتراضات احتمالية حول توزيع الضوضاء.

تم اختراع الانحدار الخطيفي مطلع القرن التاسع عشر. على الرغم من أنه قد نوقش منذ فترة طويلة ما إذا كان Gauss أو Legendre قد فكرفي الفكرة لأول مرة، إلا أن Gauss هو الذي اكتشف أيضًا التوزيع الطبيعي normal distribution (يسمى أيضًا Gaussian). اتضح أن التوزيع الطبيعي والانحدار الخطي مع الخطأ التربيعي يشتركانفي اتصال أعمق من النسب الشائعة.

للبدء، تذكر أنه يتم إعطاء التوزيع الطبيعي بمتوسط μ وتباين σ^2 (الانحراف المعياري σ)

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(x-\mu)^2\right).$$

نحدد أدناه دالة لحساب التوزيع الطبيعي.

```
def normal(x, mu, sigma):
    p = 1 / math.sqrt(2 * math.pi * sigma**2)
    return p * np.exp(-0.5 * (x - mu)**2 / sigma**2)
```

يمكننا الآن رسم التوزيعات الطبيعية.

```
# Use numpy again for visualization
x = np.arange(-7, 7, 0.01)

# Mean and standard deviation pairs
params = [(0, 1), (0, 2), (3, 1)]
d2l.plot(x, [normal(x, mu, sigma) for mu, sigma in
params], xlabel='x',
         ylabel='p(x)', figsize=(4.5, 2.5),
         legend=[f'mean {mu}, std {sigma}' for mu, sigma
in params])
```

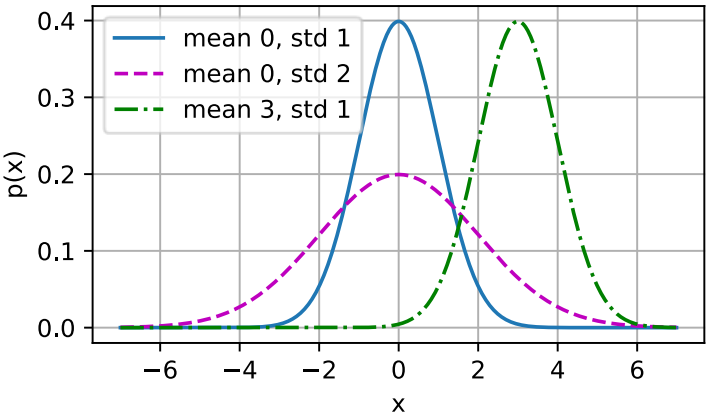

لاحظ أن تغيير المتوسط يتوافق مع التحول على طول المحور x ، وزيادة التباين يؤدي إلى انتشار التوزيع، مما يقلل من ذروته.

تتمثل إحدى طرق تحفيز الانحدار الخطي بخطأ مربعفي افتراض أن الملاحظات تنشأ من القياسات الصاخبة، حيث يتم توزيع الضوضاء عادةً على النحو التالي:

$$y = \mathbf{w}^\top \mathbf{x} + b + \epsilon \text{ where } \epsilon \sim \mathcal{N}(0, \sigma^2).$$

وبالتالي، يمكننا الآن كتابة احتمالية likelihood رؤية y معين لـ $\mathbf{x}$ عبر

$$P(y \mid \mathbf{x}) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(y - \mathbf{w}^\top \mathbf{x} - b)^2\right).$$

على هذا النحو، فإن الاحتمالية عوامل likelihood factorizes. وفقًا لمبدأ الحد الأقصى من الاحتمالية principle of maximum likelihood، فإن أفضل قيم المعلمات $\mathbf{w}$ و b هي تلك التي تزيد من احتمالية مجموعة البيانات بأكملها:

$$P(\mathbf{y} \mid \mathbf{X}) = \prod_{i=1}^{n} \quad p(y^{(i)} \mid \mathbf{x}^{(i)}).$$

تتبع المساواة equality منذ أن تم رسم جميع الأزواج $(\mathbf{x}^{(i)}, y^{(i)})$ بشكل مستقل عن بعضها البعض. تسمى التقديرات المختارة وفقًا لمبدأ الاحتمالية القصوى بمقدرات الاحتمالية القصوى maximum likelihood estimators.في حين أن تكبير ناتج العديد من الدوال الأسية قد يبدو صعبًا، يمكننا تبسيط الأشياء بشكل كبير، دون تغيير الهدف، من خلال تعظيم لوغاريتم الاحتمال بدلاً من ذلك. لأسباب تاريخية، غالبًا ما يتم التعبير عن التحسينات على أنها تصغير minimization بدلاً من تكبير maximization. لذلك، بدون تغيير أي شيء، يمكننا تقليل احتمالية السجل السلبية negative log-likelihood، والتي يمكننا التعبير عنها على النحو التالي:

$$-\log P(\mathbf{y} \mid \mathbf{X}) = \sum_{i=1}^{n} \quad \frac{1}{2}\log(2\pi\sigma^2) + \frac{1}{2\sigma^2}(y^{(i)} - \mathbf{w}^\top \mathbf{x}^{(i)} - b)^2.$$

إذا افترضنا أن σ تم إصلاحه، فيمكننا تجاهل المصطلح الأول، لأنه لا يعتمد على $\mathbf{w}$ أو b. المصطلح الثاني مطابق لخطأ الخطأ التربيعي التي تم تقديمها سابقًا، باستثناء ثابت الضرب $\frac{1}{\sigma^2}$. لحسن الحظ، الحل لا يعتمد على أي منهما. ويترتب على ذلك أن التقليل من متوسط الخطأ التربيعي يعادل الحد الأقصى لتقدير الاحتمالية لنموذج خطيفي ظل افتراض الضوضاء الغاوسية المضافة.

3.1.4. الانحدار الخطي كشبكة عصبية Linear Regression as a Neural Network

في حين أن النماذج الخطية ليست غنية بما يكفي للتعبير عن العديد من الشبكات العصبية المعقدة التي سنقدمهافي هذا الكتاب، فإن الشبكات العصبية neural networks غنية بما يكفي لتضمين النماذج الخطية كشبكات عصبية يتم فيها تمثيل كل ميزة بواسطة خلية عصبية، وكلها متصلة مباشرة إلى الإخراج.

الشكل 3.1.2 يصور الانحدار الخطي كشبكة عصبية. يبرز الرسم التخطيطي نمط الاتصال مثل كيفية توصيل كل مدخل بالمخرجات، ولكن ليس القيم المحددة المأخوذة بواسطة الأوزان أو التحيزات.

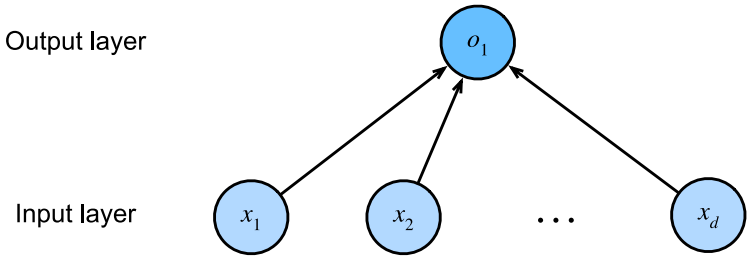

الشكل 3.1.2 الانحدار الخطي هو شبكة عصبية أحادية الطبقة.

المدخلات $x_1, \ldots, x_d$. نشير إلى عدد المدخلات number of inputs أو أبعاد الميزة feature dimensionality في طبقة الإدخال. ناتج الشبكة هو o_1. نظرًا لأننا نحاول فقط التنبؤ بقيمة عددية واحدة، فلدينا فقط خلية عصبية ناتجة واحدة. لاحظ أن جميع قيم الإدخال معطاة. هناك فقط خلية عصبية واحدة محسوبة. باختصار، يمكننا التفكير في الانحدار الخطي كشبكة عصبية أحادية الطبقة متصلة بالكامل single-layer fully connected neural network. سنواجه شبكات ذات طبقات أكثر بكثير في الفصول المستقبلية.

3.1.4.1. الاحياء Biology

نظرًا لأن الانحدار الخطي يسبق علم الأعصاب الحسابي computational neuroscience، فقد يبدو وصف الانحدار الخطي من حيث الشبكات العصبية مفارقة تاريخية. ومع ذلك، فقد كانت مكانًا طبيعيًا للبدء عندما بدأ علماء علم الإنترنت وعلماء الفسيولوجيا العصبية وارين ماكولوتش ووالتر بيتس في تطوير نماذج من الخلايا العصبية الاصطناعية. ضع في اعتبارك الصورة الكرتونية للخلايا العصبية البيولوجية في الشكل 3.1.3، والتي تتكون من التشعبات dendrites (أطراف الإدخال)، والنواة nucleus (وحدة المعالجة المركزية CPU)، والمحور العصبي axon (سلك الإخراج)، والمحطات الطرفية axon terminals (أطراف الإخراج)، مما يتيح التوصيلات بالخلايا العصبية الأخرى عبر المشابك synapses.

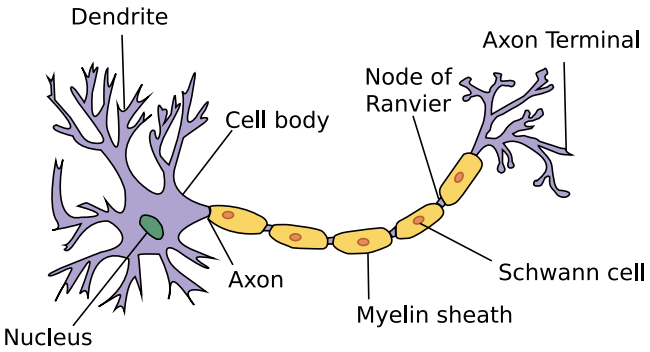

الشكل 3.1.3 الخلية العبية (العصبون) الحقيقي.

يتم تلقي المعلومات x_i الواردة من الخلايا العصبية الأخرى (أو أجهزة الاستشعار البيئية environmental sensors)في التشعبات dendrites. على وجه الخصوص، يتم اخذ اوزان weighted هذه المعلومات من خلال الأوزان المشبكية w_i (synaptic weights)، وتحديد تأثير المدخلات، على سبيل المثال، التنشيط أو التثبيط عبر المنتج $x_i w_i$. يتم تجميع المدخلات الموزونة الواردة من مصادر متعددةفي النواة كمجموع اوزان $y = \sum_i \quad x_i w_i + b$ ، وربما تخضع لبعض عمليات المعالجة اللاحقة غير الخطية عبر $\sigma(y)$. ثم يتم إرسال هذه المعلومات عبر المحور العصبي axon إلى المحاور الطرفية axon terminals، حيث تصل إلى وجهتها (على سبيل المثال، المشغل actuator مثل العضلات muscle) أو يتم تغذيتهافي خلية عصبية أخرى عبر التشعبات dendrites.

من المؤكد أن الفكرة رفيعة المستوى القائلة بإمكانية دمج العديد من هذه الوحدات مع الاتصال الصحيح وخوارزمية التعلم الصحيحة، لإنتاج سلوك أكثر تعقيدًا وإثارة للاهتمام من أي خلية عصبية واحدة وحدها يمكن أن تدين بدراستنا للأنظمة العصبية البيولوجية الحقيقية.في الوقت نفسه، تستمد معظم الأبحاثفي التعلم العميق اليوم الإلهام من مصدر أوسع بكثير. نستدعي ستيوارت راسل وبيتر نورفيج (راسل ونورفيج، 2016) اللذين أشاروا إلى أنه على الرغم من أن الطائرات ربما كانت مستوحاة من الطيور، إلا أن علم الطيور لم يكن المحرك الأساسي لابتكار الطيران لعدة قرون. وبالمثل، يأتي الإلهامفي التعلم العميق هذه الأيام على قدم المساواة أو أكبر من الرياضيات واللغويات وعلم النفس والإحصاء وعلوم الكمبيوتر والعديد من المجالات الأخرى.

3.1.5. الملخص

في هذا القسم، قدمنا الانحدار الخطي التقليدي، حيث يتم اختيار معلمات الدالة الخطية لتقليل الخسارة التربيعيةفي مجموعة التدريب. لقد حفزنا أيضًا اختيار الهدف هذا من خلال بعض الاعتبارات العملية ومن خلال تفسير الانحدار الخطي باعتباره تقديرًا أقصى لاحتماليةفي ظل افتراض الخطية والضوضاء الغاوسية. بعد مناقشة كل من الاعتبارات الحسابية والارتباطات بالإحصاءات، أظهرنا كيف يمكن التعبير عن هذه النماذج الخطية كشبكات عصبية بسيطة حيث يتم توصيل المدخلات مباشرة بالمخرجات (المخرجات). على الرغم من أننا سننتقل قريبًا إلى النماذج الخطية السابقة تمامًا، إلا أنها كافية لتقديم معظم المكونات التي تتطلبها جميع نماذجنا: النماذج البارامترية parametric forms، والأهداف القابلة للتفاضل differentiable objectives ، والتحسين عبر التدرج الاشتقاقي العشوائي المصغر ، وفي النهاية ، التقييم على البيانات غير المرئية سابقًا.

3.1.6. التمارين

1. افترض أن لدينا بعض البيانات $x_1, \ldots, x_n \in \mathbb{R}$. هدفنا هو إيجاد ثابت b يتم تصغير $\sum_i (x_i - b)^2$ إلى أدنى حد.
   1. ابحث عن حل تحليلي للقيمة المثلى لـ b.
   2. كيف ترتبط هذه المشكلة وحلها بالتوزيع الطبيعي؟
   3. ماذا لو غيرنا الخسارة من $(x_i - b)^2$ إلى $\sum_i |x_i - b|$؟ هل يمكنك العثور على الحل الأمثل لـ b؟
2. إثبت أن الدوال الأفينية التي يمكن التعبير عنها بواسطة $\mathbf{x}^\top \mathbf{w} + b$ تعادل الدوال الخطيةفي $(\mathbf{x}, 1)$.
3. افترض أنك تريد إيجاد دوال تربيعية لـ $\mathbf{x}$، أي $f(\mathbf{x}) = b + \sum_i w_i x_i + \sum_{j \leq i} w_{ij} x_i x_j$، كيف يمكنك صياغة هذافي شبكة عميقة؟
4. تذكر أن أحد شروط حل مشكلة الانحدار الخطي هو أن مصفوفة التصميم $\mathbf{X}^\top \mathbf{X}$ لها رتبة كاملة full rank.
   1. ماذا يحدث إذا لم يكن الأمر كذلك؟
   2. كيف يمكنك اصلاحها؟ ماذا يحدث إذا أضفت قدرًا صغيرًا من الضوضاء الغاوسية المستقلة ذات التنسيق الإحداثي إلى جميع إدخالات $\mathbf{X}$؟
   3. ما هي القيمة المتوقعة لمصفوفة التصميم $\mathbf{X}^\top \mathbf{X}$في هذه الحالة؟
   4. ماذا يحدث مع التدرج الاشتقاقي العشوائي SGD عندما لا يكون له رتبة كاملة؟
5. افترض أن نموذج الضوضاء الذي يحكم الضوضاء المضافة ϵ هو التوزيع الأسي. هذا هو، $p(\epsilon) = \frac{1}{2} \exp(-|\epsilon|)$
   1. اكتب الاحتمالية السلبية لسجل البيانات تحت النموذج (negative log-likelihood) $-\log P(\mathbf{y} \mid \mathbf{X})$.
   2. هل يمكنك إيجاد حل الشكل المغلق؟
   3. اقترح خوارزمية التدرج الاشتقاقي العشوائي مع الدفعات الصغيرة لحل هذه المشكلة. ما الذي يمكن أن يحدث بشكل خاطئ (تلميح: ماذا يحدث بالقرب من النقطة الثابتة بينما نستمرفي تحديث المعلمات)؟ أيمكنك إصلاح هذا؟
6. افترض أننا نريد تصميم شبكة عصبية ذات طبقتين من خلال تكوين طبقتين خطيتين. أي أن إخراج الطبقة الأولى يصبح مدخلات الطبقة الثانية. لماذا مثل هذا التكوين الساذج لا يعمل؟
7. ماذا يحدث إذا كنت تريد استخدام الانحدار لتقدير واقعي لأسعار المنازل أو أسعار الأسهم؟

1. أظهر أن افتراض الضوضاء الغاوسية المضافة غير مناسب. تلميح: هل يمكننا الحصول على أسعار سلبية؟ ماذا عن التقلبات fluctuations؟
2. لماذا يكون الانحدار إلى لوغاريتم السعر أفضل بكثير، أي $y = \log \text{price}$؟
3. ما الذي يجب أن تقلق بشأنه عند التعامل مع pennystock، أي الأسهم ذات الأسعار المنخفضة جداً؟ تلميح: هل يمكنك التداول بجميع الأسعار الممكنة؟ لماذا هذه مشكلة أكبر للأسهم الرخيصة؟
4. لمزيد من المعلومات، راجع نموذج Black-Scholes الشهير لتسعير الخيارات(Black and Scholes, 1973) .

8. لنفترض أننا نريد استخدام الانحدار لتقدير عدد التفاح المباعفي محل بقالة.
1. ما هي المشاكل مع نموذج الضوضاء الغاوسية المضافة؟ تلميح: أنت تبيع التفاح وليس الزيت.
2. يلتقط توزيع بواسون Poisson distribution التوزيعات على العد. أعطيت $p(k \mid \lambda) = \lambda^k e^{-\lambda}/k!$. من قبل λ هي دالة المعدل وk هي عدد الأحداث التي تراها. إثبات أن λ هي القيمة المتوقعة للعد k.
3. صمم دالة خطأ مرتبطة بتوزيع بواسون.
4. صمم دالة خطأ لتقدير $\log \lambda$ بدلاً من ذلك.

3.2 التصميم الكينوني للتنفيذ Object-Oriented Design for Implementation

في مقدمتنا للانحدار الخطي، مررنا عبر مكونات مختلفة بمافي ذلك البيانات والنموذج ودالة الخطأ وخوارزمية التحسين.في الواقع، يعد الانحدار الخطي أحد أبسط نماذج التعلم الآلي. ومع ذلك، فإن التدريب عليه يستخدم العديد من نفس المكونات التي تتطلبها النماذج الأخرىفي هذا الكتاب. لذلك، قبل الغوصفي تفاصيل التنفيذ، من المفيد تصميم بعض واجهات برمجة التطبيقات المستخدمةفي هذا الكتاب. عند التعامل مع المكوناتفي التعلم العميق على أنها كائنات، يمكننا البدء بتحديد فئات لهذه الكائنات وتفاعلاتها. سيؤدي هذا التصميم الموجه للكائنات للتنفيذ إلى تبسيط العرض التقديمي بشكل كبير وقد ترغبفي استخدامهفي مشاريعك.

مستوحاة من مكتبات مفتوحة المصدر مثل PyTorch Lightning، على مستوى عالٍ، نرغب في الحصول على ثلاث فئات: (1) تحتوي الوحدة النمطية على نماذج وخسائر وطرق تحسين؛ (2) توفر `DataModule` أدوات تحميل بيانات للتدريب والتحقق من الصحة؛ (3) يتم الجمع بين كلا الفئتين باستخدام فئة `Trainer` ، مما يسمح لنا بتدريب النماذج على مجموعة متنوعة من منصات الأجهزة. تتكيف معظم التعليمات البرمجيةفي هذا الكتاب مع الوحدة النمطية

Module ووحدة البيانات DataModule. سنتطرق إلى فئة المدرب Trainer فقط عندما نناقش وحدات معالجة الرسومات GPU ووحدات المعالجة المركزية CPU والتدريب الموازي وخوارزميات التحسين.

```
import time
import numpy as np
import tensorflow as tf
from d2l import torch as d2l
```

3.2.1. الأدوات المساعدة Utilities

نحتاج إلى بعض الأدوات المساعدة Utilities لتبسيط البرمجة الموجهة للكائنات object-oriented programming في نوتبوكس Jupyter. يتمثل أحد التحديات في أن تعريفات الفئات تميل إلى أن تكون كتل طويلة إلى حد ما من التعليمات البرمجية. تتطلب قابلية قراءة النوتبوك Notebook أجزاء قصيرة من التعليمات البرمجية، تتخللها تفسيرات، وهو مطلب لا يتوافق مع أسلوب البرمجة الشائع في مكتبات بايثون. تتيح لنا دالة الأداة المساعدة الأولى تسجيل الدوال كطرق في الكلاس بعد إنشاء الكلاس. في الواقع، يمكننا القيام بذلك حتى بعد إنشاء نسخ من الكلاس! يسمح لنا بتقسيم تنفيذ كلاس إلى كتل تعليمات برمجية متعددة.

```
def add_to_class(Class):  #@save
    def wrapper(obj):
        setattr(Class, obj.__name__, obj)
    return wrapper
```

دعونا نلقي نظرة سريعة على كيفية استخدامه. نحن نخطط لتنفيذ كلاس A مع طريقة do. بدلاً من وجود رمز لكل من A والقيام به في نفس كتلة التعليمات البرمجية، يمكننا أولاً إعلان الكلاس A وإنشاء مثيل (instance) a.

```
class A:
    def __init__(self):
        self.b = 1

a = A()
```

بعد ذلك نحدد الطريقة do كما نفعل عادة ، ولكن ليس في نطاق الكلاس A. بدلاً من ذلك ، نقوم بتزيين هذه الطريقة عن طريق add_to_class بالفئة A كوسيطة لها. عند القيام بذلك، تكون الطريقة قادرة على الوصول إلى متغيرات الأعضاء في A كما نتوقع إذا تم تعريفها كجزء من تعريف A. دعونا نرى ما يحدث عندما نستدعيها للمثيل a.

```
@add_to_class(A)
def do(self):
```

```
    print('Class attribute "b" is', self.b)

a.do()
```

```
Class attribute "b" is 1
```

الثاني هو كلاس utility التي تحفظ جميع الوسائطفي طريقةكلاس `__init__` كسمات للكلاس. هذا يسمح لنا بتوسيع تواقيع استدعاء المُنشئ constructor ضمنيًا دون الحاجة إلى تعليمات برمجية إضافية.

```
class HyperParameters:  #@save
    def save_hyperparameters(self, ignore=[]):
        raise NotImplemented
```

نؤجل تنفيذه إلى القسم 20.7. لاستخدامها، نحدد صنفنا الذي يرث من `HyperParameters` ويستدعي `save_hyperparameters` في طريقة `__init__`.

```
# Call the fully implemented HyperParameters class saved
in d2l
class B(d2l.HyperParameters):
    def __init__(self, a, b, c):
        self.save_hyperparameters(ignore=['c'])
        print('self.a =', self.a, 'self.b =', self.b)
        print('There is no self.c =', not hasattr(self,
'c'))

b = B(a=1, b=2, c=3)
```

```
self.a = 1 self.b = 2
There is no self.c = True
```

الأداة الأخيرة تسمح لنا برسم تقدم التجربة بشكل تفاعلي أثناء استمرارها. احترامًا للوحة TensorBoard الأكثر قوة (والمعقدة)، نطلق عليها اسم `ProgressBoard`. تم تأجيل التنفيذ إلى القسم 20.7.في الوقت الحالي، دعنا نراهفي العمل.

ترسم دالة `draw` نقطة `(x, y)` في الشكل ، مع تحديد `label`في وسيلة الإيضاح legend. يعمل الخيار `every_n` على تمهيد الخط من خلال إظهار النقاط $1/n$في الشكل فقط. يتم حساب متوسط قيمها من نقاط الجوار nفي الشكل الأصلي.

```
class ProgressBoard(d2l.HyperParameters):  #@save
    """Plot data points in animation."""
    def __init__(self, xlabel=None, ylabel=None,
xlim=None,
                 ylim=None, xscale='linear',
yscale='linear',
```

```
                ls=['-', '--', '-.', ':'],
colors=['C0', 'C1', 'C2', 'C3'],
                fig=None, axes=None, figsize=(3.5,
2.5), display=True):
        self.save_hyperparameters()

    def draw(self, x, y, label, every_n=1):
        raise NotImplemented
```

في المثال التالي، نرسم الجيب `sin` وجيب التمام `cos` بنعومة مختلفة. إذا قمت بتشغيل كتلة التعليمات البرمجية هذه، فسترى الخطوط تنمو في الرسوم المتحركة.

```
board = d2l.ProgressBoard('x')
for x in np.arange(0, 10, 0.1):
    board.draw(x, np.sin(x), 'sin', every_n=2)
    board.draw(x, np.cos(x), 'cos', every_n=10)
```

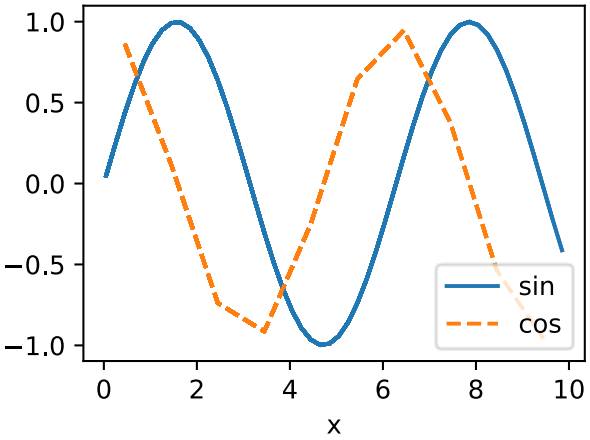

3.2.2. النماذج Models

كلاس الوحدة النمطية `Module` هي الكلاس الأساسي لجميع النماذج التي سننفذها. كحد أدنى نحتاج إلى تحديد ثلاث طرق. تقوم طريقة `__init__` بتخزين المعلمات القابلة للتعلم، وتقبل طريقة `training_step` مجموعة بيانات لإرجاع قيمة الخطأ، وتعيد طريقة `configure_optimizers` طريقة التحسين، أو قائمة بها، تُستخدم لتحديث المعلمات القابلة للتعلم. اختياريا يمكننا تحديد `validation_step` للإبلاغ عن تدابير التقييم.في بعض الأحيان نضع الكود لحساب الإخراجفي طريقة `forward` منفصلة لجعله أكثر قابلية لإعادة الاستخدام.

```
class Module(tf.keras.Model, d2l.HyperParameters):
#@save
```

```
    def __init__(self, plot_train_per_epoch=2,
plot_valid_per_epoch=1):
        super().__init__()
        self.save_hyperparameters()
        self.board = ProgressBoard()
        self.training = None

    def loss(self, y_hat, y):
        raise NotImplementedError

    def forward(self, X):
        assert hasattr(self, 'net'), 'Neural network is
defined'
        return self.net(X)

    def call(self, X, *args, **kwargs):
        if kwargs and "training" in kwargs:
            self.training = kwargs['training']
        return self.forward(X, *args)

    def plot(self, key, value, train):
        """Plot a point in animation."""
        assert hasattr(self, 'trainer'), 'Trainer is not
inited'
        self.board.xlabel = 'epoch'
        if train:
            x = self.trainer.train_batch_idx / \
                self.trainer.num_train_batches
            n = self.trainer.num_train_batches / \
                self.plot_train_per_epoch
        else:
            x = self.trainer.epoch + 1
            n = self.trainer.num_val_batches / \
                self.plot_valid_per_epoch
        self.board.draw(x, value.numpy(), (
            'train_' if train else 'val_') + key,
every_n=int(n))
    def training_step(self, batch):
        l = self.loss(self(*batch[:-1]), batch[-1])
        self.plot('loss', l, train=True)
        return l
```

```
    def validation_step(self, batch):
        l = self.loss(self(*batch[:-1]), batch[-1])
        self.plot('loss', l, train=False)

    def configure_optimizers(self):
        raise NotImplementedError
```

قد تلاحظ أن Moduleهي فئة فرعية من tf.keras.Model ، وهي الفئة الأساسية للشبكات العصبيةفي TensorFlow. يوفر ميزات ملائمة للتعامل مع الشبكات العصبية. على سبيل المثال، تستدعي طريقة callفي طريقة __call__ المضمنة. هنا نعيد توجيه call إلى دالة forward ، وحفظ وسائطها كسمة فئة. نقوم بذلك لجعل الكود الخاص بنا أكثر تشابهًا مع تطبيقات إطار العمل الأخرى.

3.2.3. بيانات Data

فئة DataModule هي الفئة الأساسية للبيانات.في كثير من الأحيان يتم استخدام طريقة __init__ لإعداد البيانات. يتضمن ذلك التنزيل والمعالجة المسبقة إذا لزم الأمر. يُرجع train_dataloader أداة تحميل البيانات لمجموعة بيانات التدريب. أداة تحميل البيانات هي منشئ generator (بايثون) ينتج دفعة بياناتفي كل مرة يتم استخدامها. يتم بعد ذلك إدخال هذه الدُفعةفي طريقة training_step للوحدة النمطية Moduleلحساب الخطأ. يوجد val_dataloader اختياري لإرجاع أداة تحميل مجموعة بيانات التحقق. يتصرف بنفس الطريقة، باستثناء أنه ينتج دفعات بيانات لأسلوب validation_stepفي Module.

```
class DataModule(d2l.HyperParameters):  #@save
    def __init__(self, root='../data'):
        self.save_hyperparameters()

    def get_dataloader(self, train):
        raise NotImplementedError

    def train_dataloader(self):
        return self.get_dataloader(train=True)

    def val_dataloader(self):
        return self.get_dataloader(train=False)
```

3.2.4. التدريب Training

يقوم فئة Trainer بتدريب المعلمات القابلة للتعلمفي فئة Module مع البيانات المحددةفي DataModule. الطريقة الرئيسية fit ، والتي تقبل وسيطتين: model ، مثيل للوحدة النمطية Module ، والبيانات data ، مثيل DataModule. ثم يتكرر على مدار مجموعة البيانات

max_epochs عدد مرات لتدريب النموذج. كمافي السابق، سوف نؤجل تنفيذ هذه الدالة إلى فصول لاحقة.

```
class Trainer(d2l.HyperParameters):  #@save
    def __init__(self, max_epochs, num_gpus=0,
gradient_clip_val=0):
        self.save_hyperparameters()
        assert num_gpus == 0, 'No GPU support yet'

    def prepare_data(self, data):
        self.train_dataloader = data.train_dataloader()
        self.val_dataloader = data.val_dataloader()
        self.num_train_batches =
len(self.train_dataloader)
        self.num_val_batches = (len(self.val_dataloader)
                                if self.val_dataloader
is not None else 0)

    def prepare_model(self, model):
        model.trainer = self
        model.board.xlim = [0, self.max_epochs]
        self.model = model

    def fit(self, model, data):
        self.prepare_data(data)
        self.prepare_model(model)
        self.optim = model.configure_optimizers()
        self.epoch = 0
        self.train_batch_idx = 0
        self.val_batch_idx = 0
        for self.epoch in range(self.max_epochs):
            self.fit_epoch()

    def fit_epoch(self):
        raise NotImplementedError
```

3.2.5. الملخص

لتسليط الضوء على التصميم الموجه للكائنات لتنفيذ التعلم العميقفي المستقبل، توضح الفئات المذكورة أعلاه فقط كيف تخزن كائناتها البيانات وتتفاعل مع بعضها البعض. سنستمرفي إثراء تطبيقات هذه الفئات، مثل add_to_class@،في بقية الكتاب. علاوة على ذلك، يتم حفظ هذه الفئات المنفذة بالكاملفي مكتبة d2l(d2l library)، وهي مجموعة أدوات خفيفة الوزن

تجعل النمذجة المنظمة للتعلم العميق أمرًا سهلاً. على وجه الخصوص، فإنه يسهل إعادة استخدام العديد من المكونات بين المشاريع دون تغيير الكثير على الإطلاق. على سبيل المثال، يمكننا استبدال المُحسِّن optimizer فقط، والنموذج model فقط، ومجموعة البيانات dataset فقط، وما إلى ذلك؛ هذه الدرجة من النمطية modularity تؤتي ثمارهافي جميع أنحاء الكتاب من حيث الإيجاز والبساطة (وهذا هو سبب إضافتها) ويمكنها أن تفعل الشيء نفسه لمشاريعك الخاصة.

3.2.6. التمارين

1. حدد موقع عمليات التنفيذ الكاملة للفئات المذكورة أعلاه المحفوظةفي مكتبة d2l. نوصي بشدة أن تنظر إلى التنفيذ بالتفصيل بمجرد أن تكتسب مزيدًا من الإلمام بنمذجة التعلم العميق.
2. قم بإزالة عبارة `save_hyperparameters`في الفئة B. هل لا يزال بإمكانك طباعة `self.a` و `self.b` ؟ اختياري: إذا كنت قد تعمقتفي التنفيذ الكامل لفئة `HyperParameters` ، فهل يمكنك توضيح السبب؟

3.3 بيانات الانحدار التركيبية Synthetic Regression Data

يدور التعلم الآلي حول استخراج المعلومات من البيانات. لذلك قد تتساءل، ما الذي يمكن أن نتعلمه من البيانات التركيبية synthetic data؟ على الرغم من أننا قد لا نهتم بشكل جوهري بالأنماط التي قمنا بتخزينهافي نموذج إنشاء البيانات الاصطناعية، إلا أن مجموعات البيانات هذه مفيدة للأغراض التعليمية، مما يساعدنا على تقييم خصائص خوارزميات التعلم الخاصة بنا والتأكد من أن تطبيقاتنا تعمل كما هو متوقع. على سبيل المثال، إذا أنشأنا بيانات تُعرف المعلمات الصحيحة لها مسبقًا priori، فيمكننا التحقق من أن نموذجنا يمكنهفي الواقع استعادتها.

```
%matplotlib inline
import random
import tensorflow as tf
from d2l import tensorflow as d2l
```

3.3.1. إنشاء مجموعة البيانات Generating the Dataset

في هذا المثال، سنعمل الأبعاد المنخفضة low-dimensional للإيجاز. يُنشئ مقتطف الشفرة التالي `1000` مثال بميزات ثنائية الأبعاد مستمدة من التوزيع العادي القياسي. تنتمي مصفوفة التصميم $\mathbf{X}$ الناتجة إلى $\mathbb{R}^{1000\times 2}$. نقوم بإنشاء كل تسمية من خلال تطبيق دالة خطية للقيم الحقيقية ground truth ، وأفسدتها عن طريق الضوضاء المضافة ϵ ، مرسومة بشكل مستقل ومتطابق لكل مثال:

$$\mathbf{y} = \mathbf{X}\mathbf{w} + b + \epsilon.$$

للسهولة، نفترض أن ذلك ϵ مستمد من التوزيع الطبيعي بمتوسط $\mu = 0$ وانحراف معياري $\sigma = 0.01$. لاحظ أنه بالنسبة للتصميم الموجه للكائنات، نضيف الكود إلى طريقة `__init__` لفئة فرعية من `d2l.DataModule` (تم تقديمه في القسم 3.2.3). من الممارسات الجيدة السماح بتعيين أي معلمات فائقة إضافية. نحقق ذلك باستخدام `save_hyperparameters()`. سيتم تحديد حجم الدفعة `batch_size` لاحقًا.

```
class SyntheticRegressionData(d2l.DataModule):  #@save
    def __init__(self, w, b, noise=0.01, num_train=1000,
num_val=1000,
                 batch_size=32):
        super().__init__()
        self.save_hyperparameters()
        n = num_train + num_val
        self.X = tf.random.normal((n, w.shape[0]))
        noise = tf.random.normal((n, 1)) * noise
        self.y = tf.matmul(self.X, tf.reshape(w, (-1,
1))) + b + noise
```

أدناه، قمنا بتعيين المعلمات الحقيقية على $\mathbf{w} = [2, -3.4]^\top$ و $b = 4.2$. لاحقًا، يمكننا التحقق من معلماتنا المقدرة مقابل قيم الحقيقة الأساسية هذه.

```
data = SyntheticRegressionData(w=tf.constant([2, -3.4]),
b=4.2)
```

يتكون كل صف في `features` من متجه في $\mathbb{R}^2$ وكل صف في `labels` عبارة عن قيمة قياسية scalar. دعونا نلقي نظرة على الإدخال الأول.

```
print('features:', data.X[0],'\nlabel:', data.y[0])
```

```
features: tf.Tensor([-0.44379362  0.23580837],
shape=(2,), dtype=float32)
label: tf.Tensor([2.506998], shape=(1,), dtype=float32)
```

3.3.2. قراءة مجموعة البيانات Reading the Dataset

غالبًا ما تتطلب نماذج التعلم الآلي للتدريب تمريرات متعددة على مجموعة بيانات Dataset، مع الحصول على دفعة صغيرة minibatch واحدة من الأمثلة في كل مرة. ثم يتم استخدام هذه البيانات لتحديث النموذج. لتوضيح كيفية عمل ذلك، نقوم بتنفيذ دالة `get_dataloader`، وتسجيلها كطريقة في فئة `SyntheticRegressionData` عبر `add_to_class` (المقدمة في القسم 3.2.1). يأخذ حجم الدُفعة، مصفوفة الميزات matrix of features، ومتجه التسميات a vector of labels، وينشئ الدُفعات المصغرة من `batch_size`. على هذا

النحو، يتكون كل minibatch من مجموعة من الميزات والتسميات. لاحظ أننا بحاجة إلى أن نضعفي اعتبارنا ما إذا كنافي وضع التدريب training أو التحقق من الصحة validation:في السابق، سنرغبفي قراءة البيانات بترتيب عشوائي،في حين أن القدرة على قراءة البيانات بترتيب محدد مسبقًا قد تكون مهمة لأغراض التصحيح.

```
@d2l.add_to_class(SyntheticRegressionData)
def get_dataloader(self, train):
    if train:
        indices = list(range(0, self.num_train))
        # The examples are read in random order
        random.shuffle(indices)
    else:
        indices = list(range(self.num_train,
self.num_train+self.num_val))
    for i in range(0, len(indices), self.batch_size):
        j = tf.constant(indices[i : i+self.batch_size])
        yield tf.gather(self.X, j), tf.gather(self.y, j)
```

لبناء بعض الحدس، دعنا نفحص الدفعة الأولى من البيانات. توفر لناكل دفعة صغيرة من الميزات حجمها وأبعاد ميزات الإدخال. وبالمثل، سيكون لمجموعة التسميات الصغيرة الخاصة بنا شكل مطابق تم تحديده بواسطة `batch_size`.

```
X, y = next(iter(data.train_dataloader()))
print('X shape:', X.shape, '\ny shape:', y.shape)
```

```
X shape: (32, 2)
y shape: (32, 1)
```

بينما يبدو غير ضار innocuous، فإن استدعاء `iter(data.train_dataloader())` يوضح قوة تصميم بايثون الموجه للكائنات. لاحظ أننا أضفنا طريقة إلى فئة `SyntheticRegressionData` بعد إنشاء كائن البيانات. ومع ذلك، فإن الكائن يستفيد من إضافة الدالة بأثر رجعي إلى الفئة.

خلال التكرار نحصل على دفعات صغيرة مميزة حتى يتم استنفاد مجموعة البيانات بالكامل (جرب هذا).في حين أن التكرار الذي تم تنفيذه أعلاه مفيد للأغراض التعليمية، إلا أنه غير فعال في الطرق التي قد تسبب لنا المشاكلفي مشاكل حقيقية. على سبيل المثال، يتطلب الأمر أن نقوم بتحميل جميع البيانات الموجودةفي الذاكرة وأن نقوم بالكثير من الوصول العشوائي إلى الذاكرة. تعد أجهزة التكرار المضمنة built-in iterators التي يتم تنفيذهافي إطار عمل التعلم العميق أكثر كفاءة إلى حد كبير ويمكنها التعامل مع مصادر مثل البيانات المخزنةفي الملفات، والبيانات

المستلمة عبر التدفق، والبيانات التي يتم إنشاؤها أو معالجتها أثناء التنقل. بعد ذلك، دعونا نحاول تنفيذ نفس الدالة باستخدام التكرارات المضمنة.

3.3.3. التنفيذ المختصر لمحمل البيانات Concise Implementation of the Data Loader

بدلاً من كتابة المكرر الخاص بنا، يمكننا استدعاء واجهة برمجة التطبيقات API الموجودةفي إطار عمل لتحميل البيانات. كما كان من قبل، نحتاج إلى مجموعة بيانات بالميزات X والتسميات y. علاوة على ذلك ، قمنا بتعيين batch_sizeفي أداة تحميل البيانات المضمنة built-in data loader وندعها تهتم بأمثلة الخلط shuffling examples بكفاءة.

```
@d2l.add_to_class(d2l.DataModule)  #@save
def get_tensorloader(self, tensors, train,
indices=slice(0, None)):
    tensors = tuple(a[indices] for a in tensors)
    shuffle_buffer = tensors[0].shape[0] if train else 1
    return
tf.data.Dataset.from_tensor_slices(tensors).shuffle(

buffer_size=shuffle_buffer).batch(self.batch_size)

@d2l.add_to_class(SyntheticRegressionData)  #@save
def get_dataloader(self, train):
    i = slice(0, self.num_train) if train else
slice(self.num_train, None)
    return self.get_tensorloader((self.X, self.y),
train, i)
```

تعمل أداة تحميل البيانات الجديدة تمامًا مثل السابقة، باستثناء أنها أكثر كفاءة ولديها بعض الدوال الإضافية.

```
X, y = next(iter(data.train_dataloader()))
print('X shape:', X.shape, '\ny shape:', y.shape)
```

```
X shape: (32, 2)
y shape: (32, 1)
```

على سبيل المثال، أداة تحميل البيانات التي توفرها واجهة برمجة التطبيقات API الخاصة بإطار العمل تدعم طريقة __len__ المضمنة ، حتى نتمكن من الاستعلام عن طولها ، أي عدد الدُفعات number of batches.

```
len(data.train_dataloader())
```

```
32
```

3.3.4. الملخص

تُعد برامج تحميل البيانات Data loaders طريقة ملائمة لاستخراج عملية تحميل البيانات ومعالجتها. وبهذه الطريقة، فإن خوارزمية التعلم الآلي نفسها قادرة على معالجة العديد من أنواع ومصادر البيانات المختلفة دون الحاجة إلى تعديل. أحد الأشياء الرائعة حول برامج تحميل البيانات هو أنه يمكن تكوينها. على سبيل المثال، قد نقوم بتحميل الصور ومن ثم يكون لدينا مرشح ما بعد المعالجة يقوم بقصها أو تعديلها بطريقة أخرى. على هذا النحو، يمكن استخدام برامج تحميل البيانات لوصف خط أنابيب معالجة البيانات بالكامل.

بالنسبة للنموذج نفسه، فإن النموذج الخطي ثنائي الأبعاد هو نموذج بسيط كما قد نواجهه. يتيح لنا اختبار دقة نماذج الانحدار دون القلق بشأن عدم وجود كميات كافية من البيانات أو نظام معادلات غير محدد بشكل كافٍ. سنستخدم هذا بشكل جيدفي القسم التالي.

3.3.5. التمارين

1. ماذا سيحدث إذا كان عدد الأمثلة لا يمكن تقسيمه على حجم الدُفعة. كيف يمكن تغيير هذا السلوك من خلال تحديد وسيطة مختلفة باستخدام واجهة برمجة التطبيقات الخاصة API بإطار العمل Framework؟
2. ماذا لو أردنا إنشاء مجموعة بيانات ضخمة، حيث يكون حجم متجه المعلمة `w` وعدد الأمثلة `num_examples` عددًا كبيرًا؟
   1. ماذا يحدث إذا لم نتمكن من الاحتفاظ بجميع البياناتفي الذاكرة؟
   2. كيف يمكنك تبديل البيانات إذا تم الاحتفاظ بالبيانات على القرص؟ مهمتك هي تصميم خوارزمية فعالة لا تتطلب الكثير من القراءة أو الكتابة العشوائية. تلميح: مولدات التقليب العشوائية الزائفة pseudorandom permutation generators تسمح لك بتصميم التعديل دون الحاجة إلى تخزين جدول التقليب permutation table بشكل صريح (Naor and Reingold، 1999).
3. قم بتنفيذ منشئ البيانات data generator الذي ينتج بيانات جديدة بسرعة،في كل مرة يتم استدعاء المكرر.
4. كيف يمكنك تصميم منشئ بيانات عشوائي random data generator يقوم بإنشاء نفس البياناتفي كل مرة يتم استدعاؤها؟

3.4. تنفيذ الانحدار الخطي من الصفر Linear Regression Implementation from Scratch

نحن الآن جاهزون للعمل من خلال التنفيذ الكامل للانحدار الخطي.في هذا القسم، سنقوم بتنفيذ الطريقة بأكملها من البداية، بمافي ذلك (1) النموذج model ؛ (2) دالة الخطأ loss function؛ (3) مُحسِّن التدرج الاشتقاقي العشوائي المصغر minibatch stochastic gradient descent optimizer ؛ و (4) دالة التدريب training function التي تجمع كل هذه القطع معًا. أخيرًا، سنقوم بتشغيل منشئ البيانات التركيبية الخاص بنا من القسم 3.3 ونطبق نموذجنا على مجموعة البيانات الناتجة. بينما يمكن لأطر التعلم العميق الحديثة أتمتة كل هذا العمل تقريبًا، فإن تنفيذ الأشياء من البداية هو الطريقة الوحيدة للتأكد من أنك تعرف حقًا ما تفعله. علاوة على ذلك، عندما يحين وقت تخصيص النماذج، وتحديد طبقاتنا الخاصة أو دوال الخطأ، فإن فهم كيفية عمل الأشياء تحت الغطاء سيكون مفيداً.في هذا القسم، سوف نعتمد فقط على الموترات والتفاضل التلقائي.في وقت لاحق، سنقدم تطبيقًا أكثر إيجازًا، مستفيدًا من أجراس وصفارات أطر التعلم العميق مع الاحتفاظ بهيكل ما يلي أدناه.

```
%matplotlib inline
import tensorflow as tf
from d2l import tensorflow as d2l
```

3.4.1. تعريف النموذج Defining the Model

قبل أن نبدأفي تحسين معلمات نموذجنا عن طريق minibatch SGD، نحتاج إلى بعض المعلمات parameetersفي المقام الأول. فيما يلي نقوم بتهيئة الأوزان عن طريق سحب أرقام عشوائية من التوزيع الطبيعي بمتوسط `0` وانحراف معياري `0.01` غالبًا ما يعمل الرقم السحري `0.01` جيداًفي الممارسة، ولكن يمكنك تحديد قيمة مختلفة من خلال وسيطة `sigma`. علاوة على ذلك، قمنا بتعيين الانحياز إلى `0`. لاحظ أنه بالنسبة للتصميم الموجه للكائنات، نضيف الكود إلى طريقة `__init__` لفئة فرعية من وحدة `d2l.Module` (المقدمةفي القسم 3.2.2).

```
class LinearRegressionScratch(d2l.Module):  #@save
    def __init__(self, num_inputs, lr, sigma=0.01):
        super().__init__()
        self.save_hyperparameters()
        w = tf.random.normal((num_inputs, 1), mean=0,
stddev=0.01)
        b = tf.zeros(1)
        self.w = tf.Variable(w, trainable=True)
        self.b = tf.Variable(b, trainable=True)
```

بعد ذلك، يجب علينا تحديد نموذجنا، وربط مدخلاته ومعلماته بمخرجاته. بالنسبة لنموذجنا الخطي، نأخذ ببساطة منتج متجه المصفوفة لميزات الإدخال **X** وأوزان النموذج **w** ، ونضيف الإزاحة(offset) b إلى كل مثال.**Xw** هو متجه وb هو قيمة قياسية scalar. نظرًا لآلية البث (انظر القسم 2.1.4)، عندما نضيف متجهًا وقيمة قياسية، تُضاف القيمة القياسية إلى كل مكون من مكونات المتجه. يتم تسجيل دالة `forward` الناتجة كطريقةفي فئة `LinearRegressionScratch` عبر `add_to_class` (تم تقديمهفي القسم 3.2.1).

```
@d2l.add_to_class(LinearRegressionScratch)  #@save
def forward(self, X):
    """The linear regression model."""
    return tf.matmul(X, self.w) + self.b
```

3.4.2. تعريف دالة الخطأ Defining the Loss Function

نظرًا لأن تحديث نموذجنا يتطلب أخذ التدرج gradient لدالة الخطأ loss function ، فيجب علينا تحديد دالة الخطأ أولاً. هنا نستخدم دالة الخطأ التربيعية squared loss functionفي (3.1.5).في التنفيذ، نحتاج إلى تحويل القيمة الحقيقية `y` إلى شكل القيمة المتوقعة `y_hat`. النتيجة التي تم إرجاعها بواسطة الدالة التالية سيكون لها أيضًا نفس شكل `y_hat`. نعيد أيضًا قيمة الخطأ المتوسطة بين جميع الأمثلةفي minibatch.

```
@d2l.add_to_class(LinearRegressionScratch)  #@save
def loss(self, y_hat, y):
    l = (y_hat - tf.reshape(y, y_hat.shape)) ** 2 / 2
    return tf.reduce_mean(l)
```

3.4.3. تعريف خوارزمية التحسين Defining the Optimization Algorithm

كما نوقش في القسم 3.1، فإن الانحدار الخطي له حل مغلق الشكل closed-form solution. ومع ذلك، فإن هدفنا هنا هو توضيح كيفية تدريب شبكات عصبية أكثر عمومية، وهذا يتطلب أن نعلمك كيفية استخدام minibatch SGD. ومن ثم سننتهز هذه الفرصة لتقديم مثالك العملي الأول لـ SGD.في كل خطوة، باستخدام minibatch مأخوذ عشوائيًا من مجموعة البيانات الخاصة بنا، نقدر تدرج الخطأ فيما يتعلق بالمعلمات. بعد ذلك، نقوم بتحديث المعلماتفي الاتجاه الذي قد يقلل من الخطأ.

الكود التالي يطبق التحديث، بالنظر إلى مجموعة من المعلمات، معدل التعلم `lr`. نظرًا لأن خسارتنا يتم حسابها كمتوسط على minibatch، لا نحتاج إلى ضبط معدل التعلم مقابل حجم الدُفعة.في فصول لاحقة سنبحثفي كيفية تعديل معدلات التعلم للدفعات الصغيرة minibatch

الكبيرة جدًا عند ظهورهافي التعلم الموزع على نطاق واسع.في الوقت الحالي، يمكننا تجاهل هذه التبعية.

نحدد فئة SGD الخاصة بنا، وهي فئة فرعية من d2l.HyperParameters (تم تقديمها في القسم 3.2.1) ، للحصول على واجهة برمجة تطبيقات API مماثلة لمُحسِّن SGD المدمج. نقوم بتحديث المعلماتفي طريقة apply_gradients. يقبل قائمة من المعلمات وأزواج التدرج.

```
class SGD(d2l.HyperParameters):  #@save
    def __init__(self, lr):
        """Minibatch stochastic gradient descent."""
        self.save_hyperparameters()

    def apply_gradients(self, grads_and_vars):
        for grad, param in grads_and_vars:
            param.assign_sub(self.lr * grad)
```

نحدد بعد ذلك طريقة configure_optimizers ، والتي تُرجع مثيلاً لفئة SGD.

```
@d2l.add_to_class(LinearRegressionScratch)  #@save
def configure_optimizers(self):
    return SGD(self.lr)
```

3.4.4. التدريب Training

الآن بعد أن أصبح لدينا جميع الأجزاءفي مكانها (المعلمات، دالة الخسارة (الخطأ)، النموذج، والمحسن)، نحن جاهزون لتنفيذ حلقة التدريب الرئيسية. من الأهمية بمكان أن تفهم هذا الرمز جيدًا لأنك ستستخدم حلقات تدريب مماثلة لكل نموذج تعليم عميق آخر مغطىفي هذا الكتاب. في كل فترة epoch، نكرر مجموعة بيانات التدريب بأكملها، ونمرر مرة واحدةفي كل مثال (بافتراض أن عدد الأمثلة قابل للقسمة على حجم الدُفعة).في كل تكرار، نحصل على دفعة مصغرة من أمثلة التدريب، ونحسب خسارتها من خلال طريقة training_step للنموذج. بعد ذلك، نحسب التدرجات فيما يتعلق بكل معلمة. أخيرًا، سنقوم باستدعاء خوارزمية التحسين لتحديث معلمات النموذج. باختصار، سنقوم بتنفيذ الحلقة التالية:

- تهيئة المعلمات $(\mathbf{w}, b)$
- كرر حتى الانتهاء
  - حساب التدرج $\mathbf{g} \leftarrow \partial_{(\mathbf{w},b)} \frac{1}{|\mathcal{B}|} \sum_{i \in \mathcal{B}} l(\mathbf{x}^{(i)}, y^{(i)}, \mathbf{w}, b)$
  - تحديث المعلمات $(\mathbf{w}, b) \leftarrow (\mathbf{w}, b) - \eta \mathbf{g}$

تذكر أن مجموعة بيانات الانحدار التركيبية synthetic regression dataset التي أنشأناهافي القسم 3.3 لا توفر مجموعة بيانات للتحقق validation dataset. ومع ذلك،في معظم الحالات، سنستخدم مجموعة بيانات تحقق لقياس جودة نموذجنا. هنا نمرر أداة تحميل بيانات التحقق مرة واحدةفي كل فترة لقياس أداء النموذج. بعد تصميمنا الموجه للكائنات، يتم تسجيل دالتي `prepare_batch` و `fit_epoch` كطريقتين من فئة `d2l.Trainer` (مقدمةفي القسم 3.2.4).

```
@d2l.add_to_class(d2l.Trainer)  #@save
def prepare_batch(self, batch):
    return batch

@d2l.add_to_class(d2l.Trainer)  #@save
def fit_epoch(self):
    self.model.training = True
    for batch in self.train_dataloader:
        with tf.GradientTape() as tape:
            loss =
self.model.training_step(self.prepare_batch(batch))
        grads = tape.gradient(loss,
self.model.trainable_variables)
        if self.gradient_clip_val > 0:
            grads =
self.clip_gradients(self.gradient_clip_val, grads)
        self.optim.apply_gradients(zip(grads,
self.model.trainable_variables))
        self.train_batch_idx += 1
    if self.val_dataloader is None:
        return
    self.model.training = False
    for batch in self.val_dataloader:

self.model.validation_step(self.prepare_batch(batch))
        self.val_batch_idx += 1
```

نحن جاهزون تقريبًا لتدريب النموذج، لكننا نحتاج أولاً إلى بعض البيانات للتدرب عليها. هنا نستخدم فئة `SyntheticRegressionData`ونمرر بعض المعلمات الحقيقة –ground truth الأساسية. بعد ذلك، نقوم بتدريب نموذجنا بمعدل التعلم `lr=0.03` وتعيين `max_epochs=3`. لاحظ أنه بشكل عام،كل من عدد الفترات ومعدل التعلم عبارة عن معلمات فائقة hyperparameters. بشكل عام، يعد إعداد المعلمات الفائقة أمرًا صعبًا وسنرغب عادةً في استخدام تقسيم ثلاثي الاتجاهات 3–way split ، ومجموعة واحدة للتدريب ، وثانية لقسم

المعلمات الفائقة، والثالثة مخصصة للتقييم النهائي. نحن نتجاهل هذه التفاصيل في الوقت الحالي ولكننا سنراجعها لاحقًا.

```
model = LinearRegressionScratch(2, lr=0.03)
data = d2l.SyntheticRegressionData(w=tf.constant([2, -
3.4]), b=4.2)
trainer = d2l.Trainer(max_epochs=3)
trainer.fit(model, data)
```

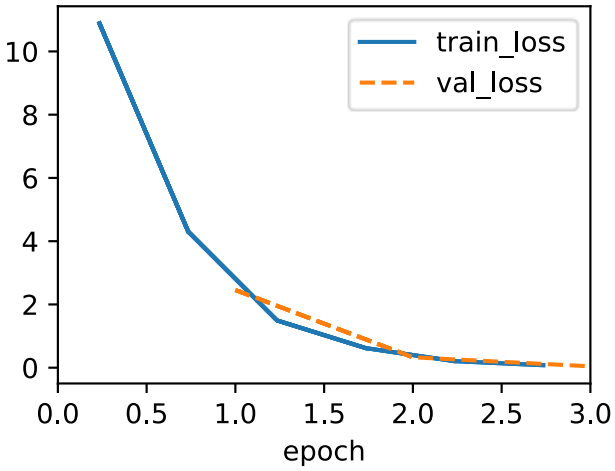

نظرًا لأننا قمنا بتجميع مجموعة البيانات بأنفسنا، فإننا نعرف بالضبط ما هي المعلمات الحقيقية. وبالتالي، يمكننا تقييم نجاحنا في التدريب من خلال مقارنة المعلمات الحقيقية بتلك التي تعلمناها من خلال حلقة التدريب الخاصة بنا. في الواقع، تبين أنهم قريبون جدًا من بعضهم البعض.

```
print(f'error in estimating w: {data.w -
tf.reshape(model.w, data.w.shape)}')
print(f'error in estimating b: {data.b - model.b}')
```

```
error in estimating w: [ 0.06905794 -0.15879321]
error in estimating b: [0.22819376]
```

لا ينبغي لنا أن نأخذ القدرة على استعادة المعلمات الحقيقية كأمر مسلم به. بشكل عام، بالنسبة للنماذج العميقة، لا توجد حلول فريدة للمعلمات، وحتى بالنسبة للنماذج الخطية، يكون استرداد المعلمات بالضبط ممكنًا فقط عندما لا تعتمد أي ميزة خطيًا على الميزات الأخرى. ومع ذلك، في التعلم الآلي، غالبًا ما نكون أقل اهتمامًا باستعادة المعلمات الأساسية الحقيقية، وأكثر اهتمامًا بالمعلمات التي تؤدي إلى تنبؤ عالي الدقة (Vapnik، 1992). لحسن الحظ، حتى في مشكلات التحسين الصعبة، غالبًا ما يجد التدرج الاشتقاقي العشوائي حلولًا جيدة بشكل ملحوظ، ويرجع

ذلك جزئيًا إلى حقيقة أنه، بالنسبة للشبكات العميقة، توجد العديد من تكوينات المعلمات التي تؤدي إلى تنبؤ عالي الدقة.

3.4.5. الملخص

في هذا القسم، اتخذنا خطوة مهمة نحو تصميم أنظمة التعلم العميق من خلال تنفيذ نموذج شبكة عصبية يعمل بكامل طاقته وحلقة تدريب.في هذه العملية، قمنا ببناء أداة تحميل البيانات، ونموذج، ودالة الخطأ، وإجراء التحسين، وأداة الرسم والمراقبة. لقد فعلنا ذلك من خلال تكوين كائن بايثون يحتوي على جميع المكونات ذات الصلة لتدريب النموذج. على الرغم من أن هذا ليس تطبيقًا احترافيًا بعد، إلا أنه يعمل بشكل مثالي ويمكن أن يساعدك رمز مثل هذا بالفعل في حل المشكلات الصغيرة بسرعة.في الأقسام التالية، سنرى كيفية القيام بذلك بشكل أكثر إيجازًا (تجنب الكود المعياري avoiding boilerplate code) وبكفاءة أكبر (استخدم وحدات معالجة الرسومات GPUs الخاصة بنا إلى أقصى إمكاناتها).

3.4.6. التمارين

1. ماذا سيحدث إذا قمنا بتهيئة الأوزان إلى الصفر. هل ستظل الخوارزمية تعمل؟ ماذا لو قمنا بتهيئة المعلمات مع التباين 1,000 بدلاً من 0.01 ؟
2. افترض أنك جورج سيمون أوم تحاول ابتكار نموذج للمقاومات التي تربط الجهد والتيار. هل يمكنك استخدام التفاضل التلقائي automatic differentiation لمعرفة معلمات نموذجك؟
3. هل يمكنك استخدام قانون بلانك Planck's Law لتحديد درجة حرارة جسم ما باستخدام كثافة الطاقة الطيفية؟ كمرجع، فإن الكثافة الطيفية B للإشعاع المنبعث من جسم أسود هي $B(\lambda, T) = \frac{2hc^2}{\lambda^5} \cdot (\exp \frac{hc}{\lambda kT} - 1)^{-1}$. λ هو الطول الموجي، وT درجة الحرارة، وc سرعة الضوء، وh كمية بلانك، وk ثابت بولتزمان. تقيس الطاقة لأطوال موجية مختلفة وتحتاج الآن لمواءمة منحنى الكثافة الطيفية مع قانون بلانك.
4. ما هي المشاكل التي قد تواجهها إذا أردت حساب المشتقات الثانية للخطأ؟ كيف تصلحهم؟
5. لماذا طريقة إعادة التشكيل `reshape` مطلوبةفي دالة الخطأ `loss function` ؟
6. جرب استخدام معدلات تعلم مختلفة لمعرفة مدى سرعة انخفاض قيمة دالة الخطأ. هل يمكنك تقليل الخطأ عن طريق زيادة عدد فترات التدريب number of epochs of training؟
7. إذا كان عدد الأمثلة لا يمكن تقسيمه على حجم الدُفعة، فماذا يحدث لـ `data_iter` في نهاية الفترة epoch؟

8. حاول تنفيذ دالة خطأ مختلفة، مثل خطأ القيمة المطلقة absolute value loss `(y_hat - d2l.reshape(y, y_hat.shape)).abs().sum()`.
   1. تحقق مما يحدث للبيانات العادية.
   2. تحقق مما إذا كان هناك اختلاف في السلوك إذا قمت بتشويش بعض إدخالات $\mathbf{y}$ مثل $y_5 = 10{,}000$.
   3. هل يمكنك التفكير في حل رخيص للجمع بين أفضل جوانب الخسارة التربيعية وخسارة القيمة المطلقة؟ تلميح: كيف يمكنك تجنب قيم التدرج الكبيرة حقًا؟
9. لماذا نحتاج إلى تعديل مجموعة البيانات؟ هل يمكنك تصميم حالة تؤدي فيها مجموعة بيانات ضارة إلى كسر خوارزمية التحسين بطريقة أخرى؟

3.5 التنفيذ المختصر للانحدار الخطي Concise Implementation of Linear Regression

شهد التعلم العميق انفجارًا كامبريًا Cambrian explosion من نوع ما خلال العقد الماضي. إن العدد الهائل من التقنيات والتطبيقات والخوارزميات يفوق إلى حد بعيد التقدم المحرزفي العقود السابقة. ويرجع ذلك إلى مجموعة مصادفة من عدة عوامل، أحدها هو الأدوات المجانية القوية التي يقدمها عدد من أطر التعلم العميق مفتوحة المصدر. يمكن القول إن Theano (Bergstra et al.، 2010) و DistBelief (Dean et al.، 2012)، و Caffe (Jia et al.، 2014) يمثل الجيل الأول من هذه النماذج التي وجدت اعتمادًا واسع النطاق. على عكس الأعمال السابقة (الأساسية) مثل SN2 (Simulateur Neuristique) Cun، Bottou and Le Cun، 1988) ، والتي قدمت تجربة برمجة تشبه Lisp ، توفر الأطر الحديثة تمايزًا تلقائيًا وملاءمة بايثون. تسمح لنا هذه الأطر بأتمتة العمل المتكرر لتنفيذ خوارزميات التعلم القائم على التدرج وتصميمه.

في القسم 3.4، اعتمدنا فقط على (1) الموترات لتخزين البيانات والجبر الخطي؛ و (2) التفاضل التلقائي لحساب التدرجات.في الممارسة العملية، نظرًا لأن مكررات البيانات ودوال الخطأ والمحسّنات وطبقات الشبكة العصبية شائعة جدًا، فإن المكتبات الحديثة تنفذ هذه المكونات لنا أيضًا.في هذا القسم، سنوضح لك كيفية تنفيذ نموذج الانحدار الخطي من القسم 3.4 بإيجاز باستخدام واجهات برمجة التطبيقات API عالية المستوى لأطر التعلم العميق.

```
import numpy as np
import tensorflow as tf
from d2l import tensorflow as d2l
```

3.5.1. تعريف النموذج Defining the Model

عندما قمنا بتنفيذ الانحدار الخطي من البدايةفي القسم 3.4، قمنا بتعريف معلمات نموذجنا بوضوح وقمنا بترميز الحسابات لإنتاج مخرجات باستخدام عمليات الجبر الخطي الأساسية. يجب أن تعرف كيف تفعل هذا. ولكن بمجرد أن تصبح نماذجك أكثر تعقيدًا، وبمجرد أن تضطر إلى القيام بذلك كل يوم تقريبًا، ستكون سعيدًا بالمساعدة. الوضع مشابه لترميز مدونتك الخاصة من البداية. يعد القيام بذلك مرة أو مرتين أمرًا مفيدًا ومفيدًا، لكنك ستكون مطور ويب رديئًا إذا قضيت شهرًافي إعادة اختراع العجلة.

بالنسبة للعمليات القياسية، يمكننا استخدام الطبقات المحددة مسبقًا لإطار العمل، والتي تسمح لنا بالتركيز على الطبقات المستخدمة لبناء النموذج بدلاً من القلق بشأن تنفيذها. أذكر معمارية شبكة أحادية الطبقة على النحو الموصوففي الشكل 2.1.3. تسمى الطبقة متصلة بالكامل fully connected, نظرًا لأن كل مدخل من مدخلاتها متصل بكل من مخرجاتها عن طريق ضرب المصفوفة–المتجه matrix-vector multiplication.

في Keras، يتم تحديد الطبقة المتصلة بالكاملفي فئة `Dense`. نظرًا لأننا نريد فقط إنشاء ناتج قيمة قياسية واحده Scalar، فقد قمنا بتعيين هذا الرقم على 1. وتجدر الإشارة إلى أنه، للسهولة، لا يتطلب منا Keras تحديد شكل الإدخال لكل طبقة. لا نحتاج إلى إخبار Keras بعدد المدخلات التي تدخلفي هذه الطبقة الخطية. عندما نحاول لأول مرة تمرير البيانات من خلال نموذجنا، على سبيل المثال، عندما ننفذ `net(X)` لاحقًا، ستستنتج Keras تلقائيًا عدد المدخلات لكل طبقة. سنصف كيف يعمل هذا بمزيد من التفصيل لاحقًا.

```
class LinearRegression(d2l.Module):  #@save
    def __init__(self, lr):
        super().__init__()
        self.save_hyperparameters()
        initializer =
tf.initializers.RandomNormal(stddev=0.01)
        self.net = tf.keras.layers.Dense(1,
kernel_initializer=initializer)
```

في طريقة `forward`، نستدعي دالة `__call__` المضمنة للطبقات المحددة مسبقًا لحساب المخرجات.

```
@d2l.add_to_class(LinearRegression)  #@save
def forward(self, X):
    """The linear regression model."""
    return self.net(X)
```

3.5.2. تعريف دالة الخطأ Defining the Loss Function

تحسب فئة `MeanSquaredError` متوسط الخطأ التربيعي (بدون 1/2 العامل في (3.1.5)). بشكل افتراضي، تقوم بإرجاع متوسط الخطأ على الأمثلة .

```
@d2l.add_to_class(LinearRegression)  #@save
def loss(self, y_hat, y):
    fn = tf.keras.losses.MeanSquaredError()
    return fn(y, y_hat)
```

3.5.3. تعريف خوارزمية التحسين Defining the Optimization Algorithm

Minibatch SGD هي أداة قياسية لتحسين الشبكات العصبية ، وبالتالي تدعمها Keras جنبًا إلى جنب مع عدد من الاختلافات في هذه الخوارزمية في وحدة `optimizers`.

```
@d2l.add_to_class(LinearRegression)  #@save
def configure_optimizers(self):
    return tf.keras.optimizers.SGD(self.lr)
```

3.5.4. التدريب Training

ربما لاحظت أن التعبير عن نموذجنا من خلال واجهات برمجة التطبيقات API عالية المستوى لإطار عمل التعلم العميق يتطلب عددًا أقل من أسطر التعليمات البرمجية. لم يكن علينا تخصيص المعلمات بشكل فردي أو تحديد دالة الخطأ أو تنفيذ minibatch SGD. بمجرد أن نبدأ العمل مع نماذج أكثر تعقيدًا، فإن مزايا واجهة برمجة التطبيقات عالية المستوى ستنمو بشكل كبير. الآن بعد أن أصبح لدينا جميع الأجزاء الأساسية في مكانها الصحيح، فإن حلقة التدريب نفسها هي نفسها التي طبقناها من البداية. لذلك نحن فقط نستدعي طريقة `fit` (المقدمة في القسم 3.2.4)، والتي تعتمد على تنفيذ طريقة `fit_epoch` في القسم 3.4 ، لتدريب نموذجنا.

```
model = LinearRegression(lr=0.03)
data = d2l.SyntheticRegressionData(w=tf.constant([2, -
3.4]), b=4.2)
trainer = d2l.Trainer(max_epochs=3)
trainer.fit(model, data)
```

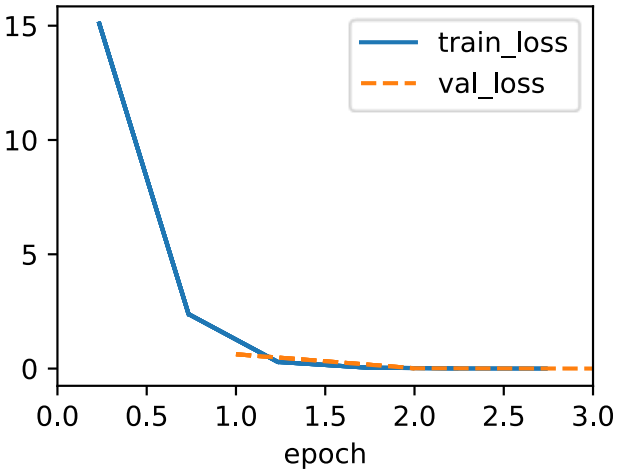

أدناه، نقارن معلمات النموذج التي تم تعلمها من خلال التدريب على البيانات المحدودة والمعلمات الفعلية التي أنشأت مجموعة البيانات الخاصة بنا. للوصول إلى المعلمات، نصل إلى أوزان وانحياز الطبقة التي نحتاجها. كما هو الحال في تنفيذنا من البداية، لاحظ أن معلماتنا المقدرة قريبة من نظيراتها الحقيقية.

```
@d2l.add_to_class(LinearRegression)  #@save
def get_w_b(self):
    return (self.get_weights()[0],
self.get_weights()[1])

w, b = model.get_w_b()
print(f'error in estimating w: {data.w - tf.reshape(w,
data.w.shape)}')
print(f'error in estimating b: {data.b - b}')
```

```
error in estimating w: [ 0.00565076 -0.0058403 ]
error in estimating b: [0.01354933]
```

3.5.5. الملخص

يحتوي هذا القسم على أول تطبيق لشبكة عميقة (في هذا الكتاب) للاستفادة من وسائل الراحة التي توفرها أطر التعلم العميق الحديثة، مثل Gluon ، JAX، PyTorch ، Tensorflow. استخدمنا الإعدادات الافتراضية لإطار العمل لتحميل البيانات، وتحديد الطبقة، ودالة الخطأ، والمحسن، وحلقة التدريب. عندما يوفر إطار العمل جميع الميزات الضرورية، فمن الجيد عمومًا استخدامها، نظرًا لأن تطبيقات المكتبة لهذه المكونات تميل إلى تحسين الأداء بشكل كبير واختبارها بشكل صحيح من أجل الموثوقية. في نفس الوقت، حاول ألا تنسى أنه يمكن تنفيذ هذه

الوحدات مباشرة. هذا مهم بشكل خاص للباحثين الطموحين الذين يرغبونفي العيش على حافة النزف لتطوير النموذج، حيث ستبتكر مكونات جديدة لا يمكن أن توجدفي أي مكتبة حالية.

في TensorFlow، توفر وحدة `data` أدوات لمعالجة البيانات، وتحدد وحدة `keras` عددًا كبيرًا من طبقات الشبكة العصبية ودوال الخطأ الشائعة. علاوة على ذلك، توفر وحدة `initializers` طرقًا مختلفة لتهيئة معلمة النموذج. يتم استنتاج الأبعاد والتخزين للشبكات تلقائيًا (ولكن احرص على عدم محاولة الوصول إلى المعلمات قبل تهيئتها).

3.5.6. التمارين

1. كيف ستحتاج إلى تغيير معدل التعلم إذا قمت باستبدال الخطأ الإجمالي على minibatch بمتوسط فوق الخطأفي minibatch؟
2. راجع وثائق إطار العمل لمعرفة دوال الخطأ المتوفرة. على وجه الخصوص، استبدل الخطأ التربيعية بدالة الخطأ القوية لهوبر Huber's robust loss function. أي، استخدم دالة الخطأ:

$$l(y, y') = \begin{cases} |y - y'| - \frac{\sigma}{2} & \text{if } |y - y'| > \sigma \\ \frac{1}{2\sigma}(y - y')^2 & \text{otherwise} \end{cases}$$

3. كيف يمكنك الوصول إلى التدرج لأوزان النموذج؟
4. كيف يتغير الحل إذا قمت بتغيير معدل التعلم وعدد الفترات؟ هل تستمرفي التحسن؟
5. كيف يتغير الحل عندما تقوم بتغيير كمية البيانات التي يتم إنشاؤها؟

1. ارسم خطأ التقدير لـ $\hat{\mathbf{w}} - \mathbf{w}$و $\hat{b} - b$كدالة لمقدار البيانات. تلميح: قم بزيادة كمية البيانات لوغاريتميًا وليس خطيًا، أي 5 ، 10 ، 20 ، 50 ، ... ، 10000 بدلاً من 1000 ، 2000 ، ... ، 10000.
2. لماذا الاقتراحفي التلميح مناسب؟

3.6 التعميم Generalization

ضعفي اعتبارك أن اثنين من طلاب الكلية يستعدان بجد للامتحان النهائي. بشكل عام، سيتألف هذا الإعداد من ممارسة واختبار قدراتهم من خلال إجراء الاختبارات التي أجريتفي السنوات السابقة. ومع ذلك، فإن الأداء الجيدفي الاختبارات السابقة لا يضمن تفوقهم عندما يكون الأمر مهمًا. على سبيل المثال، تخيل طالبًا، تدعى إليفنتين إيلي Elephantine Ellie، تألف إعدادها بالكامل من حفظ إجابات أسئلة امتحان السنوات السابقة. حتى لو كانت إيلي تتمتع بذاكرة فيل، وبالتالي تمكنت تمامًا من تذكر إجابة أي سؤال سبق رؤيته، فقد تتجمد مع ذلك عندما تواجه

سؤالًا جديدًا (لم يسبق رؤيته). بالمقارنة، تخيل أن تلميذة أخرى، إيرين الاستقرائية Inductive Irene، لديها مهارات حفظ ضعيفة نسبيًا، ولكنها موهوبةفي التقاط الأنماط. لاحظ أنه إذا كان الاختبار يتألف حقًا من أسئلة معاد تدويرها من عام سابق، فستتفوق إيلي بسهولة على إيرين. حتى لو أسفرت أنماط إيرين المستنبطة عن تنبؤات دقيقة بنسبة 90٪، فلا يمكنها أبدًا منافسة استدعاء إيلي بنسبة 100٪. ومع ذلك، حتى لو كان الاختبار يتكون بالكامل من أسئلة جديدة، فقد تحافظ إيرين على متوسطها البالغ 90٪.

كعلماءفي التعلم الآلي، هدفنا هو اكتشاف الأنماط discover patterns. ولكن كيف يمكننا التأكد من أننا اكتشفنا حقًا نمطًا عامًا ولم نحفظ بياناتنا ببساطة؟في معظم الأحيان، تكون تنبؤاتنا مفيدة فقط إذا اكتشف نموذجنا مثل هذا النمط. لا نريد توقع أسعار الأسهمفي الأمس، ولكن أسعار الغد. لا نحتاج إلى التعرف على الأمراض التي تم تشخيصها بالفعل للمرضى الذين تمت رؤيتهم سابقًا، ولكن بالأحرى الأمراض التي لم يتم تشخيصها من قبلفي المرضى الذين لم يتم رؤيتهم من قبل. هذه المشكلة ـ كيفية اكتشاف الأنماط التي تعمم how to discover patterns that generalize ـ هي المشكلة الأساسية للتعلم الآلي، ويمكن القول إنها مشكلة جميع الإحصائيات. قد نعتبر هذه المشكلة مجرد شريحة واحدة من سؤال أعظم بكثير يبتلع العلم كله: متى يكون لدينا ما يبرر قيامنا بالقفزة من ملاحظات معينة إلى عبارات أكثر عمومية (Popper, 2005)؟

في الحياة الواقعية، يجب علينا ملائمة fit النماذج باستخدام مجموعة محدودة من البيانات. تختلف المقاييس النموذجية لتلك البيانات بشكل كبير عبر المجالات. بالنسبة للعديد من المشكلات الطبية المهمة، لا يمكننا الوصول إلا إلى بضعة آلاف من نقاط البيانات. عند دراسة الأمراض النادرة، قد نكون محظوظين للوصول إلى المئات. على النقيض من ذلك، تحتوي أكبر مجموعات البيانات العامة التي تتكون من صور فوتوغرافية مصنفة (على سبيل المثال، ImageNet) (2009,Deng et al.)، على ملايين الصور. وبعض مجموعات الصور غير المسماة unlabeled image مثل مجموعة بيانات Flickr YFC100M يمكن أن تكون أكبر، حيث تحتوي على أكثر من 100 مليون صورة (Thomee et al.، 2016). ومع ذلك، حتىفي هذا النطاق الأقصى، يظل عدد نقاط البيانات المتاحة صغيرًا بشكل لا نهائي مقارنة بمساحة جميع الصور الممكنة بدقة 1 ميجابكسل. عندما نعمل مع عينات محدودة، يجب أن نضعفي اعتبارنا المخاطر التي قد نلائمها مع بيانات التدريب الخاصة بنا، فقط لنكتشف أننا فشلنافي اكتشاف نمط قابل للتعميم.

تسمى ظاهرة الاقتراب من بيانات التدريب الخاصة بنا أكثر من التوزيع الأساسي بفرط التجهيز او التعلم overfitting، وغالبًا ما تسمى تقنيات مكافحة فرط التعلم بأساليب التنظيم

regularization. بينما لا يوجد بديل لمقدمة مناسبة لنظرية التعلم الإحصائي (انظر Boucheron et al. (2005)، Vapnik (1998))، سنمنحك الحدس الكافي فقط للبدء. سوف نعيد النظر في التعميم في العديد من الفصول في جميع أنحاء الكتاب، ونستكشف كل مما هو معروف عن المبادئ الكامنة وراء التعميم في النماذج المختلفة، وكذلك التقنيات الاستدلالية التي تم العثور عليها (تجريبيًا) لتحقيق تعميم أفضل للمهام ذات الأهمية العملية.

3.6.1. خطأ في التدريب وخطأ في التعميم Training Error and Generalization Error

في إعداد التعلم القياسي الخاضع للإشراف، نفترض أن بيانات التدريب وبيانات الاختبار مستمدة بشكل مستقل عن التوزيعات المتطابقة Independently from Identical Distributions. وهذا ما يسمى عادة افتراض IID. في حين أن هذا الافتراض قوي، فمن الجدير بالذكر أنه في غياب أي افتراض من هذا القبيل سنكون ميتين في الماء. لماذا يجب أن نعتقد أن بيانات التدريب المأخوذة من التوزيع $P(X, Y)$ يجب أن تخبرنا بكيفية عمل تنبؤات بشأن بيانات الاختبار الناتجة عن توزيع مختلف $Q(X, Y)$؟ إن تحقيق مثل هذه القفزات يتطلب افتراضات قوية حول كيفية ارتباط P و Q. سنناقش لاحقًا بعض الافتراضات التي تسمح بالتغيرات في التوزيع ولكننا نحتاج أولاً إلى فهم حالة IID حيث $P(\cdot) = Q(\cdot)$.

بادئ ذي بدء، نحتاج إلى التفريق بين خطأ التدريب R_{emp}، وهو إحصاء محسوب على مجموعة بيانات التدريب، وخطأ التعميم R، وهو توقع يتم إجراؤه فيما يتعلق بالتوزيع الأساسي. يمكنك التفكير في خطأ التعميم كما تراه إذا قمت بتطبيق النموذج الخاص بك على دفق لا نهائي infinite stream من أمثلة البيانات الإضافية المستمدة من نفس توزيع البيانات الأساسي. رسميًا، يتم التعبير عن خطأ التدريب كمجموع (بنفس الترميز في القسم 3.1):

$$R_{\text{emp}}[\mathbf{X}, \mathbf{y}, f] = \frac{1}{n}\sum_{i=1}^{n} \quad l(\mathbf{x}^{(i)}, y^{(i)}, f(\mathbf{x}^{(i)})),$$

بينما يتم التعبير عن خطأ التعميم كجزء لا يتجزأ:

$$R[p, f] = E_{(\mathbf{x},y)\sim P}[l(\mathbf{x}, y, f(\mathbf{x}))] = \int\int l(\mathbf{x}, y, f(\mathbf{x}))p(\mathbf{x}, y)d\mathbf{x}dy.$$

من الناحية الإشكالية، لا يمكننا أبدًا حساب خطأ التعميم تمامًا. لا أحد يخبرنا أبدًا عن الشكل الدقيق لدالة الكثافة $p(\mathbf{x}, y)$. علاوة على ذلك، لا يمكننا أخذ عينة من دفق لا نهائي من نقاط البيانات. وبالتالي، من الناحية العملية، يجب علينا تقدير خطأ التعميم من خلال تطبيق نموذجنا على مجموعة اختبار مستقلة تتكون من اختيار عشوائي $\mathbf{X}'$ للأمثلة والتسميات $\mathbf{y}'$ التي تم حجبها

من مجموعة التدريب الخاصة بنا. يتكون هذا من تطبيق نفس الصيغة المستخدمة لحساب خطأ التدريب التجريبي ولكن على مجموعة اختبار $\mathbf{X}', \mathbf{y}'$.

بشكل حاسم، عندما نقوم بتقييم المصنف الخاص بنا على مجموعة الاختبار، فإننا نعمل مع مصنف ثابت fixed classifier (لا يعتمد على عينة مجموعة الاختبار)، وبالتالي فإن تقدير الخطأ هو ببساطة مشكلة تقدير المتوسط problem of mean estimation. ومع ذلك لا يمكن قول الشيء نفسه بالنسبة لمجموعة التدريب. لاحظ أن النموذج الذي انتهينا إليه يعتمد بشكل صريح على اختيار مجموعة التدريب، وبالتالي فإن خطأ التدريب سيكون بشكل عام تقديرًا متحيزًا للخطأ الحقيقي على السكان الأساسيين. السؤال المركزي للتعميم هو متى يجب أن نتوقع أن يكون خطأ التدريب لدينا قريبًا من الخطأ السكاني population error (وبالتالي خطأ التعميم).

3.6.1.1. تعقيد النموذج Model Complexity

في النظرية الكلاسيكية، عندما يكون لدينا نماذج بسيطة وبيانات وفيرة، تميل أخطاء التدريب والتعميم إلى التقارب. ومع ذلك، عندما نعمل مع نماذج أكثر تعقيدًا و / أو أمثلة أقل، نتوقع أن ينخفض خطأ التدريب بينما تنمو فجوة التعميم. هذا يجب ان لا يكون مفاجئا. تخيل أن فئة النموذج معبرة جدًا لدرجة أنه بالنسبة لأي مجموعة بيانات n من الأمثلة، يمكننا العثور على مجموعة من المعلمات التي يمكن أن تتلاءم تمامًا مع التسميات التعسفية، حتى لو تم تعيينها عشوائيًا.في هذه الحالة، حتى لو تناسبنا بيانات التدريب الخاصة بنا تمامًا، كيف يمكننا استنتاج أي شيء عن خطأ التعميم؟ لكل ما نعرفه، قد لا يكون خطأ التعميم أفضل من التخمين العشوائي.

بشكل عام،في حالة عدم وجود أي قيود على فئة النموذج لدينا، لا يمكننا الاستنتاج بناءً على ملاءمة بيانات التدريب وحدها أن نموذجنا قد اكتشف أي نمط قابل للتعميم (Vapnik et al.، 1994). من ناحية أخرى، إذا كانت فئة النموذج الخاصة بنا غير قادرة على ملاءمة تسميات عشوائية، فلا بد أنها اكتشفت نمطًا. استمدت الأفكار النظرية التعليمية حول تعقيد النموذج بعض الإلهام من أفكار كارل بوبر، فيلسوف العلم المؤثر، الذي صاغ معيار القابلية للتزييف criterion of falsifiability. وفقًا لبوبر، النظرية التي يمكن أن تشرح أي وجميع الملاحظات ليست نظرية علمية على الإطلاق! بعد كل شيء، ماذا قال لنا عن العالم إذا لم يستبعد أي احتمال؟ باختصار، ما نريده هو فرضية لا يمكن أن تفسر أي ملاحظات قد نتصورها ومع ذلك تصادف أنها متوافقة مع تلك الملاحظات التي نقوم بهافي الواقع.

الآن ما يشكل بدقة فكرة مناسبة لتعقيد النموذج هو مسألة معقدة.في كثير من الأحيان، تكون النماذج التي تحتوي على المزيد من المعلمات قادرة على ملاءمة عدد أكبر من التسميات المعينة بشكل تعسفي. ومع ذلك، هذا ليس صحيحا بالضرورة. على سبيل المثال، تعمل طرق النواة

kernel methodsفي مساحات ذات أعداد لا حصر لها من المعلمات، ومع ذلك يتم التحكمفي تعقيدها بوسائل أخرى (Scholkopf and Smola، 2002). أحد المفاهيم التي غالبًا ما تكون مفيدة عن التعقيد هو نطاق القيم التي يمكن أن تتخذها المعلمات. هنا، سيكون النموذج الذي يُسمح لمعلماته بأخذ قيم عشوائية أكثر تعقيدًا. سنعيد النظرفي هذه الفكرةفي القسم التالي، عندما نقدم تناقص او اضمحلال الوزن weight decay، وهو أول أسلوب عملي لتنظيم الأمور. والجدير بالذكر أنه قد يكون من الصعب مقارنة التعقيد بين أعضاء فئات النماذج المختلفة إلى حد كبير (على سبيل المثال، أشجار القرار decision trees مقابل الشبكات العصبية neural networks).

في هذه المرحلة، يجب أن نؤكد على نقطة مهمة أخرى سنعيد النظر فيها عند إدخال الشبكات العصبية العميقة. عندما يكون النموذج قادرًا على تركيب تسميات عشوائية، فإن خطأ التدريب المنخفض لا يعني بالضرورة خطأ تعميم منخفض. ومع ذلك، فإنه لا يعني بالضرورة خطأ التعميم العالي أيضًا! كل ما يمكننا قوله بثقة هو أن خطأ التدريب المنخفض وحده لا يكفي للتصديق على خطأ التعميم المنخفض. تبين أن الشبكات العصبية العميقة هي مجرد نماذج من هذا القبيل: فبينما يتم تعميمها جيدًافي الممارسة العملية، فهي قوية جدًا بحيث لا تسمح لنا باستنتاج الكثير على أساس خطأ التدريب وحده.في هذه الحالات، يجب أن نعتمد بشكل أكبر على بياناتنا المؤجلة للمصادقة على التعميم بعد وقوع الحقيقة. يسمى الخطأفي بيانات الانتظار، أي مجموعة التحقق من الصحة validation set، خطأ التحقق من الصحة validation error.

3.6.2. الضبط الناقص Underfitting أو الضبط الزائد Overfitting؟

عندما نقارن أخطاء التدريب والتحقق من الصحة، نريد أن نضعفي اعتبارنا حالتين شائعتين. أولاً، نريد أن ننتبه للحالات التي يكون فيها خطأ التدريب وخطأ التحقق من الصحة كبيرًا ولكن هناك فجوة صغيرة بينهما. إذا كان النموذج غير قادر على تقليل خطأ التدريب، فقد يعني ذلك أن نموذجنا بسيط للغاية (أي غير معبر بشكل كاف insufficiently expressive) لالتقاط النمط الذي نحاول نمذجته. علاوة على ذلك، نظرًا لأن فجوة التعميم $(R_{\text{emp}} - R)$ بين أخطاء التدريب والتعميم لدينا صغيرة، فلدينا سبب للاعتقاد بأنه يمكننا التخلص من نموذج أكثر تعقيدًا. تُعرف هذه الظاهرة باسم الضبط الناقص underfitting.

من ناحية أخرى، كما ناقشنا أعلاه، نريد أن ننتبه للحالات التي يكون فيها خطأ التدريب لدينا أقل بكثير من خطأ التحقق من الصحة، مما يشير إلى الضبط الزائد (فرط التجهيز) overfitting الشديد. لاحظ أن فرط التجهيز ليس دائمًا أمرًا سيئًا.في التعلم العميق على وجه الخصوص، غالبًا ما يكون أداء أفضل النماذج التنبؤية أفضل بكثير على بيانات التدريب مقارنةً بالبيانات الرافضة holdout data.في النهاية، نحن نهتم عادةً بتوجيه خطأ التعميم إلى الأسفل، ولا نهتم إلا بالفجوة

بقدر ما تصبح عقبةفي طريق تحقيق هذه الغاية. لاحظ أنه إذا كان خطأ التدريب صفرًا، فإن فجوة التعميم تساوي تمامًا خطأ التعميم ولا يمكننا إحراز تقدم إلا من خلال تقليل الفجوة.

3.6.2.1. ملائمة منحنى متعدد الحدود Polynomial Curve Fitting

لتوضيح بعض الحدس الكلاسيكي حول الضبط الزائد وتعقيد النموذج، ضعفي اعتبارك ما يلي: بالنظر إلى بيانات التدريب التي تتكون من ميزة واحدة x وعلامة ذات قيمة حقيقية مقابلة y، نحاول العثور على متعدد الحدود للدرجة d

$$\hat{y} = \sum_{i=0}^{d} x^i w_i$$

لتقدير التسمية y. هذه مجرد مشكلة انحدار خطي حيث يتم إعطاء ميزاتنا من خلال قوى x، وتعطي أوزان النموذج من قبل w_i، ويتم إعطاء التحيز w_0 منذ $x^0 = 1$ الحين لكلx. نظرًا لأن هذه مجرد مشكلة انحدار خطي، فيمكننا استخدام الخطأ التربيعي كدالة للخطأ.

تعتبر دالة كثيرة الحدود ذات الترتيب الأعلى higher-order polynomial function أكثر تعقيدًا من دالة كثيرة الحدود ذات الترتيب الأدنى lower-order polynomial function، نظرًا لأن كثير الحدود ذو الترتيب الأعلى يحتوي على معلمات أكثر ونطاق اختيار دالة النموذج أوسع. عند إصلاح مجموعة بيانات التدريب، يجب أن تحقق الدوال متعددة الحدود ذات الترتيب الأعلى دائمًا خطأ تدريب أقل (في أسوأ الأحوال، متساوٍ) بالنسبة إلى كثيرات الحدود من الدرجة الأدنى.في الواقع، كلما كان لكل مثال بيانات قيمة مميزة لـ x ، فإن دالة متعددة الحدود بدرجة مساوية لعدد أمثلة البيانات يمكن أن تلائم fit مجموعة التدريب تمامًا. نحن نتخيل العلاقة بين درجة متعددة الحدود (تعقيد النموذج) والضبط الناقص مقابل الضبط الزائدفي الشكل 3.6.1.

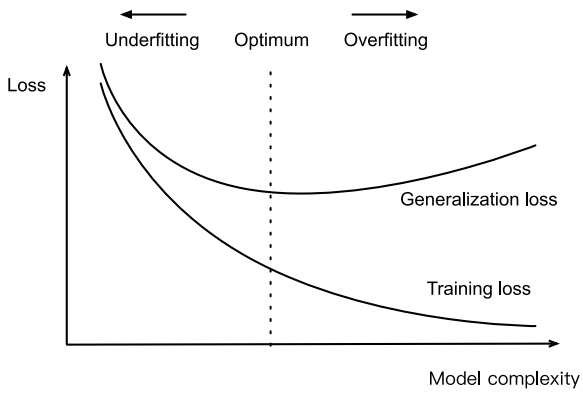

الشكل 3.6.1 تأثير تعقيد النموذج على الضبط الناقص والزائد

3.6.2.2. حجم مجموعة البيانات Dataset Size

كما يشير الحد أعلاه بالفعل، هناك اعتبار كبير آخر يجب أخذهفي الاعتبار وهو حجم مجموعة البيانات dataset size. عند إصلاح نموذجنا، كلما قل عدد العينات التي لدينافي مجموعة بيانات التدريب، زادت احتمالية (والأكثر خطورة) أن نواجه فرط التجهيز. مع زيادة كمية بيانات التدريب، ينخفض خطأ التعميم عادةً. علاوة على ذلك، بشكل عام، المزيد من البيانات لا يضر أبدًا. بالنسبة للمهمة الثابتة وتوزيع البيانات، يجب ألا يزيد تعقيد النموذج بسرعة أكبر من كمية البيانات. بالنظر إلى المزيد من البيانات، قد نحاول ملاءمة نموذج أكثر تعقيدًا.في غياب البيانات الكافية، قد يكون من الصعب التغلب على النماذج الأبسط. بالنسبة للعديد من المهام، يتفوق التعلم العميق فقط على النماذج الخطية عندما تتوفر عدة آلاف من أمثلة التدريب. يرجع النجاح الحالي للتعلم العميق جزئيًا إلى وفرة مجموعات البيانات الضخمة الناشئة عن شركات الإنترنت والتخزين الرخيص والأجهزة المتصلة والرقمنة الواسعة للاقتصاد.

3.6.3. اختيار النموذج Model Selection

عادة، نختار نموذجنا النهائي، فقط بعد تقييم نماذج متعددة تختلف بطرق مختلفة (بنى مختلفة، أهداف تدريب، ميزات مختارة، معالجة البيانات المسبقة، معدلات التعلم، إلخ). الاختيار من بين العديد من النماذج يسمى على نحو مناسب اختيار النموذج model selection.

من حيث المبدأ، لا ينبغي أن نلمس مجموعة الاختبار الخاصة بنا إلا بعد أن نختار جميع معلماتنا الفائقة. إذا استخدمنا بيانات الاختبارفي عملية اختيار النموذج، فهناك خطر أننا قد نفرط overfit في بيانات الاختبار. عندها سنكونفي مشكلة خطيرة. إذا قمنا بزيادة بيانات التدريب الخاصة بنا، فهناك دائمًا تقييم لبيانات الاختبار لإبقائنا صادقين. ولكن إذا تجاوزنا بيانات الاختبار، فكيف لنا أن نعرف ذلك؟ انظر Ong et al. (2005) على سبيل المثال كيف يمكن أن يؤدي ذلك إلى نتائج سخيفة حتى بالنسبة للنماذج التي يمكن التحكم فيها بإحكامفي التعقيد.

وبالتالي، لا ينبغي لنا أبدًا الاعتماد على بيانات الاختبار لاختيار النموذج. ومع ذلك لا يمكننا الاعتماد فقط على بيانات التدريب لاختيار النموذج إما لأننا لا نستطيع تقدير خطأ التعميم على نفس البيانات التي نستخدمها لتدريب النموذج.

في التطبيقات العملية، تصبح الصورة أكثر تعكيرًا.في حين أننا من الناحية المثالية لن نلمس بيانات الاختبار إلا مرة واحدة، لتقييم أفضل نموذج أو لمقارنة عدد صغير من النماذج مع بعضها البعض، نادرًا ما يتم تجاهل بيانات الاختبار الواقعية بعد استخدام واحد فقط. نادرًا ما يمكننا تحمل مجموعة اختبار جديدة لكل جولة من التجارب.في الواقع، يمكن أن يكون لإعادة تدوير البيانات المعيارية لعقود تأثير كبير على تطوير الخوارزميات، على سبيل المثال، لتصنيف الصور image classification والتعرف البصري على الأحرف optical character recognition.

تتمثل الممارسة الشائعة لمعالجة مشكلة التدريب على مجموعة الاختبارفي تقسيم بياناتنا بثلاث طرق، بمافي ذلك مجموعة التحقق من الصحة بالإضافة إلى مجموعات بيانات التدريب والاختبار. والنتيجة هي ممارسة غامضة حيث تكون الحدود بين التحقق من الصحة وبيانات الاختبار غامضة بشكل مثير للقلق. ما لم ينص صراحة على خلاف ذلك،في التجاربفي هذا الكتاب، نحن نعمل حقًا مع ما ينبغي أن يُطلق عليه حقًا بيانات التدريب وبيانات التحقق من الصحة، بدون مجموعات اختبار حقيقية. لذلك، فإن الدقة المبلغ عنهافي كل تجربة للكتاب هي في الحقيقة دقة التحقق وليست دقة مجموعة اختبار حقيقية.

3.6.3.1. التحقق المتبادل Cross-Validation

عندما تكون بيانات التدريب نادرة، فقد لا نتمكن حتى من تحمل بيانات كافية لتشكيل مجموعة تحقق مناسبة. أحد الحلول الشائعة لهذه المشكلة هو استخدام التحقق المتبادل k-fold Cross-Validation. هنا، يتم تقسيم بيانات التدريب الأصلية إلى K مجموعات فرعية غير متداخلة. ثم يتم تنفيذ تدريب النموذج والتحقق من الصحة K مرات،في كل مرة يتم فيها التدريب على مجموعات فرعية والتحقق من صحة $K-1$ مجموعة فرعية مختلفة (المجموعة التي لم يتم استخدامها للتدريبفي تلك الجولة). أخيرًا، يتم تقدير أخطاء التدريب والتحقق من الصحة من خلال حساب متوسط النتائج من K التجارب.

3.6.4. الملخص

استكشف هذا القسم بعض أسس التعميمفي التعلم الآلي. تصبح بعض هذه الأفكار معقدة وغير بديهية عندما نصل إلى نماذج أعمق، فهناك، تكون النماذج قادرة على الضبط الزائد overfitting للبيانات بشكل سيئ، ويمكن أن تكون مفاهيم التعقيد ذات الصلة ضمنية وغير بديهية (على سبيل المثال، البنى الأكبر مع المزيد من المعلمات المعممة بشكل أفضل). نترك لك بعض القواعد الأساسية:

1. استخدام مجموعات التحقق من الصحة (أو التحقق المتبادل k-fold Cross-Validation) لاختيار النموذج؛
2. غالبًا ما تتطلب النماذج الأكثر تعقيدًا المزيد من البيانات؛
3. تتضمن مفاهيم التعقيد ذات الصلة كلاً من عدد المعلمات ونطاق القيم التي يُسمح لها بأخذها؛
4. مع الحفاظ على جميع الأمور الأخرى متساوية، تؤدي البيانات المتزايدة دائمًا تقريبًا إلى تعميم أفضل؛

5. كل هذا الحديث عن التعميم مبني على افتراض IID. إذا قمنا بتخفيف هذا الافتراض، والسماح للتوزيعات بالانتقال بين فترات التدريب والاختبار، فلا يمكننا قول أي شيء عن التعميمفي غياب افتراض آخر (ربما أكثر اعتدالًا).

3.6.5. التمارين

1. متى يمكنك حل مشكلة الانحدار متعدد الحدود polynomial regression بالضبط؟
2. أعط ما لا يقل عن خمسة أمثلة حيث المتغيرات العشوائية التابعة تجعل معالجة المشكلة على أنها بيانات IID غير مستحسنة.
3. هل يمكن أن تتوقع ألا ترى أي خطأفي التدريب؟ ما هي الظروف التي سترى فيها خطأ التعميم الصفري؟
4. لماذا يعد التحقق من الصحة المتبادل ذو الطيات k-fold Cross-Validation مكلفًا جدًا للحساب؟
5. لماذا يكون تقدير خطأ التحقق المتبادل ذو أضعاف منحازة؟
6. يتم تعريف بُعد VC على أنه الحد الأقصى لعدد النقاط التي يمكن تصنيفها باستخدام تسميات عشوائية $\{\pm 1\}$ بواسطة دالة لفئة من الدوال. لماذا قد لا تكون هذه فكرة جيدة لقياس مدى تعقيد فئة الدوال؟ تلميح: ماذا عن حجم الدوال؟
7. يمنحك مديرك مجموعة بيانات صعبة لا تعمل فيها الخوارزمية الحالية بشكل جيد. كيف تبرر له أنك بحاجة إلى مزيد من البيانات؟ تلميح: لا يمكنك زيادة البيانات ولكن يمكنك تقليلها.

3.7 اضمحلال الوزن Weight Decay

الآن بعد أن وصفنا مشكلة الضبط الزائد overfitting، يمكننا تقديم تقنية التنظيم regularization الأولى لدينا. تذكر أنه يمكننا دائمًا التخفيف من فرط التجهيز (الضبط الزائد) من خلال جمع المزيد من بيانات التدريب. ومع ذلك، قد يكون ذلك مكلفًا أو يستغرق وقتًا طويلاً أو خارج عن سيطرتنا تمامًا، مما يجعله مستحيلًا على المدى القصير.في الوقت الحالي، يمكننا أن نفترض أن لدينا بالفعل قدرًا كبيرًا من البيانات عالية الجودة بقدر ما تسمح به مواردنا ونركز على الأدوات الموجودة تحت تصرفنا حتى عندما يتم أخذ مجموعة البيانات على أنها أمر مفروغ منه.

تذكر أنهفي مثال الانحدار متعدد الحدود polynomial regression الخاص بنا (القسم 3.6.2.1)، يمكننا تحديد سعة نموذجنا عن طريق تعديل درجة كثير الحدود المتوافقة.في الواقع، يعد الحد من عدد الميزات أسلوبًا شائعًا للتخفيف من الضبط الزائد. ومع ذلك، فإن مجرد

إهمال الميزات جانباً يمكن أن يكون أداة حادة للغاية. بالتمسك بمثال الانحدار متعدد الحدود، ضعفي اعتبارك ما يمكن أن يحدث مع المدخلات عالية الأبعاد high-dimensional input. تسمى الامتدادات الطبيعية لكثيرات الحدود للبيانات متعددة المتغيرات باحادية الحد monomials، والتي هي ببساطة نتاج قوى المتغيرات. درجة المتغيرات أحادية الحد هي مجموع القوى. فمثلا، $x_1^2 x_2$ و $x_3 x_5^2$ كلاهما أحادي الحد من الدرجة الثالثة.

لاحظ أن عدد الحدود مع الدرجة d يتضخم بسرعة كلما زاد حجم d. بالنظر إلى المتغيرات k ، يكون عدد احاديات الحد من الدرجة d (أي k متعدد الخيوط d) هو $\binom{k-1+d}{k-1}$. حتى التغييرات الصغيرةفي الدرجة، لنقل من 2 إلى 3 ، تزيد بشكل كبير من تعقيد نموذجنا. وبالتالي نحتاج غالبًا إلى أداة أكثر دقة لتعديل تعقيد الدالة.

3.7.1. المعايير وتناقص الوزن Norms and Weight Decay

بدلاً من التلاعب المباشر بعدد المعلمات، يعمل تناقص الوزن عن طريق تقييد القيم التي يمكن أن تأخذها المعلمات. أكثر شيوعًا يسمى التنظيم ℓ_2 (ℓ_2 *regularization*) خارج دوائر التعلم العميق عند تحسينه عن طريق التدرج الاشتقاقي العشوائي المصغر minibatch SGD، قد يكون تناقص الوزن هو الأسلوب الأكثر استخدامًا على نطاق واسع لتنظيم نماذج التعلم الآلي البارامترية. يتم تحفيز هذه التقنية من خلال الحدس الأساسي الذي مفاده أن الدالة $f = 0$ (تعيين القيمة 0 لجميع المدخلات) من بين جميع الدوال f هي أبسطها بمعنى ما، وأنه يمكننا قياس مدى تعقيد الدالة من خلال مسافة معلماتها من الصفر. ولكن ما مدى دقة قياس المسافة بين الدالة والصفر؟ لا توجد إجابة واحدة صحيحة.في الواقع، تم تخصيص فروع كاملة للرياضيات، بمافي ذلك أجزاء من التحليل الدالي ونظرية فضاءات باناخ Banach spaces، لمعالجة مثل هذه القضايا.

قد يكون أحد التفسيرات البسيطة هو قياس مدى تعقيد دالة خطية $f(\mathbf{x}) = \mathbf{w}^\top \mathbf{x}$ من خلال معيار norm معين لمتجه وزنها، على سبيل المثال $\|\mathbf{w}\|^2$. تذكر أننا قدمنا المعيار ℓ_2 والمعيار ℓ_1 ، وهما حالات خاصة للمعيار الأكثر عمومية ℓ_pفي القسم 2.3.11. الطريقة الأكثر شيوعًا لضمان متجه وزن صغير هي إضافة معياره كمصطلح جزائي لمشكلة تقليل الخطأ. وهكذا نستبدل هدفنا الأصلي، وهو تقليل خطأ التنبؤ prediction loss على تسميات التدريب training labels، بهدف جديد، وتقليل مجموع خطأ التنبؤ sum of the prediction loss ومدة العقوبة penalty term. الآن، إذا نما متجه الوزن بشكل كبير جدًا، فقد تركز خوارزمية التعلم الخاصة بنا على تقليل معيار الوزن $\|\mathbf{w}\|^2$ إلى الحد الأدنى مقابل تقليل خطأ التدريب. هذا هو بالضبط ما نريده. لتوضيح الأشياءفي الكود، نعيد إحياء مثالنا السابق من القسم 3.1 للانحدار الخطي. هناك، خطأنا:

$$L(\mathbf{w}, b) = \frac{1}{n}\sum_{i=1}^{n} \frac{1}{2}(\mathbf{w}^\top \mathbf{x}^{(i)} + b - y^{(i)})^2.$$

تذكر أن $\mathbf{x}^{(i)}$ هي الميزات، $y^{(i)}$ هي التسمية لأي مثال بيانات i، $(\mathbf{w}, b)$ وهي معلمات الوزن والتحيز، على التوالي. لمعاقبة حجم متجه الوزن weight vector، يجب أن نضيف $\|\mathbf{w}\|^2$ بطريقة ما إلى دالة الخطأ، ولكن كيف يجب أن يقايض النموذج الخطأ القياسي لهذه العقوبة المضافة الجديدة؟في الممارسة العملية، نميز هذه المقايضة من خلال ثابت التنظيم λ ، وهو معلمة فائقة غير سلبية نلائمها باستخدام بيانات التحقق من الصحة validation data:

$$L(\mathbf{w}, b) + \frac{\lambda}{2}\|\mathbf{w}\|^2.$$

بالنسبة لـ $\lambda = 0$ ، نستعيد دالة الخسارة الأصلية الخاصة بنا. لـ $\lambda > 0$ ، نحن نقيد حجم $\|\mathbf{w}\|$. نقسم على 2 حسب الاصطلاح: عندما نأخذ مشتق دالة تربيعية، نلغي 2 ونلغي $1/2$ ، مما يضمن أن تعبير التحديث يبدو لطيفًا وبسيطًا. قد يتساءل القارئ الذكي عن سبب تعاملنا مع المعيار التربيعي squared norm وليس المعيار القياسي standard norm (أي المسافة الإقليدية). نحن نفعل هذا للراحة الحسابية. بتربيع المعيار ℓ_2 ، نزيل الجذر التربيعي، ونترك مجموع مربعات كل مكون من متجه الوزن. هذا يجعل من السهل حساب مشتق العقوبة: مجموع المشتقات يساوي مشتق المجموع.

علاوة على ذلك، قد تسأل لماذا نتعامل مع المعيار ℓ_2 في المقام الأول وليس، على سبيل المثال، المعيار ℓ_1.في الواقع، الخيارات الأخرى صالحة وشائعةفي جميع الإحصاءات.في حين أن النماذج الخطية المنتظمة ℓ_2 تشكل خوارزمية انحدار ريدج ridge regression algorithm، فإن الانحدار الخطي المنتظم ℓ_1 هو طريقة أساسية مماثلةفي الإحصاء، والمعروفة باسم انحدار لاسو (lasso regression). أحد أسباب العمل مع المعيار ℓ_2 هو أنه يفرض عقوبة كبيرة على المكونات الكبيرة لمتجه الوزن. يؤدي هذا إلى تحيز خوارزمية التعلم الخاصة بنا نحو النماذج التي توزع الوزن بالتساوي عبر عدد أكبر من الميزات.في الممارسة العملية، قد يجعلهم ذلك أكثر قوةفي مواجهة خطأ القياسفي متغير واحد. على النقيض من ذلك، تؤدي العقوبات ℓ_1 إلى نماذج تركز الأوزان على مجموعة صغيرة من الميزات عن طريق إزالة الأوزان الأخرى إلى الصفر. يمنحنا هذا طريقة فعالة لاختيار الميزة، والتي قد تكون مرغوبة لأسباب أخرى. على سبيل المثال، إذا كان نموذجنا يعتمد فقط على بعض الميزات، فقد لا نحتاج إلى جمع البيانات أو تخزينها أو نقلها للميزات الأخرى (التي تم إسقاطها dropped).

باستخدام نفس الترميزفي (3.1.11)، تتبع تحديثات التدرج الاشتقاقي العشوائي المصغر للانحدار المنتظم ℓ_2:

$$\mathbf{w} \leftarrow (1-\eta\lambda)\mathbf{w} - \frac{\eta}{|\mathcal{B}|}\sum_{i\in\mathcal{B}} \mathbf{x}^{(i)}(\mathbf{w}^\top\mathbf{x}^{(i)} + b - y^{(i)}).$$

كمافي السابق، نقوم بتحديث $\mathbf{w}$ بناءً على المقدار الذي يختلف به تقديرنا عن الملاحظة. ومع ذلك، فإننا نقوم أيضًا بتقليص حجم $\mathbf{w}$ باتجاه الصفر. هذا هو السببفي أن الطريقة تسمى أحيانًا "تضاؤل او تناقص الوزن weight decay ": نظرًا لمصطلح العقوبة وحده، فإن خوارزمية التحسين الخاصة بنا تنقص الوزنفي كل خطوة من خطوات التدريب. على عكس اختيار الميزة feature selection، يوفر لنا تناقص الوزن آلية مستمرة لضبط تعقيد الدالة. تتوافق القيم الأصغر لـ λ لأقل تقييدًا لـ $\mathbf{w}$ ،في حين أن القيم الأكبر لـ λ تقيد $\mathbf{w}$ أكثر وضوحًا. ما إذا كنا نقوم بتضمين عقوبة التحيز b^2 المقابلة يمكن أن تختلف عبر التطبيقات، وقد تختلف عبر طبقات الشبكة العصبية.في كثير من الأحيان، لا نقوم بتنظيم مصطلح التحيز. إلى جانب ذلك، على الرغم من أن التنظيم قد لا يكون مكافئًا لتناقص الوزن بالنسبة لخوارزميات التحسين الأخرى، إلا أن فكرة التنظيم من خلال تقليص حجم الأوزان لا تزال صحيحة.

3.7.2. الانحدار الخطي عالي الأبعاد High-Dimensional Linear Regression

يمكننا توضيح فوائد تناقص الوزن من خلال مثال تركيبي بسيط.

```
%matplotlib inline
import tensorflow as tf
from d2l import tensorflow as d2l
```

أولاً، نقوم بإنشاء بعض البيانات كمافي السابق:

$$y = 0.05 + \sum_{i=1}^{d} 0.01x_i + \epsilon \text{ where } \epsilon \sim \mathcal{N}(0, 0.01^2).$$

في مجموعة البيانات التركيبية synthetic dataset هذه، يتم إعطاء التسمية الخاصة بنا من خلال دالة خطية أساسية لمدخلاتنا، تالفة بسبب الضوضاء الغاوسية مع متوسط الصفر والانحراف المعياري 0.01. لأغراض توضيحية، يمكننا أن نجعل تأثيرات الضبط الزائد واضحة، من خلال زيادة أبعاد مشكلتنا لـ $d = 200$ والعمل مع مجموعة تدريب صغيرة مع 20 مثالًا فقط.

```
class Data(d2l.DataModule):
    def __init__(self, num_train, num_val, num_inputs,
batch_size):
        self.save_hyperparameters()
        n = num_train + num_val
```

```
        self.X = tf.random.normal((n, num_inputs))
        noise = tf.random.normal((n, 1)) * 0.01
        w, b = tf.ones((num_inputs, 1)) * 0.01, 0.05
        self.y = tf.matmul(self.X, w) + b + noise

    def get_dataloader(self, train):
        i = slice(0, self.num_train) if train else
slice(self.num_train, None)
        return self.get_tensorloader([self.X, self.y],
train, i)
```

3.7.3. التنفيذ من البداية Implementation from Scratch

الآن، دعونا نحاول تطبيق تناقص الوزن من الصفر. نظرًا لأن التدرج الاشتقاقي العشوائي المصغر SGD minibatch هو المحسّن الخاص بنا ، فنحن نحتاج فقط إلى إضافة عقوبة تربيعية ℓ_2 إلى دالة الخطأ الأصلية.

3.7.3.1. تحديد عقوبة ℓ_2 المعيارية Defining ℓ_2 Norm Penalty

ربما تكون الطريقة الأكثر ملاءمة لتنفيذ هذه العقوبة هي تسوية كل الشروط الموجودة وتلخيصها.

```
def l2_penalty(w):
    return tf.reduce_sum(w**2) / 2
```

3.7.3.2. تعريف النموذج Defining the Model

في النموذج النهائي، لم يتغير الانحدار الخطي والخطأ التربيعي منذ القسم 3.4، لذلك سنقوم فقط بتعريف فئة فرعية من d2l.LinearRegressionScratch. التغيير الوحيد هنا هو أن خطأنا تشمل الآن مصطلح العقوبة.

```
class WeightDecayScratch(d2l.LinearRegressionScratch):
    def __init__(self, num_inputs, lambd, lr,
sigma=0.01):
        super().__init__(num_inputs, lr, sigma)
        self.save_hyperparameters()

    def loss(self, y_hat, y):
        return super().loss(y_hat, y) + self.lambd *
l2_penalty(self.w)
```

يناسب الكود التالي نموذجنافي مجموعة التدريب مع 20 مثالًا ويقيمه على مجموعة التحقق من الصحة مع 100 مثال.

```
data = Data(num_train=20, num_val=100, num_inputs=200,
batch_size=5)
```

```
trainer = d2l.Trainer(max_epochs=10)

def train_scratch(lambd):
    model = WeightDecayScratch(num_inputs=200,
lambd=lambd, lr=0.01)
    model.board.yscale='log'
    trainer.fit(model, data)
    print('L2 norm of w:', float(l2_penalty(model.w)))
```

3.7.3.3. التدريب بدون التنظيم Training without Regularization

نقوم الآن بتشغيل هذا الكود مع `lambd = 0`، مما يؤدي إلى تعطيل تناقص الوزن weight decay. لاحظ أننا نفرطفي التجهيز بشكل سيئ، مما يقلل من خطأ التدريب ولكن ليس خطأ التحقق من الصحة ـ وهي حالة كتابية من الضبط الزائد overfitting.

```
train_scratch(0)
```

```
L2 norm of w: 0.010603310540318489
```

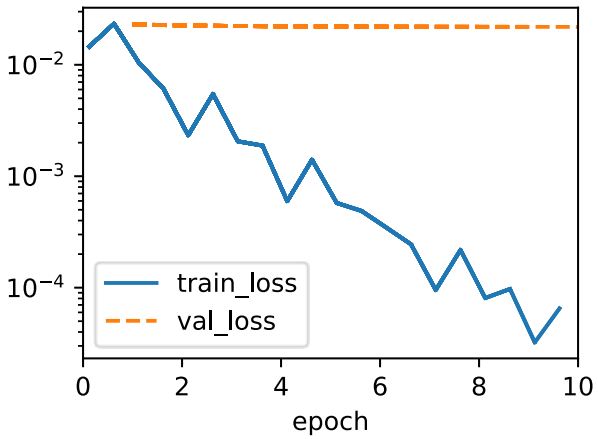

3.7.3.4. استخدام تناقص الوزن Using Weight Decay

أدناه، نجري مع تناقص كبيرفي الوزن. لاحظ أن خطأ التدريب يزداد ولكن خطأ التحقق من الصحة يتناقص. هذا هو بالضبط التأثير الذي نتوقعه من التنظيم.

```
train_scratch(3)
```

```
L2 norm of w: 0.0014634879771620035
```

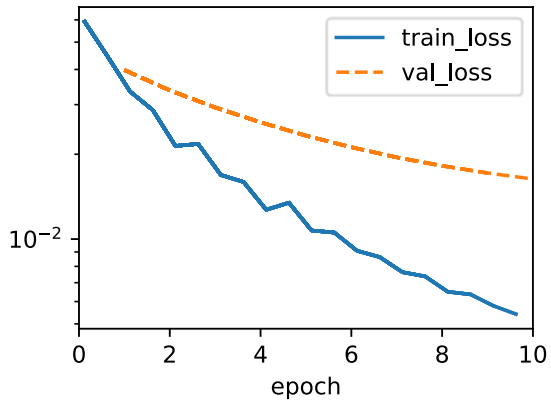

3.7.4. التنفيذ المختصر Concise Implementation

نظرًا لأن تناقص الوزن موجودفي كل مكانفي تحسين الشبكة العصبية، فإن إطار التعلم العميق يجعله مناسبًا بشكل خاص، حيث يدمج تناقص الوزنفي خوارزمية التحسين نفسها لسهولة الاستخدام مع أي دالة خطأ. علاوة على ذلك، يخدم هذا التكامل فائدة حسابية، مما يسمح لحيل التنفيذ بإضافة تناقص الوزن إلى الخوارزمية، دون أي نفقات حسابية إضافية. نظرًا لأن جزء تناقص الوزنفي التحديث يعتمد فقط على القيمة الحالية لكل معلمة، يجب أن يلمس المحسن كل معلمة مرة واحدة على أي حال.

في الكود التالي، أنشأنا منظم ℓ_2 باستخدام المعامل التشعبي لتناقص الوزن ونطبقه على أوزان الطبقة من خلال وسيطة `kernel_regularizer`.

```
class WeightDecay(d2l.LinearRegression):
    def __init__(self, wd, lr):
        super().__init__(lr)
        self.save_hyperparameters()
        self.net = tf.keras.layers.Dense(
            1,
kernel_regularizer=tf.keras.regularizers.l2(wd),

kernel_initializer=tf.keras.initializers.RandomNormal(0,
0.01)
        )

    def loss(self, y_hat, y):
        return super().loss(y_hat, y) + self.net.losses
```

تبدو الحبكة مشابهة لتلك التي حدثت عندما نفذنا عملية تناقص الوزن من نقطة الصفر. ومع ذلك، يعمل هذا الإصدار بشكل أسرع وأسهلفي التنفيذ، وستصبح الفوائد أكثر وضوحًا عندما تعالج مشاكل أكبر ويصبح هذا العمل روتينيًا بشكل أكبر.

```
model = WeightDecay(wd=3, lr=0.01)
model.board.yscale='log'
trainer.fit(model, data)
print('L2 norm of w:',
float(l2_penalty(model.get_w_b()[0])))
```

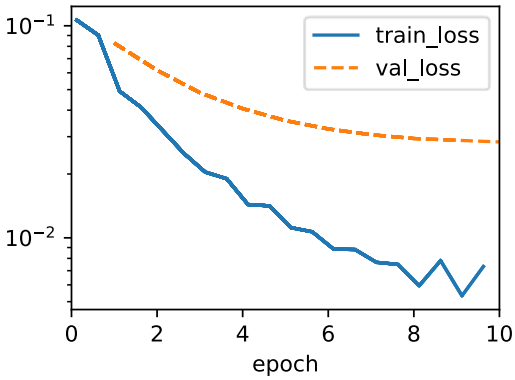

حتى الآن، تطرقنا فقط إلى فكرة واحدة عما يشكل دالة خطية بسيطة. علاوة على ذلك، ما الذي يشكل دالة غير خطية بسيطة يمكن أن يكون سؤالًا أكثر تعقيدًا. على سبيل المثال، يسمح reproducing kernel Hilbert space (RKHS) للمرء بتطبيق الأدوات المقدمة للدوال الخطيةفي سياق غير خطي. لسوء الحظ، تميل الخوارزميات المستندة إلى RKHS إلى التوسع بشكل سيئفي البيانات الكبيرة عالية الأبعاد.في هذا الكتاب، غالبًا ما نعتمد الاستدلال المشترك حيث يتم تطبيق انحلال (تناقص) الوزن على جميع طبقات الشبكة العميقة.

3.7.5. الملخص

- التنظيم Regularization هو طريقة شائعة للتعامل مع فرط التجهيز overfitting. تضيف تقنيات التنظيم الكلاسيكية مصطلحًا جزائيًا penalty term لدالة الخطأ (عند التدريب) لتقليل تعقيد النموذج الذي تم تعلمه.
- أحد الخيارات المحددة للحفاظ على النموذج بسيطًا هو استخدام عقوبة ℓ_2. هذا يؤدي إلى تناقص الوزنفي خطوات التحديث لخوارزمية التدرج الاشتقاقي العشوائي المصغر.
- يتم توفير دالة تناقص الوزنفي المُحسِّنون من أطر التعلم العميق.

- يمكن أن يكون للمجموعات المختلفة من المعلمات سلوكيات تحديث مختلفةفي نفس حلقة التدريب.

3.7.6. التمارين

1. جرب قيمة λفي مسألة التقديرفي هذا القسم. ارسم دقة التدريب ودقة التحقق من الصحة كدالة. ماذا تلاحظ؟
2. استخدم مجموعة التحقق validation set للعثور على القيمة المثلى لـ λ. هل هي حقا القيمة المثلى؟ هل هذا مهم؟
3. كيف ستبدو معادلات التحديث إذا استخدمنا $\sum_i |w_i|$ بدلاً من $\|\mathbf{w}\|^2$ كعقوبة اختيار (تنظيم ℓ_1)؟
4. نحن نعلم $\|\mathbf{w}\|^2 = \mathbf{w}^\top \mathbf{w}$. هل يمكنك العثور على معادلة مماثلة للمصفوفات (راجع معيار Frobeniusفي القسم 2.3.11)؟
5. راجع العلاقة بين خطأ التدريب training error وخطأ التعميم generalization error. بالإضافة إلى تناقص الوزن weight decay، وزيادة التدريب increased training، واستخدام نموذج التعقيد المناسب، ما هي الطرق الأخرى التي يمكنك التفكير بها للتعامل مع فرط التجهيز؟
6. في إحصائيات بايز Bayesian statistics، نستخدم ناتج سابق واحتمالية الوصول إلى لاحقة عبر $P(w \mid x) \propto P(x \mid w)P(w)$. كيف يمكنك تحديد $P(w)$ مع التنظيم regularization؟

4

الشبكات العصبية الخطية للتصنيف

4. الشبكات العصبية الخطية للتصنيف Linear Neural Networks for Classification

الآن بعد أن عملت من خلال جميع الآليات، فأنت جاهز لتطبيق هذه المهارات على أنواع أوسع من المهام. حتى عندما نتجه نحو التصنيف Classification، تظل معظم أعمال السباكة كما هي: تحميل البيانات، وتمريرها عبر النموذج، وتوليد المخرجات، وحساب الخطأ، وأخذ التدرجات فيما يتعلق بالأوزان، وتحديث النموذج. ومع ذلك، فإن الشكل الدقيق للأهداف، ومعلمات طبقة المخرجات، واختيار دالة الخطأ سوف تتكيف لتلائم إعداد التصنيف.

4.1 انحدار Softmax

في القسم 3.1، قدمنا الانحدار الخطي، والعمل من خلال عمليات التنفيذ من البدايةفي القسم 3.4 ومرة أخرى باستخدام واجهات برمجة التطبيقات API عالية المستوى لإطار عمل التعلم العميقفي القسم 3.5 للقيام بالرفع الثقيل.

الانحدار Regression هو المطرقة التي نصل إليها عندما نريد أن نجيب إلى أي مدى؟ أو كم عددها؟ أسئلة. إذا كنت ترغبفي التنبؤ بعدد الدولارات (السعر) التي سيتم بيع منزل بها، أو عدد مرات الفوز التي قد يحققها فريق البيسبول، أو عدد الأيام التي سيبقى فيها المريضفي المستشفى قبل الخروج من المستشفى، فمن المحتمل أنك تبحث عن نموذج الانحدار. ومع ذلك، حتىفي نماذج الانحدار، هناك فروق مهمة. على سبيل المثال، لن يكون سعر المنزل سالبًا أبدًا وقد تكون التغييراتفي الغالب مرتبطة بسعره الأساسي. على هذا النحو، قد يكون التراجع عن لوغاريتم السعر أكثر فاعلية. وبالمثل، فإن عدد الأيام التي يقضيها المريضفي المستشفى هو متغير عشوائي منفصل غير سلبي. على هذا النحو، قد لا تكون المربعات الأقل دلالة نهجًا مثاليًا أيضًا. يأتي هذا النوع من النمذجة من وقت إلى حدث time-to-event modeling مع مجموعة من المضاعفات الأخرى التي يتم التعامل معهافي حقل فرعي متخصص يسمى نمذجة البقاء survival modeling.

وجهة النظر هنا ليست إرباكك ولكن فقط لإعلامك بأن هناك الكثير من التقدير أكثر من مجرد تقليل الأخطاء التربيعية. وعلى نطاق أوسع، هناك الكثير للتعلم الخاضع للإشراف أكثر من الانحدار.في هذا القسم نركز على مشاكل التصنيف classification problems حيث نضع جانباكم؟ الأسئلة وبدلاً من ذلك التركيز على أي فئة؟ أسئلة.

- هل ينتمي هذا البريد الإلكتروني إلى مجلد البريد العشوائي أو صندوق البريد الوارد؟
- هل من المرجح أن يقوم هذا العميل بالتسجيل أو عدم الاشتراكفي خدمة الاشتراك؟
- هل تصور هذه الصورة حمارًا أو كلبًا أو قطة أو ديكًا؟

- ما هو الفيلم الذي من المرجح أن يشاهده أستون بعد ذلك؟
- أي قسم من الكتاب سوف تقرأه بعد ذلك؟

بالعامية، يثقل ممارسو التعلم الآلي كلمة التصنيف classification لوصف مشكلتين مختلفتين تمامًا: (1) تلك التي نهتم فيها فقط بالتخصيصات الصعبة للأمثلة للفئات categories (الفئات classes)؛ و(2) تلك التي نرغبفي إجراء تخصيصات بسيطة، أي لتقييم احتمالية تطبيق كل فئة. يميل التمييز إلى التعتيم جزئيًا، لأنهفي كثير من الأحيان، حتى عندما نهتم فقط بالمهام الصعبة، ما زلنا نستخدم النماذج التي تقوم بمهام بسيطة.

أكثر من ذلك، هناك حالات يكون فيها أكثر من تسمية label واحدة صحيحة. على سبيل المثال، قد تغطي مقالة إخباريةفي نفس الوقت موضوعات الترفيه والأعمال ورحلات الفضاء، ولكن لا تغطي موضوعات الطب أو الرياضة. وبالتالي، فإن تصنيفها إلى إحدى الفئات المذكورة أعلاه بمفردها لن يكون مفيدًا للغاية. تُعرف هذه المشكلة عمومًا باسم التصنيف متعدد التسميات multi-label classification. انظر Tsoumakas and Katakis (2007) للحصول على نظرة عامة و Huang et al. (2015) لخوارزمية فعالة عند وضع علامات tagging على الصور.

4.1.1. التصنيف Classification

لتبليل أقدامنا، لنبدأ بمشكلة بسيطةفي تصنيف الصور image classification. هنا، يتكون كل إدخال من 2×2 صورة ذات تدرج رمادي. يمكننا تمثيل كل قيمة بكسل باستخدام عدد قياسي واحد، مما يعطينا أربع ميزات x_1, x_2, x_3, x_4. علاوة على ذلك، لنفترض أن كل صورة تنتمي إلى واحدة من بين الفئات "قطة" و "دجاج" و "كلب".

بعد ذلك، علينا أن نختار كيفية تمثيل التسميات labels. لدينا خياران واضحان. ربما يكون الدافع الأكثر طبيعية هو اختيار $y \in \{1,2,3\}$ ، حيث تمثل الأعداد الصحيحة {dog,cat,chicken} على التوالي. هذه طريقة رائعة لتخزين مثل هذه المعلومات على جهاز الكمبيوتر. إذا كان للفئات بعض الترتيب الطبيعي فيما بينها، على سبيل المثال إذا كنا نحاول التنبؤ بـ {baby,toddler,adolescent,young adult,adult,geriatric}، فقد يكون من المنطقي اعتبار ذلك مشكلة انحدار ترتيبية والاحتفاظ بالتسميات بهذا التنسيق. انظر Moon et al. (2010) للحصول على نظرة عامة على أنواع مختلفة من دوال فقدان الترتيب و Beutel et al. (2014) لنهج بايزي Bayesian approach الذي يعالج الاستجابات بأكثر من وضع.

بشكل عام، لا تأتي مشاكل التصنيف مع الترتيب الطبيعي بين الفئات classes. لحسن الحظ، ابتكر الإحصائيون منذ فترة طويلة طريقة بسيطة لتمثيل البيانات الفئوية categorical data: التشفير الواحد الساخن one-hot encoding. الترميز الواحد الساخن هو متجه يحتوي على

العديد من المكونات مثل الفئات الموجودة لدينا. يتم تعيين المكون المقابل لفئة مثيل معين على 1 ويتم تعيين جميع المكونات الأخرى على 0.في حالتنا، سيكون التسمية y متجهًا ثلاثي الأبعاد، مع (1,0,0) المقابل لـ "قطة" و(0,1,0) "دجاجة" و(0,0,1) "كلب":

$$y \in \{(1,0,0), (0,1,0), (0,0,1)\}.$$

4.1.1.1. النموذج الخطي Linear Model

لتقدير الاحتمالات الشرطية المرتبطة بجميع الفئات الممكنة، نحتاج إلى نموذج بمخرجات متعددة، واحدة لكل فئة. لمعالجة التصنيف بالنماذج الخطية، سنحتاج إلى العديد من الدوال الأفينية affine functions مثل عدد المخرجات. بالمعنى الدقيق للكلمة، نحتاج فقط إلى واحد أقل، لأن الفئة الأخيرة يجب أن تكون الفرق بين 1 ومجموع الفئات الأخرى ولكن لأسباب التناظر symmetry نستخدم معلمات زائدة عن الحاجة. كل ناتج يتوافق مع الدالة الأفينية الخاصة به.في حالتنا، نظرًا لأن لدينا 4 ميزات و3 فئات إخراج محتملة، نحتاج إلى 12 قيمة قياسية Scalar لتمثيل الأوزان (w مع الرموز المنخفضة subscripts)، و3 مقاييس لتمثيل التحيزات (b مع الرموز المنخفضة subscripts). هذه العوائد:

$$\begin{aligned} o_1 &= x_1 w_{11} + x_2 w_{12} + x_3 w_{13} + x_4 w_{14} + b_1, \\ o_2 &= x_1 w_{21} + x_2 w_{22} + x_3 w_{23} + x_4 w_{24} + b_2, \\ o_3 &= x_1 w_{31} + x_2 w_{32} + x_3 w_{33} + x_4 w_{34} + b_3. \end{aligned}$$

يظهر مخطط الشبكة العصبية المقابلفي الشكل 4.1.1. كما هو الحالفي الانحدار الخطي، نستخدم شبكة عصبية أحادية الطبقة single-layer neural network. ونظرًا لأن حساب كل ناتج o_1, o_2، ويعتمد على جميع المدخلات،x_1 وx_2 ،x_3 وx_4 ، يمكن أيضًا وصف طبقة المخرجات بأنها طبقة متصلة بالكامل fully connected layer.

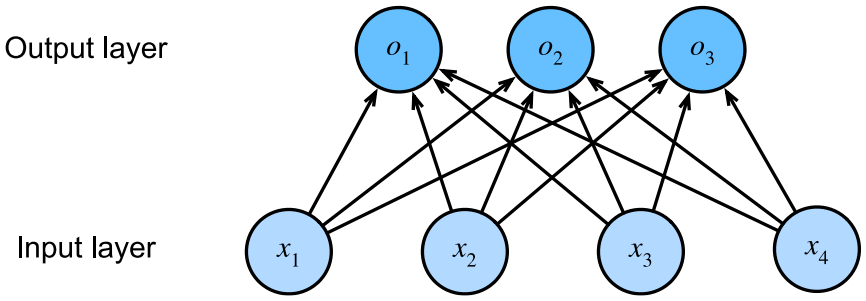

الشكل 4.1.1 انحدار Softmax عبارة عن شبكة عصبية أحادية الطبقة.

للحصول على تدوين أكثر إيجازًا، نستخدم المتجهات والمصفوفات:$\mathbf{o} = \mathbf{W}\mathbf{x} + \mathbf{b}$ وهي أكثر ملاءمة للرياضيات والرموز. لاحظ أننا جمعنا كل أوزاننافي مصفوفة 4×3 وجميع التحيزاتفي متجه $\mathbf{b} \in \mathbb{R}^3$.

4.1.1.2. سوفت ماكس Softmax

بافتراض دالة خطأ مناسبة، يمكننا أن نحاول، مباشرة، تقليل الاختلاف بين $\mathbf{o}$ والتسميات $\mathbf{y}$. بينما اتضح أن معالجة التصنيف على أنه مشكلة انحدار ذات قيمة متجهية vector-valued regression تعمل بشكل جيد بشكل مدهش، إلا أنها مع ذلك تفتقر إلى الطرق التالية:

- ليس هناك ما يضمن أن مجموع المخرجات o_iيصل إلى 1 بالطريقة التي نتوقع أن تتصرف بها الاحتمالات.
- ليس هناك ما يضمن أن النواتج o_i هي حتى غير سالبة، حتى لو كانت مخرجاتها تصل إلى 1، أو أنها لا تتجاوز 1.

كلا الجانبين يجعل مشكلة التقدير صعبة الحل والحل هش للغاية للقيم المتطرفة outliers. على سبيل المثال، إذا افترضنا أن هناك تبعية خطية linear dependency موجبة بين عدد غرف النوم واحتمال قيام شخص ما بشراء منزل، فقد يتجاوز الاحتمال 1 عندما يتعلق الأمر بشراء قصر! على هذا النحو، نحن بحاجة إلى آلية "لسحق squish" المخرجات.

هناك العديد من الطرق التي يمكننا من خلالها تحقيق هذا الهدف. على سبيل المثال، يمكننا أن نفترض أن المخرجات $\mathbf{o}$ هي إصدارات تالفة من $\mathbf{y}$ ، حيث يحدث التلف عن طريق إضافة ضوضاء مستمدة من التوزيع الطبيعي. بمعنى آخر، $\mathbf{y} = \mathbf{o} + \epsilon$ حيث $\epsilon_i \sim \mathcal{N}(0, \sigma^2)$. هذا هو ما يسمى بنموذج الاختبار probit model، الذي قدمه Fechner لأول مرة (1860).في حين أنها جذابة، فإنها لا تعمل بشكل جيد أو تؤدي إلى مشكلة تحسين لطيفة بشكل خاص، عند مقارنتها بـ softmax.

هناك طريقة أخرى لتحقيق هذا الهدف (ولضمان اللاسلبية nonnegativity) وهي استخدام دالة أسية $P(y = i) \propto \exp\ o_i$. هذا بالفعل يفي بمتطلبات زيادة احتمال الطبقة الشرطية مع زيادة o_i، وهو رتيب monotonic، وجميع الاحتمالات غير سالبة. يمكننا بعد ذلك تحويل هذه القيم بحيث يتم جمعها الى 1 بقسمة كل منها على مجموعها. هذه العملية تسمى التسوية normalization. يمنحنا وضع هاتين القطعتين معًا دالة softmax:

$$\hat{\mathbf{y}} = \text{softmax}(\mathbf{o}) \text{where} \hat{y}_i = \frac{\exp\ (o_i)}{\sum_j \exp\ (o_j)}.$$

لاحظ أن أكبر إحداثي لـ $\mathbf{o}$ يتوافق مع الفئة الأكثر احتمالًا وفقًا لـ $\hat{\mathbf{y}}$. علاوة على ذلك، نظرًا لأن عملية softmax تحافظ على الترتيب بين وسيطاتها، فإننا لا نحتاج إلى حساب softmax لتحديد الفئة التي تم تخصيص أعلى احتمالية لها.

$$\operatorname*{argmax}_j \hat{y}_j = \operatorname*{argmax}_j o_j.$$

تعود فكرة softmax إلى جيبس Gibbs، الذي قام بتكييف الأفكار من الفيزياء (Gibbs، 1902). منذ زمن بعيد، استخدم بولتزمان، والد الديناميكا الحرارية الحديثة، هذه الحيلة لنمذجة التوزيع على حالات الطاقةفي جزيئات الغاز. على وجه الخصوص، اكتشف أن انتشار حالة من الطاقةفي مجموعة ديناميكية حرارية، مثل الجزيئاتفي الغاز، يتناسب مع $\exp(-E/kT)$. هنا، Eطاقة الحالة، T هي درجة الحرارة، وk ثابت بولتزمان. عندما يتحدث الإحصائيون عن زيادة أو خفض "درجة حرارة" نظام إحصائي، فإنهم يشيرون إلى التغيير لصالح حالات الطاقة المنخفضة أو الأعلى. باتباع فكرة جيبس، الطاقة تساوي الخطأ. تستخدم النماذج القائمة على الطاقة (Ranzato et al.، 2007) وجهة النظر هذه عند وصف المشكلاتفي التعلم العميق.

4.1.1.3. الفيكتوريزاشن Vectorization

لتحسين الكفاءة الحسابية، نقوم بتوجيه الحساباتفي الدفعات الصغيرة من البيانات. افترض أننا حصلنا على دفعات صغيرة $\mathbf{X} \in \mathbb{R}^{n \times d}$ من n من الميزات ذات الأبعاد (عدد المدخلات) d. علاوة على ذلك، افترض أن لدينا q فئاتفي المخرجات. ثم الأوزان تحقق $\mathbf{W} \in \mathbb{R}^{d \times q}$ والتحيز يحقق $\mathbf{b} \in \mathbb{R}^{1 \times q}$.

$$\begin{aligned} \mathbf{O} &= \mathbf{X}\mathbf{W} + \mathbf{b}, \\ \hat{\mathbf{Y}} &= \operatorname{softmax}(\mathbf{O}). \end{aligned}$$

يؤدي هذا إلى تسريع العملية السائدةفي ضرب المصفوفةـالمصفوفة $\mathbf{XW}$. علاوة على ذلك، نظرًا لأن كل صفـفي $\mathbf{X}$ يمثل مثالًا للبيانات، يمكن حساب عملية softmax نفسهافي اتجاه الصف rowwise: لكل صف من $\mathbf{O}$ ، ثم قم بتسويتها بالمجموع. لاحظ، مع ذلك، أنه يجب توخي الحذر لتجنب الأس وأخذ اللوغاريتمات ذات الأعداد الكبيرة، لأن هذا يمكن أن يسبب تجاوزًا رقميًا أو تدنيًا. تعتني أطر التعلم العميق بهذا الأمر تلقائيًا.

4.1.2. دالة الخطأ Loss Function

الآن بعد أن أصبح لدينا تعيين من الميزات $\mathbf{x}$ إلى الاحتمالات $\hat{\mathbf{y}}$، نحن بحاجة إلى طريقة لتحسين دقة هذا التعيين. سوف نعتمد على تقدير الاحتمال الأقصى maximum likelihood

estimation، وهو نفس المفهوم الذي واجهناه عند تقديم تبرير احتمالي لمتوسط خسارة الخطأ التربيعي في القسم 3.1.3.

Log-Likelihood .4.1.2.1

تعطينا دالة softmax متجهًا $\hat{\mathbf{y}}$، والتي يمكننا تفسيرها على أنها احتمالات مشروطة (مقدرة) لكل فئة، مع الأخذ في الاعتبار أي مدخلات $\mathbf{x}$ ، مثل $\hat{y}_1 = P(y = \text{cat} \mid \mathbf{x})$. فيما يلي نفترض أنه بالنسبة لمجموعة البيانات ذات الميزات $\mathbf{X}$، يتم تمثيل التسميات $\mathbf{Y}$ باستخدام متجه تسمية ترميز واحد ساخن one-hot encoding. يمكننا مقارنة التقديرات بالواقع من خلال التحقق من مدى احتمالية أن تكون الفئات الفعلية وفقًا لنموذجنا، مع مراعاة الميزات:

$$P(\mathbf{Y} \mid \mathbf{X}) = \prod_{i=1}^{n} P(\mathbf{y}^{(i)} \mid \mathbf{x}^{(i)}).$$

يُسمح لنا باستخدام التحليل إلى عوامل factorization لأننا نفترض أن كل تسمية مرسومة بشكل مستقل عن التوزيع $P(\mathbf{y} \mid \mathbf{x}^{(i)})$ الخاص به. نظرًا لأن تعظيم منتج المصطلحات أمر غير ملائم، فإننا نأخذ اللوغاريتم السالب للحصول على المشكلة المكافئة لتقليل log-likelihood:

$$-\log P(\mathbf{Y} \mid \mathbf{X}) = \sum_{i=1}^{n} -\log P(\mathbf{y}^{(i)} \mid \mathbf{x}^{(i)}) = \sum_{i=1}^{n} l(\mathbf{y}^{(i)}, \hat{\mathbf{y}}^{(i)}),$$

أين لأي زوج من التسمية $\mathbf{y}$ والتنبؤ $\hat{\mathbf{y}}$ بالنموذج على الفئات q، فإن دالة الخطأ l هي

$$l(\mathbf{y}, \hat{\mathbf{y}}) = -\sum_{j=1}^{q} y_j \log \hat{y}_j.$$

لأسباب تم توضيحها لاحقًا، فإن دالة الخطأفي (4.1.8) تسمى عادةً خطأ الانتروبيا المتقاطعة cross-entropy loss. نظرًا لأن $\mathbf{y}$ متجه واحد ساخن للطول q، فإن المجموع على جميع الإحداثيات j يختفي لجميع المصطلحات باستثناء مصطلح واحد. لاحظ أن الخطأ $l(\mathbf{y}, \hat{\mathbf{y}})$ يحدها من الأسفل بواسطة 0 حيث $\hat{y}$ هو متجه احتمالي: لا يوجد إدخال واحد أكبر من 1، وبالتالي لا يمكن أن يكون اللوغاريتم السالب أقل من 0؛ فقط إذا $l(\mathbf{y}, \hat{\mathbf{y}}) = 0$ توقعنا التسمية الفعلي على وجه اليقين certainty. لا يمكن أن يحدث هذا أبدًا لأي إعداد محدود للأوزان لأن أخذ إخراج softmax نحو 1 يتطلب أخذ المدخلات المقابلة o_i إلى ما لا نهاية (أو جميع المخرجات o_j الأخرى لكل $j \neq i$ إلى اللانهاية السالبة). حتى إذا كان بإمكان نموذجنا تعيين

احتمال إخراج 0، فإن أي خطأ يرتكب عند تعيين مثل هذه الثقة العالية سيؤدي إلى خطأ لا نهائي $(-\log 0 = \infty)$.

4.1.2.2. Softmax وخطأ الانتروبيا Softmax and Cross-Entropy Loss

نظرًا لأن دالة softmax وخطأ الانتروبيا المقابلة شائعة جدًا، فمن الجدير فهم كيفية حسابها بشكل أفضل قليلاً. إدخال (4.1.3)في تعريف الخطأفي (4.1.8) وباستخدام تعريف softmax نحصل عليه:

$$\begin{aligned} l(\mathbf{y}, \hat{\mathbf{y}}) &= -\sum_{j=1}^{q} y_j \log \frac{\exp(o_j)}{\sum_{k=1}^{q} \exp(o_k)} \\ &= \sum_{j=1}^{q} y_j \log \sum_{k=1}^{q} \exp(o_k) - \sum_{j=1}^{q} y_j o_j \\ &= \log \sum_{k=1}^{q} \exp(o_k) - \sum_{j=1}^{q} y_j o_j. \end{aligned}$$

لفهم ما يجري بشكل أفضل قليلاً، ضعفي الاعتبار المشتق فيما يتعلق بأي لوغاريتم o_j. نحن نحصل

$$\partial_{o_j} l(\mathbf{y}, \hat{\mathbf{y}}) = \frac{\exp(o_j)}{\sum_{k=1}^{q} \exp(o_k)} - y_j = \text{softmax}(\mathbf{o})_j - y_j.$$

بمعنى آخر، المشتق derivative هو الفرق بين الاحتمال المحدد بواسطة نموذجنا، كما يعبر عنه عملية SoftMax، وما حدث بالفعل، على النحو المعبر عنه بالعناصر الموجودةفي متجه التسمية الساخنة الواحدة. بهذا المعنى، فهو مشابه جدًا لما رأيناهفي الانحدار، حيث كان التدرج هو الفرق بين الملاحظة y والتقدير $\hat{y}$. هذه ليست صدفة.في أي نموذج عائلي أسي، يتم إعطاء تدرجات احتمالية السجل من خلال هذا المصطلح على وجه التحديد. هذه الحقيقة تجعل حوسبة التدرجات سهلةفي الممارسة.

الآن ضعفي اعتبارك الحالة التي نلاحظ فيها ليس فقط نتيجة واحدة ولكن توزيعًا كاملاً على النتائج. يمكننا استخدام نفس التمثيل السابق للتسمية $\mathbf{y}$. الاختلاف الوحيد هو أنه بدلاً من المتجه الذي يحتوي على مدخلات ثنائية فقط، على سبيل المثال (0,0,1)، لدينا الآن متجه احتمالي عام، على سبيل المثال (0.1,0.2,0.7). الرياضيات التي استخدمناها سابقًا لتحديد الخطأفي (4.1.8) لا تزال تعمل بشكل جيد، فقط أن التفسير أكثر عمومية. إنها القيمة المتوقعة للخطأ توزيع على التسميات. يسمى هذه الخطأ بخطأ الانتروبيا المتقاطعة cross-entropy loss وهو

واحد من أكثر الاخطاء استخدامًا لمشاكل التصنيف. يمكننا إزالة الغموض عن الاسم من خلال تقديم أساسيات نظرية المعلومات فقط. باختصار، إنه يقيس عدد البتات لترميز ما نراه $\mathbf{y}$ بالنسبة لما نتوقع حدوثه $\hat{\mathbf{y}}$. نقدم شرحًا أساسيًا جدًا فيما يلي. لمزيد من التفاصيل حول نظرية المعلومات انظر (Cover and Thomas، 1999) أو (MacKay and Mac Kay، 2003).

4.1.3. أساسيات نظرية المعلومات Information Theory Basics

تستخدم العديد من أوراق التعلم العميق الحدس والمصطلحات من نظرية المعلومات information theory. لفهمها، نحتاج إلى لغة مشتركة. هذا هو دليل البقاء على قيد الحياة. تتعامل نظرية المعلومات مع مشكلة ترميز المعلومات وفك تشفيرها ونقلها ومعالجتها (المعروفة أيضًا باسم البيانات data).

4.1.3.1. الإنتروبيا Entropy

الفكرة المركزيةفي نظرية المعلومات هي تحديد كمية المعلومات الواردةفي البيانات. هذا يضع حدًا لقدرتنا على ضغط البيانات. بالنسبة للتوزيع P، يتم تعريف الانتروبيا على النحو التالي:

$$H[P] = \sum_j - P(j)\log\ P(j).$$

تنص إحدى النظريات الأساسية لنظرية المعلومات على أنه من أجل ترميز البيانات المستمدة عشوائيًا من التوزيع P، نحتاج على الأقل $H[P]$ إلى "nats" لتشفيرها (Shannon، 1948). إذا كنت تتساءل ما هو "nat"، فهو مكافئ للبت ولكن عند استخدام رمز مع الأساس e بدلاً من واحد مع الأساس 2. وبالتالي، فإن nat واحد هو $\frac{1}{\log(2)} \approx 1.44$ بت

4.1.3.2. Surprisal

قد تتساءل ما علاقة الضغط بالتنبؤ. تخيل أن لدينا دفقًا من البيانات التي نريد ضغطها. إذا كان من السهل علينا دائمًا توقع الرمز المميز التالي، فمن السهل ضغط هذه البيانات. خذ المثال حيث يأخذ كل رمز مميزفي الدفق نفس القيمة دائمًا. هذا دفق بيانات ممل للغاية! وهو ليس مملًا فحسب، بل يسهل توقعه أيضًا. نظرًا لأنهما دائمًا متماثلان، فلا يتعين علينا نقل أي معلومات لتوصيل محتويات الدفق. سهل التنبؤ، سهل الضغط.

ومع ذلك، إذا لم نتمكن من التنبؤ بكل حدث تمامًا، فقد نتفاجأ أحيانًا. تكون دهشتنا أكبر عندما خصصنا حدثًا احتمالية أقل. استقر كلود شانون على $\log \frac{1}{P(j)} = -\log\ P(j)$ لتقدير مفاجأة المرءفي مراقبة حدث ما j بعد أن منحه احتمالًا $P(j)$. إن الانتروبيا المحددةفي (4.1.11) هي

إذن المفاجأة المتوقعة عندما يقوم أحدهم بتعيين الاحتمالات الصحيحة التي تتطابق بالفعل مع عملية توليد البيانات.

4.1.3.3. إعادة النظر عبر الانتروبيا Cross-Entropy Revisited

لذا، إذا كان الانتروبيا هو مستوى المفاجأة الذي يختبره شخص يعرف الاحتمال الحقيقي ، فقد تتساءل ، ما هو الانتروبيا المتقاطعة cross-entropy؟ إن الانتروبيا المتقاطعة من P إلى Q، المشار إليها $H(P,Q)$، هي المفاجأة المتوقعة لمراقب ذي احتمالات ذاتية عند رؤية البيانات التي تم إنشاؤها بالفعل وفقًا للاحتمالات P. هذا معطى من قبل $H(P,Q) \stackrel{\text{def}}{=} \sum_j - P(j)\log Q(j)$. يتم تحقيق أدنى قدر ممكن من الانتروبيا عندما $P = Q$.في هذه الحالة، فإن الانتروبيا المتقاطعة P إلى Qهي $H(P,P) = H(P)$.

باختصار، يمكننا التفكيرفي هدف التصنيف عبر الانتروبيا بطريقتين: (1) تعظيم احتمالية البيانات المرصودة؛ و (2) لتقليل مفاجأتنا (وبالتالي عدد البتات) المطلوبة لتوصيل التسميات labels.

4.1.4. الملخص والمناقشة

في هذا القسم، واجهنا أول دالة خطأ غير بديهية، مما يسمح لنا بتحسين مساحات الإخراج المنفصلة. كان المفتاحفي تصميمه هو أننا اتخذنا نهجًا احتماليًا، حيث تعاملنا مع الفئات المنفصلة على أنها حالات سحب من توزيع احتمالي. كأثر جانبي، واجهنا softmax، وهي دالة تنشيط مريحة تحول مخرجات طبقة الشبكة العصبية العادية إلى توزيعات احتمالية منفصلة صالحة. لقد رأينا أن مشتق خطأ الانتروبيا المتقاطعة عندما يقترن بـ softmax يتصرف بشكل مشابه جدًا لمشتق الخطأ التربيعي، أي عن طريق أخذ الفرق بين السلوك المتوقع والتنبؤ به. وبينما كنا قادرين فقط على خدش السطح ذاته، واجهنا روابط مثيرة للفيزياء الإحصائية ونظرية المعلومات.

في حين أن هذا كاف ليأخذكفي طريقك، ونأمل أن يكون كافيًا لإثارة شهيتك، إلا أننا بالكاد نغوص بعمق هنا. من بين أمور أخرى، تخطينا الاعتبارات الحسابية. على وجه التحديد، بالنسبة لأي طبقة متصلة بالكامل بها d مدخلات وq مخرجات، المعلمات والتكلفة الحسابية هي $\mathcal{O}(dq)$، والتي يمكن أن تكون باهظةفي الممارسة العملية. لحسن الحظ، يمكن تقليل تكلفة تحويل المدخلات d إلى مخرجات q من خلال التقريب approximation والضغط compression. على سبيل المثال، يستخدم Deep Fried Convnets،(Yang et al.، 2015) مجموعة من التباديل وتحويلات فورييه والقياس لتقليل التكلفة من التربيعية إلى اللوغاريتمية الخطية. تعمل تقنيات مماثلة من أجل تقريب مصفوفة هيكلية أكثر تقدمًا (Sindhwani et al.، 2015). أخيرًا، يمكننا استخدام تحليلات تشبه Quaternion لتقليل التكلفة الى $\mathcal{O}(\frac{dq}{n})$، مرة أخرى،

إذا كنا على استعداد لمقايضة قدر ضئيل من الدقة بتكلفة الحساب والتخزين (Zhang et al.، 2021) بناءً على عامل الضغط n. هذا مجال نشط للبحث. ما يجعل الأمر صعبًا هو أننا لا نسعى بالضرورة إلى التمثيل الأكثر إحكاما أو أصغر عدد من عمليات الفاصلة العائمة floating point ولكن بالأحرى للحل الذي يمكن تنفيذه بكفاءة أكبر على وحدات معالجة الرسومات الحديثة GPUs.

4.1.5. التمارين

1. يمكننا استكشاف العلاقة بين العائلات الأسية وsoftmax بعمق أكبر.
   1. احسب المشتق الثاني لخطأ الانتروبيا $l(\mathbf{y}, \hat{\mathbf{y}})$ من أجل softmax.
   2. احسب تباين التوزيع الذي قدمه $\mathrm{softmax}(\mathbf{o})$ وأظهر أنه يطابق المشتق الثاني المحسوب أعلاه.
2. افترض أن لدينا ثلاث فئات تحدث باحتمالية متساوية، أي متجه الاحتمال هو $(\frac{1}{3}, \frac{1}{3}, \frac{1}{3})$
   1. ما هي المشكلة إذا حاولنا تصميم كود ثنائي لها؟
   2. هل يمكنك تصميم كود أفضل؟ تلميح: ماذا يحدث إذا حاولنا ترميز ملاحظتين مستقلتين؟ ماذا لو قمنا بترميز n ملاحظات بشكل مشترك؟
3. عند إرسال إشارات ترميز عبر سلك مادي، لا يستخدم المهندسون دائمًا رموزًا ثنائية. على سبيل المثال، يستخدم PAM-3 ثلاثة مستويات للإشارة $\{-1,0,1\}$ بدلاً من مستويين $\{0,1\}$. كم عدد الوحدات الثلاثية ternary units التي تحتاجها لإرسال عدد صحيح في النطاق $\{0, \ldots, 7\}$؟ لماذا قد تكون هذه فكرة أفضل من حيث الإلكترونيات؟
4. يستخدم نموذج برادلي تيري Bradley-Terry model نموذجًا لوجستيًا logistic model لالتقاط التفضيلات. لكي يختار المستخدم بين التفاح والبرتقال، يفترض المرء أن الدرجات o_{apple} وo_{orange}. متطلباتنا هي أن الدرجات الأكبر يجب أن تؤدي إلى احتمالية أعلى في اختيار العنصر المرتبط وأن العنصر الحاصل على أكبر درجة هو العنصر الأكثر احتمالية لاختياره (Bradley and Terry، 1952).
   1. إثبت أن softmax يلبي هذا المطلب.
   2. ماذا يحدث إذا كنت تريد السماح بخيار افتراضي لا يختار فيه التفاح ولا البرتقال؟ تلميح: الآن لدى المستخدم 3 اختيارات.
5. تشتق Softmax اسمها من التعيين التالي: $\mathrm{RealSoftMax}(a, b) = \log(\exp(a) + \exp(b))$.
   1. اثبت $\mathrm{RealSoftMax}(a, b) > \max(a, b)$.

2. ما مدى صغر حجم الفرق بين الدالتين؟ تلميح: بدون فقدان التعميم يمكنك ضبط $b = 0$و $a \geq b$.
3. إثبت أن $\lambda^{-1}\text{RealSoftMax}(\lambda a, \lambda b)$، بشرط $\lambda > 0$.
4. أظهر ذلك لـ $\lambda \to \infty$ لدينا $\lambda^{-1}\text{RealSoftMax}(\lambda a, \lambda b) \to \max(a, b)$.
5. كيف تبدو soft-min؟
6. قم بتوسيع هذا إلى أكثر من رقمين.

6. الدالة $\exp x_i \quad g(\mathbf{x}) \stackrel{\text{def}}{=} \log \sum_i$ يشار إليها أحيانًا أيضًا باسم log-partition function.

1. إثبت أن الدالة محدبة convex. تلميح: للقيام بذلك، استخدم حقيقة أن المشتق الأول يرقى إلى الاحتمالات من دالة softmax وأظهر أن المشتق الثاني هو التباين variance.
2. أظهر أن g هي الترجمة ثابتة invariant، أي $g(\mathbf{x} + b) = g(\mathbf{x})$.
3. ماذا يحدث إذا كانت بعض الإحداثيات كبيرة جدًا؟ ماذا يحدث إذا كانوا جميعًا صغارًا جدًا؟
4. أظهر أنه إذا اخترنا $b = \max_i x_i$ سننتهي بتطبيق مستقر عدديًا.

7. افترض أن لدينا بعض التوزيع الاحتمالي P. لنفترض أننا اخترنا توزيعًا آخر Q باستخدام $Q(i) \propto P(i)^\alpha$.

1. أي اختيار لـ α يتوافق مع مضاعفة درجة الحرارة؟ أي خيار يتوافق مع النصف؟
2. ماذا يحدث إذا تركنا درجة الحرارة تتقارب converge الى 0؟
3. ماذا يحدث إذا تركنا درجة الحرارة تتقارب الى ∞؟

4.2 مجموعة بيانات تصنيف الصور The Image Classification Dataset

إحدى مجموعات البيانات Dataset المستخدمة على نطاق واسع لتصنيف الصور هي مجموعة بيانات MNIST، (LeCun et al، 1998) للأرقام المكتوبة بخط اليد.في وقت إصداره في التسعينيات، شكل تحديًا هائلاً لمعظم خوارزميات التعلم الآلي، ويتألف من 60.000 صورة بدقة بكسل (بالإضافة إلى مجموعة بيانات اختبار من 10000 صورة). لوضع الأمور في نصابها الصحيح،في ذلك الوقت، تم اعتبار Sun SPARCStation 5 بسعة 64 ميجابايت من ذاكرة الوصول العشوائي الهائلة و5 MFLOPs من أحدث المعدات للتعلم الآلي في مختبرات AT&T Bell في عام 1995 . كان تحقيق دقة عالية في التعرف على الأرقام بمثابة المكون الرئيسي في أتمتة فرز الرسائل لـ USPS في التسعينيات. الشبكات العميقة مثل LeNet-5،(LeCun et al، 1995) والات المتجهات الداعمة support vector machines مع الثوابت invariances

(Schölkopf et al.، 1996) ، ومصنفات المسافة المماسية tangent distance classifiers (Simard et al.، 1998) كلها سمحت بالوصول إلى معدلات خطأ أقل من 1%.

لأكثر من عقد من الزمان، عملت MNIST كنقطة مرجعية لمقارنة خوارزميات التعلم الآلي. على الرغم من أنه كان يعمل بشكل جيد كمجموعة بيانات معيارية، إلا أن النماذج البسيطة وفقًا لمعايير اليوم تحقق دقة تصنيف تزيد عن 95٪، مما يجعلها غير مناسبة للتمييز بين النماذج الأقوى والنماذج الأضعف. أكثر من ذلك، تسمح مجموعة البيانات بمستويات عالية جدًا من الدقة، لا تُرى عادةً في العديد من مشكلات التصنيف. هذا التطوير الخوارزمي المنحرف نحو عائلات معينة من الخوارزميات التي يمكن أن تستفيد من مجموعات البيانات النظيفة clean datasets، مثل أساليب المجموعة النشطة وخوارزميات المجموعة النشطة التي تسعى للحد من الحدود. اليوم، تعمل MNIST بمثابة فحوصات سلامة أكثر من كونها معيارًا. تشكّل شبكة ImageNet، (Denget al.، 2009) تحديًا أكثر صلة بالموضوع. لسوء الحظ، تعد ImageNet كبيرة جدًا بالنسبة للعديد من الأمثلة والرسوم التوضيحيةفي هذا الكتاب، حيث سيستغرق التدريب وقتًا طويلاً لجعل الأمثلة تفاعلية. كبديل، سنركز مناقشتنافي الأقسام القادمة على مجموعة بيانات Fashion-MNIST المتشابهة نوعياً، ولكن الأصغر بكثير (Xiao et al.، 2017)، والتي تم إصدارهافي عام 2017. وهي تحتوي على صور لعشر فئات من الملابس بدقة 28 × 28 بكسل.

```
%matplotlib inline
import time
import tensorflow as tf
from d2l import tensorflow as d2l

d2l.use_svg_display()
```

4.2.1. تحميل مجموعة البيانات Loading the Dataset

نظرًا لأنها مجموعة بيانات مستخدمة بشكل متكرر، فإن جميع الأطر الرئيسية توفر إصدارات مُعالجة مسبقًا منها. يمكننا تنزيل مجموعة بيانات Fashion-MNIST وقراءتهافي الذاكرة باستخدام دوال إطار العمل المضمنة.

```
class FashionMNIST(d2l.DataModule):  #@save
    def __init__(self, batch_size=64, resize=(28, 28)):
        super().__init__()
        self.save_hyperparameters()
        self.train, self.val =
tf.keras.datasets.fashion_mnist.load_data()
```

يتكون Fashion-MNIST من صور من 10 فئات، كل منها ممثلة بـ 6000 صورةفي مجموعة بيانات التدريب training dataset و1000في مجموعة بيانات الاختبار test dataset. تُستخدم مجموعة بيانات الاختبار لتقييم أداء النموذج (لا يجب استخدامها للتدريب). وبالتالي، تحتوي مجموعة التدريب ومجموعة الاختبار على 60.000 و10000 صورة على التوالي.

```
data = FashionMNIST(resize=(32, 32))
len(data.train[0]), len(data.val[0])
```

الصور ذات تدرج رمادي وترقيتها إلى 32×32 بكسلفي الدقة أعلاه. هذا مشابه لمجموعة بيانات MNIST الأصلية التي تتكون من صور (ثنائية) بالأبيض والأسود. لاحظ، مع ذلك، أن معظم بيانات الصور الحديثة تحتوي على 3 قنوات (أحمر، أخضر، أزرق) وصور فائقة الطيف hyperspectral images يمكن أن تحتوي على أكثر من 100 قناة (مستشعر HyMap به 126 قناة). حسب الاصطلاح، نقوم بتخزين الصورة كموتّر $c \times h \times w$ ، حيث يكون c عدد قنوات اللون،h هو الارتفاع وw هو العرض.

```
data.train[0][0].shape
```

```
(28, 28)
```

فئات Fashion-MNIST لها أسماء مفهومة من قبل الإنسان. يتم تحويل دالة الملائمة convenience function التالية بين التسميات الرقمية وأسمائها.

```
@d2l.add_to_class(FashionMNIST)  #@save
def text_labels(self, indices):
    """Return text labels."""
    labels = ['t-shirt', 'trouser', 'pullover', 'dress',
'coat',
              'sandal', 'shirt', 'sneaker', 'bag',
'ankle boot']
    return [labels[int(i)] for i in indices]
```

4.2.2. قراءة الدفعات الصغيرة Reading a Minibatch

لجعل حياتنا أسهل عند القراءة من مجموعات التدريب والاختبار، نستخدم مكرر البيانات المدمج built-in data iterator بدلاً من إنشاء واحد من البداية. تذكر أنهفي كل تكرار، يقرأ مكرر البيانات دفعة صغيرة من البيانات ذات الحجم `batch_size`. نقوم أيضًا بترتيب الأمثلة عشوائيًا لمكرر بيانات التدريب.

```
@d2l.add_to_class(FashionMNIST)  #@save
def get_dataloader(self, train):
    data = self.train if train else self.val
    process = lambda X, y: (tf.expand_dims(X, axis=3) /
255,
```

```
                                tf.cast(y, dtype='int32'))
    resize_fn = lambda X, y:
(tf.image.resize_with_pad(X, *self.resize), y)
    shuffle_buf = len(data[0]) if train else 1
    return
tf.data.Dataset.from_tensor_slices(process(*data)).batch
(

self.batch_size).map(resize_fn).shuffle(shuffle_buf)
```

لمعرفة كيفية عمل ذلك، دعنا نحمل مجموعة صغيرة minibatch من الصور عن طريق استدعاء طريقة `train_dataloader` المضافة حديثًا. يحتوي على 64 صورة.

```
X, y = next(iter(data.train_dataloader()))
print(X.shape, X.dtype, y.shape, y.dtype)
```

```
(64, 32, 32, 1) <dtype: 'float32'> (64,) <dtype:
'int32'>
```

دعونا نلقي نظرة على الوقت المستغرق لقراءة الصور. على الرغم من أنه محمل مدمج built-in loader، إلا أنه ليس سريعًا للغاية. ومع ذلك، يعد هذا كافيًا لأن معالجة الصور باستخدام شبكة عميقة تستغرق وقتًا أطول قليلاً. ومن ثم، فمن الجيد بما يكفي ألا يكون تدريب الشبكة مقيدًا بإدخال معلومات.

```
tic = time.time()
for X, y in data.train_dataloader():
    continue
f'{time.time() - tic:.2f} sec'
```

```
'0.82 sec'
```

4.2.3. التمثيل البياني Visualization

سنستخدم مجموعة بيانات Fashion-MNIST كثيرًا. يمكن استخدام دالة ملائمة `show_images` لتمثيل البياني للصور والتسميات المرتبطة بها. تفاصيل تنفيذه مؤجلة إلى الملحق.

```
def show_images(imgs, num_rows, num_cols, titles=None,
scale=1.5):  #@save
    """Plot a list of images."""
    raise NotImplementedError
```

دعونا نستخدمها بشكل جيد. بشكل عام، من الجيد تمثيل وفحص البيانات التي تتدرب عليها. إن البشر بارعون جدًافي اكتشاف الجوانب غير المعتادة، وبالتالي، فإن التمثيل البياني بمثابة حماية

إضافية ضد الأخطاءفي تصميم التجارب. فيما يلي الصور والتسميات المقابلة لها (في النص) للأمثلة القليلة الأولىفي مجموعة بيانات التدريب.

```
@d2l.add_to_class(FashionMNIST)  #@save
def visualize(self, batch, nrows=1, ncols=8, labels=[]):
    X, y = batch
    if not labels:
        labels = self.text_labels(y)
    d2l.show_images(tf.squeeze(X), nrows, ncols,
titles=labels)

batch = next(iter(data.val_dataloader()))
data.visualize(batch)
```

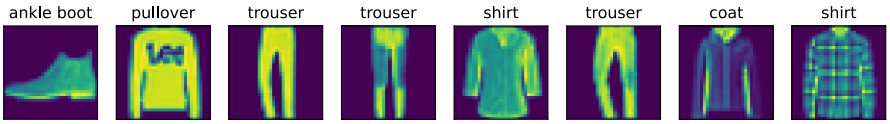

نحن الآن جاهزون للعمل مع مجموعة بيانات Fashion-MNISTفي الأقسام التالية.

4.2.4. الملخص

لدينا الآن مجموعة بيانات أكثر واقعية لاستخدامهافي التصنيف. Fashion-MNIST هي مجموعة بيانات لتصنيف الملابس تتكون من صور تمثل 10 فئات. سنستخدم مجموعة البيانات هذهفي الأقسام والفصول اللاحقة لتقييم تصميمات الشبكات المختلفة، من نموذج خطي بسيط إلى شبكات متبقية متقدمة. كما نفعل عادةً مع الصور، نقرأها كموتّر للشكل (حجم الدفعة، عدد القنوات، الارتفاع، العرض).في الوقت الحالي، لدينا قناة واحدة فقط لأن الصور ذات تدرج رمادي (يستخدم التمثيل البياني أعلاه لوحة ألوان زائفة لتحسين الرؤية).

أخيرًا، تعد أجهزة تكرار البيانات data iterators مكونًا رئيسيًا للأداء الفعال. على سبيل المثال، قد نستخدم وحدات معالجة الرسومات GPU لإلغاء ضغط الصورة بكفاءة، أو تحويل ترميز الفيديو، أو غير ذلك من عمليات المعالجة المسبقة. كلما كان ذلك ممكنًا، يجب أن تعتمد على مكررات البيانات التي تم تنفيذها جيدًا والتي تستغل الحوسبة عالية الأداء لتجنب إبطاء حلقة التدريب الخاصة بك.

4.2.5. التمارين

1. هل تقليل حجم الدفعة `batch_size` (على سبيل المثال، إلى 1) يؤثر على أداء القراءة؟

2. أداء مكرر البيانات data iterator مهم. هل تعتقد أن التنفيذ الحالي سريع بما فيه الكفاية؟ استكشف الخيارات المختلفة لتحسينها. استخدم ملف تعريف النظام لمعرفة مكان الاختناقات bottlenecks.
3. تحقق من وثائق API على الإنترنت الخاصة بإطار العمل. ما هي مجموعات البيانات الأخرى المتوفرة؟

4.3 نموذج التصنيف الأساسي The Base Classification Model

ربما لاحظت أن عمليات التنفيذ من البداية implementations from scratch والتنفيذ المختصر concise implementation باستخدام دالة إطار العمل كانت متشابهة تمامًافي حالة الانحدار. وينطبق الشيء نفسه على التصنيف. نظرًا لأن العديد من النماذجفي هذا الكتاب تتعامل مع التصنيف، فمن الجدير إضافة بعض الدوال لدعم هذا الإعداد على وجه التحديد. يوفر هذا القسم فئة أساسية لنماذج التصنيف لتبسيط الكود المستقبلي.

```
import tensorflow as tf
from IPython import display
from d2l import tensorflow as d2l
```

4.3.1. فئة المصنف The Classifier Class

نحدد فئة المصنف Classifier أدناه.في `validation_step` نقوم بالإبلاغ عن كل من قيمة الخطأ ودقة التصنيف classification accuracy على دفعة التحقق من الصحة validation batch. نحن نرسم تحديثًا لكل عدد من الدفعات `num_val_batches`. هذا له فائدة توليد متوسط الخطأ والدقة على بيانات التحقق بأكملها. هذه الأرقام المتوسطة ليست صحيحة تمامًا إذا كانت الدفعة الأخيرة تحتوي على أمثلة أقل، لكننا نتجاهل هذا الاختلاف الطفيف للحفاظ على بساطة الرمز.

```
class Classifier(d2l.Module):  #@save
    def validation_step(self, batch):
        Y_hat = self(*batch[:-1])
        self.plot('loss', self.loss(Y_hat, batch[-1]),
train=False)
        self.plot('acc', self.accuracy(Y_hat, batch[-
1]), train=False)
```

بشكل افتراضي، نستخدم مُحسِّن التدرج الاشتقاقي العشوائي SGD، يعمل على الدفعات الصغيرةminibatches، تمامًا كما فعلنافي سياق الانحدار الخطي.

```
@d2l.add_to_class(d2l.Module)  #@save
def configure_optimizers(self):
    return tf.keras.optimizers.SGD(self.lr)
```

4.3.2. الدقة Accuracy

بالنظر إلى التوزيع الاحتمالي المتوقع y_hat، فإننا عادةً ما نختار الفئة ذات أعلى احتمالية متوقعة عندما يتعين علينا إخراج تنبؤ صعب.في الواقع، تتطلب العديد من التطبيقات أن نقوم بالاختيار. على سبيل المثال، يجب أن يصنف Gmail بريدًا إلكترونيًا إلى "أساسي" أو "اجتماعي" أو "تحديثات" أو "منتديات" أو "بريد عشوائي". قد يقدر الاحتمالات داخليًا، ولكنفي نهاية اليوم، يجب عليه اختيار واحد من بين الفئات.

عندما تتوافق التنبؤات مع فئة التسمية y، فإنها صحيحة. دقة التصنيف هي جزء من كل التوقعات الصحيحة. على الرغم من أنه قد يكون من الصعب تحسين الدقة بشكل مباشر (لا يمكن التمييز بينها)، إلا أنه غالبًا ما يكون مقياس الأداء الذي نهتم به كثيرًا. غالبًا ما تكون الكمية ذات الصلةفي المعايير. على هذا النحو، سنقوم دائمًا بالإبلاغ عن ذلك عند تدريب المصنفات.

يتم حساب الدقة على النحو التالي. أولاً، إذا كانت y_hat عبارة عن مصفوفة، فإننا نفترض أن البعد الثاني يخزن درجات التنبؤ لكل فئة. نستخدم argmaxللحصول على الفئة المتوقعة بواسطة الفهرس لأكبر إدخالفي كل صف. ثم نقارن الفئة المتنبأ بها مع الحقيقة الأساسية y بشكل عنصري elementwise. نظرًا لأن عامل المساواة == حساس لأنواع البيانات، فإننا نقوم بتحويل نوع بيانات y_hat لمطابقة نوع بيانات y. والنتيجة هي موتر يحتوي على إدخالات من 0 (خطأ) و1 (صواب). أخذ المجموع ينتج عنه عدد التنبؤات الصحيحة.

```
@d2l.add_to_class(Classifier)  #@save
def accuracy(self, Y_hat, Y, averaged=True):
    """Compute the number of correct predictions."""
    Y_hat = tf.reshape(Y_hat, (-1, Y_hat.shape[-1]))
    preds = tf.cast(tf.argmax(Y_hat, axis=1), Y.dtype)
    compare = tf.cast(preds == tf.reshape(Y, -1),
tf.float32)
    return tf.reduce_mean(compare) if averaged else
compare
```

4.3.3. الملخص

التصنيف مشكلة شائعة بما فيه الكفاية لدرجة أنه يضمن دوال الملائمة convenience functions الخاصة به. من الأهمية بمكانفي التصنيف دقة المصنف. لاحظ أنه بينما نهتم غالبًا بالدقة، فإننا ندرب المصنفين لتحسين مجموعة متنوعة من الأهداف الأخرى لأسباب إحصائية وحسابية. ومع ذلك، بغض النظر عن دالة الخطأ التي تم تقليلها أثناء التدريب، فمن المفيد أن يكون لديك طريقة ملائمة لتقييم دقة المصنف تجريبيًا.

4.3.4. تمارين

1. قم بالإشارة إلى خطأ التحقق من الصحة L_v ، وليكن L_v^q تقديرها السريع والقذر محسوبًا بواسطة دالة الخطأفي المتوسطفي هذا القسم. أخيرًا، قم بالإشارة بواسطة l_v^bالخطأفي آخر minibatch. قم بالتعبير عن L_v من حيث L_v^q و l_v^b وأحجام العينة و minibatch.
2. أظهر أن التقدير السريع والقذر L_v^q غير متحيز unbiased. هذا هو، أظهر ذلك $E[L_v] = E[L_v^q]$. لماذا لا تزال ترغبفي استخدام L_v بدلا من ذلك؟
3. بالنظر إلى خطأ التصنيف متعدد الطبقات multiclass classification loss، $l(y, y')$ التي تدل على عقوبة التقدير y' عندما نرى y والاحتمالية المعطاة $p(y \mid x)$، قم بصياغة القاعدة للاختيار الأمثل لـ y'. تلميح: عبر عن الخطأ المتوقع باستخدام l و $p(y \mid x)$.

4.4 تنفيذ انحدار Softmax من الصفر Softmax Regression Implementation from Scratch

نظرًا لأن انحدار softmax أساسي جدًا، فنحن نعتقد أنه يجب عليك معرفة كيفية تنفيذه بنفسك. هنا، نقتصر على تحديد الجوانب الخاصة بـ softmax للنموذج وإعادة استخدام المكونات الأخرى من قسم الانحدار الخطي، بمافي ذلك حلقة التدريب.

```
import tensorflow as tf
from d2l import tensorflow as d2l
```

4.4.1. سوفت ماكس The Softmax

لنبدأ بالجزء الأكثر أهمية: التخطيط من القيم القياسية Scalars إلى الاحتمالات probabilities. لتجديد المعلومات، تذكر عملية عامل المجموع على طول أبعاد محددةفي موتر، كما تمت مناقشتهفي القسم 2.3.6 والقسم 2.3.7. بالنظر إلى المصفوفة X، يمكننا جمع كل العناصر (افتراضيًا) أو فقط العناصر الموجودةفي نفس المحور. يتيح لنا متغير المحور حساب مجاميع الصفوف والأعمدة:

```
X = tf.constant([[1.0, 2.0, 3.0], [4.0, 5.0, 6.0]])
tf.reduce_sum(X, 0, keepdims=True), tf.reduce_sum(X, 1,
keepdims=True)
```

```
(<tf.Tensor: shape=(1, 3), dtype=float32,
numpy=array([[5., 7., 9.]], dtype=float32)>,
 <tf.Tensor: shape=(2, 1), dtype=float32, numpy=
 array([[ 6.],
        [15.]], dtype=float32)>)
```

يتطلب حساب softmax ثلاث خطوات: (1) الأس لكل مصطلح؛ (2) مجموع كل صف لحساب ثابت التسوية لكل مثال؛ (3) قسمة كل صف على ثابت التسوية الخاص به ، مع التأكد من أن النتيجة تصل إلى 1.

$$\text{softmax}(\mathbf{X})_{ij} = \frac{\exp(\mathbf{X}_{ij})}{\sum_k \exp(\mathbf{X}_{ik})}.$$

يسمى (لوغاريتم) المقام بدالة القسم (اللوغارتم) partition function (log). تم تقديمهفي الفيزياء الإحصائية statistical physics لتلخيص جميع الحالات الممكنةفي مجموعة الديناميكا الحرارية. التنفيذ مباشر:

```
def softmax(X):
    X_exp = tf.exp(X)
    partition = tf.reduce_sum(X_exp, 1, keepdims=True)
    return X_exp / partition  # The broadcasting
mechanism is applied here
```

لأي إدخال X، نحول كل عنصر إلى رقم غير سالب. يلخص كل صف ما يصل إلى 1، كما هو مطلوب للاحتمال. تحذير: الكود أعلاه ليس قويًا ضد المدخلات الكبيرة جدًا أو الصغيرة جدًا. في حين أن هذا كافٍ لتوضيح ما يحدث، يجب ألا تستخدم هذا الرمز حرفيًا لأي غرض جاد. تحتوي أطر التعلم العميق على مثل هذه الحماية المضمنة وسنستخدم softmax المدمجفي المستقبل.

```
X = tf.random.uniform((2, 5))
X_prob = softmax(X)
X_prob, tf.reduce_sum(X_prob, 1)
```

```
(<tf.Tensor: shape=(2, 5), dtype=float32, numpy=
 array([[0.15478596, 0.14451225, 0.31821206, 0.1521694 ,
0.23032041],
        [0.21168488, 0.29741856, 0.15408915, 0.14877847,
0.18802889]],
       dtype=float32)>,
 <tf.Tensor: shape=(2,), dtype=float32,
numpy=array([1.0000001 , 0.99999994], dtype=float32)>)
```

4.4.2. الموديل The Model

لدينا الآن كل ما نحتاجه لتنفيذ نموذج انحدار softmax. كمافي مثال الانحدار الخطي الخاص بنا، سيتم تمثيل كل مثيل instance بواسطة متجه بطول ثابت. نظرًا لأن البيانات الأولية هنا تتكون من صور 28 × 28 بكسل، فإننا نقوم بتسوية كل صورة، ومعاملتها كمتجهات بطول 784.

في فصول لاحقة، سنقدم الشبكات العصبية التلافيفية convolutional neural networks، والتي تستغل البنية المكانية بطريقة أكثر إرضاءً.

في انحدار softmax، يجب أن يكون عدد المخرجات من شبكتنا مساويًا لعدد الفئات. نظرًا لأن مجموعة البيانات الخاصة بنا تتكون من 10 فئات، فإن بُعد إخراج شبكتنا هو 10. وبالتالي، تشكل أوزاننا مصفوفة 10 × 784 بالإضافة إلى متجه صف 10 × 1 أبعاد للتحيزات. كما هو الحال مع الانحدار الخطي، نقوم بتهيئة الأوزان W بضوضاء غاوسي. تتم تهيئة التحيزات كأصفار.

```
class SoftmaxRegressionScratch(d2l.Classifier):
    def __init__(self, num_inputs, num_outputs, lr,
sigma=0.01):
        super().__init__()
        self.save_hyperparameters()
        self.W = tf.random.normal((num_inputs,
num_outputs), 0, sigma)
        self.b = tf.zeros(num_outputs)
        self.W = tf.Variable(self.W)
        self.b = tf.Variable(self.b)
```

يحدد الكود أدناه كيف تقوم الشبكة بتعيين كل إدخال إلى أحد المخرجات. لاحظ أننا نقوم بتسوية كل صورة 28 × 28 بكسل في الدُفعة إلى متجه باستخدام إعادة التشكيل `reshape` قبل تمرير البيانات عبر نموذجنا.

```
@d2l.add_to_class(SoftmaxRegressionScratch)
def forward(self, X):
    return softmax(tf.matmul(tf.reshape(
        X, (-1, self.W.shape[0])), self.W) + self.b)
```

4.4.3. الخطأ عبر الانتروبيا The Cross-Entropy Loss

بعد ذلك نحتاج إلى تنفيذ دالة الخطأ عبر الانتروبيا (المقدمةفي القسم 4.1.2). قد تكون هذه هي دالة الخطأ الأكثر شيوعًافي كل التعلم العميق.في الوقت الحالي، فإن تطبيقات التعلم العميق تلقي بسهولة مشاكل التصنيف التي تفوق بكثير تلك التي يتم التعامل معها بشكل أفضل على أنها مشاكل انحدار.

تذكر أن الانتروبيا المتقاطعة Cross-Entropy تأخذ احتمالية اللوغارتم السلبية للاحتمال المتوقع المخصص للتسمية الحقيقية. من أجل الكفاءة، نتجنب بايثون for-loops ونستخدم الفهرسة indexing بدلاً من ذلك. على وجه الخصوص، يتيح لنا التشفير الأحادي الساخن تحديد مصطلحات المطابقةفي $\mathbf{y}$ بتحديد مصطلحات المطابقةفي $\hat{\mathbf{y}}$.

لرؤية هذا عمليًا، قمنا بإنشاء عينة بيانات y_hat مع مثالين للاحتمالات المتوقعة عبر 3 فئات والتسميات المقابلة لها y. التسميات الصحيحة هي 1 و2 على التوالي. باستخدام y كمؤشرات للاحتمالاتفي y_hat، يمكننا اختيار الحدود بكفاءة.

```
y_hat = tf.constant([[0.1, 0.3, 0.6], [0.3, 0.2, 0.5]])
y = tf.constant([0, 2])
tf.boolean_mask(y_hat, tf.one_hot(y, depth=y_hat.shape[-
1]))
```

```
<tf.Tensor: shape=(2,), dtype=float32, numpy=array([0.1,
0.5], dtype=float32)>
```

يمكننا الآن تنفيذ دالة الخطأ عبر الانتروبيا من خلال حساب المتوسط على لوغاريتمات الاحتمالات المحددة.

```
def cross_entropy(y_hat, y):
    return - tf.reduce_mean(tf.math.log(tf.boolean_mask(
        y_hat, tf.one_hot(y, depth=y_hat.shape[-1]))))

cross_entropy(y_hat, y)
```

```
<tf.Tensor: shape=(), dtype=float32, numpy=1.4978662>
```

```
@d2l.add_to_class(SoftmaxRegressionScratch)
def loss(self, y_hat, y):
    return cross_entropy(y_hat, y)
```

4.4.4. التدريب Training

نعيد استخدام طريقة الملاءمة المحددةفي القسم 3.4 لتدريب النموذج على 10 فترات. لاحظ أن كلاً من عدد الفترات (max_epochs)، وحجم الدفعات الصغيرة (batch_size)، ومعدل التعلم (lr) هي معلمات فائقة قابلة للتعديل adjustable hyperparameters. هذا يعني أنه على الرغم من عدم تعلم هذه القيم خلال حلقة التدريب الأولية لدينا، إلا أنها لا تزال تؤثر على أداء نموذجنا، والبوت مقابل التدريب وأداء التعميم. من الناحية العملية، سترغبفي اختيار هذه القيم بناءً على تقسيم التحقق من صحة البيانات ثم تقييم نموذجك النهائيفي نهاية المطاففي قسم الاختبار. كما تمت مناقشتهفي القسم 3.6.3، سوف نتعامل مع بيانات اختبار Fashion-MNIST باعتبارها مجموعة التحقق من الصحة، وبالتالي الإبلاغ عن خطأ التحقق من الصحة ودقة التحقق من الصحة على هذا التقسيم.

```
data = d2l.FashionMNIST(batch_size=256)
model = SoftmaxRegressionScratch(num_inputs=784,
num_outputs=10, lr=0.1)
trainer = d2l.Trainer(max_epochs=10)
trainer.fit(model, data)
```

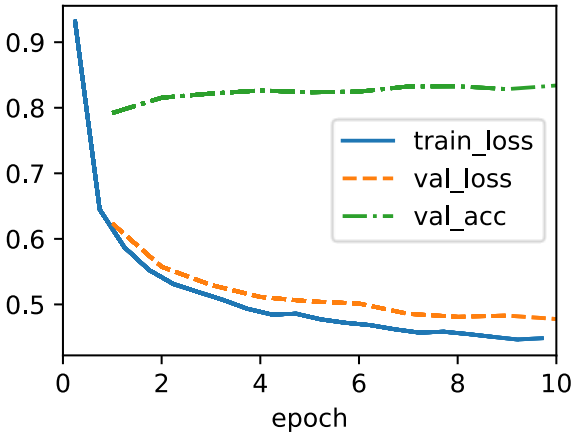

4.4.5. التنبؤ Prediction

الآن بعد اكتمال التدريب، أصبح نموذجنا جاهزًا لتصنيف بعض الصور.

```
X, y = next(iter(data.val_dataloader()))
preds = tf.argmax(model(X), axis=1)
preds.shape
```

```
TensorShape([256])
```

نحن مهتمون أكثر بالصور التي نسميها label بشكل غير صحيح. نتخيلها من خلال مقارنة تسمياتها الفعلية (السطر الأول من إخراج النص) مع التنبؤات من النموذج (السطر الثاني من إخراج النص)

```
wrong = tf.cast(preds, y.dtype) != y
X, y, preds = X[wrong], y[wrong], preds[wrong]
labels = [a+'\n'+b for a, b in zip(
    data.text_labels(y), data.text_labels(preds))]
data.visualize([X, y], labels=labels)
```

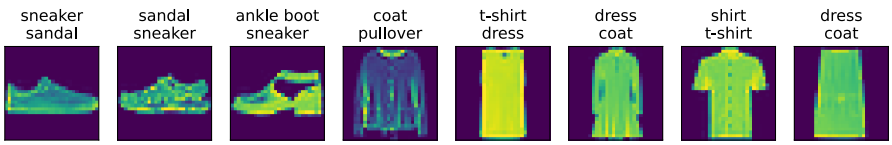

4.4.6. الملخص

لقد بدأنا الآنفي اكتساب بعض الخبرةفي حل مشاكل الانحدار الخطي والتصنيف. بواسطته، وصلنا إلى ما يمكن القول إنه حالة فن النمذجة الإحصائيةفي الستينيات والسبعينيات من القرن

الماضي.في القسم التالي، سنوضح لك كيفية الاستفادة من أطر التعلم العميق لتنفيذ هذا النموذج بشكل أكثر كفاءة.

4.4.7. التمارين

1. في هذا القسم، قمنا بتنفيذ دالة softmax بشكل مباشر بناءً على التعريف الرياضي لعملية softmax. كما نوقش في القسم 4.1، يمكن أن يتسبب هذا في عدم استقرار رقمي numerical instabilities.
   1. اختبر ما إذا كان softmax لا يزال يعمل بشكل صحيح إذا كانت قيمة الإدخال 100 ؟
   2. اختبر ما إذا كان softmax لا يزال يعمل بشكل صحيح إذا كان أكبر المدخلات أصغر من -100 ؟
   3. قم بتنفيذ الإصلاح بالنظر إلى القيمة المتعلقة بأكبر إدخال في الوسيطة.
2. تنفيذ دالة عبر_انتروبيا `cross_entropy` تتبع تعريف دالة الخطأ عبر الانتروبيا $\sum_i \quad y_i \log \hat{y}_i$
   1. جربه في مثال الكود أعلاه.
   2. لماذا تعتقد أنه يعمل بشكل أبطأ؟
   3. هل يجب عليك استخدامه؟في أي الحالات يكون له معنى؟
   4. ما الذي تحتاج إلى توخي الحذر منه؟ تلميح: ضع في اعتبارك مجال اللوغاريتم.
3. هل من الجيد دائمًا إرجاع التسمية الأكثر احتمالاً؟ على سبيل المثال، هل ستفعل هذا من أجل التشخيص الطبي؟ كيف ستحاول معالجة هذا؟
4. افترض أننا نريد استخدام انحدار softmax للتنبؤ بالكلمة التالية بناءً على بعض الميزات. ما هي بعض المشاكل التي قد تنشأ من المفردات الكبيرة؟
5. جرب المعلمات الفائقة hyperparameters للشفرة أعلاه. خاصه:
   1. ارسم كيف يتغير خطأ التحقق أثناء تغيير معدل التعلم.
   2. هل يتغير التحقق من الصحة وخطأ التدريب كلما قمت بتغيير حجم الدفعات الصغيرة؟ إلى أي مدى يجب أن تذهب قبل أن ترى تأثيرًا كبيرًا أم صغيرًا؟

4.5 التنفيذ المختصر لانحدار Softmax

مثلما سهّلت أطر التعلم العميق عالية المستوى تنفيذ الانحدار الخطي (انظر القسم 3.5)، فهي مناسبة أيضًا هنا.

```
import tensorflow as tf
from d2l import tensorflow as d2l
```

4.5.1. تعريف النموذج Defining the Model

كمافي القسم 3.5، نقوم ببناء الطبقة المتصلة بالكامل باستخدام الطبقة المضمنة built-in layer. ثم تستدعي طريقة `__call__` المضمنة `forward` كلما احتجنا إلى تطبيق الشبكة على بعض المدخلات.

```
class SoftmaxRegression(d2l.Classifier):
    def __init__(self, num_outputs, lr):
        super().__init__()
        self.save_hyperparameters()
        self.net = tf.keras.models.Sequential()
        self.net.add(tf.keras.layers.Flatten())
        self.net.add(tf.keras.layers.Dense(num_outputs))

    def forward(self, X):
        return self.net(X)
```

4.5.2. إعادة النظر في سوفت ماكس Softmax Revisited

في القسم 4.4، قمنا بحساب ناتج نموذجنا وطبقنا خطأ الانتروبيا المتقاطعة.في حين أن هذا معقول رياضيًا تمامًا، إلا أنه محفوف بالمخاطر من الناحية الحسابية، بسبب underflow و overflow في الأس.

تذكر أن دالة softmax تحسب الاحتمالات عبر $\hat{y}_j = \frac{\exp(o_j)}{\sum_k \exp(o_k)}$. إذا كان بعضها كبيرًا جدًا، أي إيجابي جدًا، فقد يكون أكبر من أكبر رقم يمكننا الحصول عليه لأنواع بيانات معينة. هذا يسمى الفائض overflow. وبالمثل، إذا كانت جميع المعاملات arguments سلبية للغاية، فسنحصل على underflow. على سبيل المثال، تغطي أرقام الفاصلة العائمة ذات الدقة الواحدة تقريبًا نطاق إلى 10^{-38}. على هذا النحو، إذا كان الحد الأكبرفي $\mathbf{o}$ يقع خارج الفترة الزمنية $[-90,90]$ ، فلن تكون النتيجة مستقرة. حل هذه المشكلة هو طرح $\overline{o} \stackrel{\text{def}}{=} \max_k o_k$ من كافة الإدخالات:

$$\hat{y}_j = \frac{\exp o_j}{\sum_k \exp o_k} = \frac{\exp(o_j - \overline{o})\exp \overline{o}}{\sum_k \exp(o_k - \overline{o})\exp \overline{o}} = \frac{\exp(o_j - \overline{o})}{\sum_k \exp(o_k - \overline{o})}.$$

من خلال البناء نعرف $o_j - \overline{o} \leq 0$ لكل j. على هذا النحو، بالنسبة لمشكلة تصنيف فئة q ، يتم احتواء المقامفي الفاصل الزمني $[1, q]$. علاوة على ذلك، لا يتجاوز البسط أبدًا 1 ، وبالتالي يمنع التدفق العددي numerical overflow. يحدث التدفق العددي فقط عندما $\exp(o_j - \overline{o})$ تُقيم عدديًا كـ 0. ومع ذلك، على بعد خطوات قليلة على الطريق، قد نجد أنفسنافي مأزق عندما نريد حساب $\log \hat{y}_j$ كما $\log 0$. على وجه الخصوص،في الانتشار الخلفي

backpropagation، قد نجد أنفسنافي مواجهة شاشة من نتائج NaN المخيفة (ليس رقمًا Not a Number).

لحسن الحظ، يتم إنقاذنا من حقيقة أنه على الرغم من أننا نحسب الدوال الأسية، فإننا نعتزمفي النهاية أخذ log (عند حساب خطأ الانتروبيا المتقاطعة). من خلال الجمع بين softmax و cross-entropy، يمكننا الهروب من مشكلات الاستقرار العددي تمامًا. نملك:

$$\log \hat{y}_j = \log \frac{\exp(o_j - \overline{o})}{\sum_k \exp(o_k - \overline{o})} = o_j - \overline{o} - \log \sum_k \exp(o_k - \overline{o}).$$

هذا يتجنب كلاً من الفائض overflow والفيضان underflow. سنرغبفي الاحتفاظ بدالة softmax التقليديةفي متناول اليدفي حالة رغبتنافي تقييم احتمالات الإخراج من خلال نموذجنا. ولكن بدلاً من تمرير احتمالات softmax إلى دالة الخسارة الجديدة لدينا، نقوم فقط بتمرير السجلات logits وحساب softmax وسجله مرة واحدة داخل دالة فقدان الانتروبيا، والتي تقوم بأشياء ذكية مثل "خدعة"LogSumExp trick" ".

```
@d2l.add_to_class(d2l.Classifier)  #@save
def loss(self, Y_hat, Y, averaged=True):
    Y_hat = tf.reshape(Y_hat, (-1, Y_hat.shape[-1]))
    Y = tf.reshape(Y, (-1,))
    fn =
tf.keras.losses.SparseCategoricalCrossentropy(from_logit
s=True)
    return fn(Y, Y_hat)
```

4.5.3. التدريب Training

بعد ذلك نقوم بتدريب نموذجنا. كما كان من قبل، نستخدم صور Fashion-MNIST، تسطح flattened إلى 784 متجهًا للميزات ذات الأبعاد.

```
data = d2l.FashionMNIST(batch_size=256)
model = SoftmaxRegression(num_outputs=10, lr=0.1)
trainer = d2l.Trainer(max_epochs=10)
trainer.fit(model, data)
```

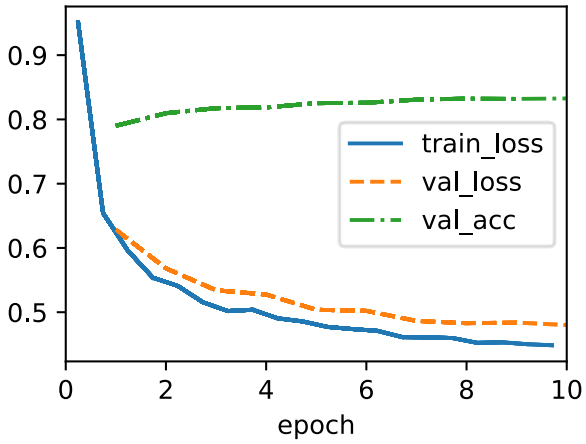

كمافي السابق، تتقارب هذه الخوارزمية مع حل يحقق دقة لائقة، وإن كان هذا الوقت يحتوي على عدد أقل من سطور التعليمات البرمجية عن ذي قبل.

4.5.4. الملخص

تعد واجهات برمجة التطبيقات APIs عالية المستوى ملائمة للغايةفي إخفاء الجوانب التي يحتمل أن تكون خطرة عن مستخدميها، مثل الاستقرار العددي numerical stability. علاوة على ذلك، فهي تسمح للمستخدمين بتصميم النماذج بإيجاز مع عدد قليل جدًا من أسطر التعليمات البرمجية. هذا هو بمثابة نعمة ونقمة. الفائدة الواضحة هي أنه يجعل الأشياء سهلة الوصول، حتى للمهندسين الذين لم يأخذوا فئة واحدة من الإحصائياتفي حياتهم (في الواقع، هذا هو أحد الجماهير المستهدفة للكتاب). لكن إخفاء الحواف الحادة يأتي أيضًا مع ثمن: عامل مثبط لإضافة مكونات جديدة ومختلفة بمفردك، نظرًا لوجود ذاكرة عضلية قليلة للقيام بذلك. علاوة على ذلك، فإنه يجعل من الصعب إصلاح الأشياء كلما فشلت الحشوة الحامية protective padding لإطار العملفي تغطية جميع حالات الزاوية بالكامل. مرة أخرى، هذا يرجع إلى عدم الإلمام.

على هذا النحو، نحثك بشدة على مراجعة كل من العظام المجردة والإصدارات الأنيقة للعديد من التطبيقات التالية. بينما نؤكد على سهولة الفهم، فإن التطبيقات عادة ما تكون عالية الأداء (التلافيف convolutions هي الاستثناء الكبير هنا). نعتزم السماح لك بالبناء عليها عندما تخترع شيئًا جديدًا لا يمكن لأي إطار عمل أن يمنحك إياه.

4.5.5. التمارين

1. يستخدم التعلم العميق العديد من تنسيقات الأرقام المختلفة، بمافي ذلك الدقة المزدوجة لـ FP64 (نادرًا جدًا)، الدقة الفردية FP32، BFLOAT16 (جيدة للتمثيلات المضغوطة) ، FP16 (غير مستقر جدًا) ، TF32 (تنسيق جديد من

NVIDIA)،و INT8. احسب أصغر وأكبر وسيطة للدالة الأسية التي لا تؤدي نتيجتها إلى تدفق رقمي numerical underflow أو overflow.

2. INT8 هو تنسيق محدود للغاية بأرقام غير صفرية من 1 إلى 255. كيف يمكنك توسيع نطاقها الديناميكي دون استخدام المزيد من البتات؟ هل الضرب والجمع القياسيان مازالا يعملان؟
3. زيادة عدد فترات التدريب number of epochs for training. لماذا قد تنخفض دقة التحقق بعد فترة؟ كيف يمكننا إصلاح هذا؟
4. ماذا يحدث كلما زادت معدل التعلم؟ قارن منحنيات الخطأ للعديد من معدلات التعلم. أيهما يعمل بشكل أفضل؟ متى؟

4.6 التعميم في التصنيف Generalization in Classification

حتى الآن، ركزنا على كيفية معالجة مشاكل التصنيف متعدد الطبقات multiclass classification problems من خلال تدريب الشبكات العصبية (الخطية) ذات المخرجات المتعددة ودوال softmax. عند تفسير مخرجات نموذجنا على أنها تنبؤات احتمالية، قمنا بتحفيز واشتقاق دالة خطأ الانتروبيا المتقاطعة cross-entropy loss function، والتي تحسب احتمالية اللوغارتم السلبي negative log likelihood التي يخصصها نموذجنا (لمجموعة ثابتة من المعلمات) للتسميات الفعلية. وأخيرًا، نضع هذه الأدوات موضع التنفيذ من خلال ملاءمة fitting نموذجنا لمجموعة التدريب. ومع ذلك، كما هو الحال دائمًا، فإن هدفنا هو تعلم الأنماط العامة general patterns، كما تم تقييمها تجريبياً على بيانات غير مرئية من قبل unseen data (مجموعة الاختبار). الدقة العاليةفي مجموعة التدريب لا تعني شيئًا. عندما تكون كل من مدخلاتنا فريدة من نوعها (وهذا ينطبق بالفعل على معظم مجموعات البيانات عالية الأبعاد)، يمكننا تحقيق دقة مثاليةفي مجموعة التدريب بمجرد حفظ مجموعة البياناتفي فترة التدريب الأولى، ثم البحث عن التسمية كلما رأينا صورة جديدة. ومع ذلك، فإن حفظ التسميات الدقيقة المرتبطة بأمثلة التدريب الدقيقة لا يخبرنا بكيفية تصنيف الأمثلة الجديدة.في غياب المزيد من الإرشادات، قد نضطر إلى الرجوع إلى التخمين العشوائي كلما واجهنا أمثلة جديدة.

يتطلب عدد من الأسئلة الملحة اهتمامًا فوريًا: 1. كم عدد أمثلة الاختبار التي نحتاجها لتقدير دقة المصنفات الخاصة بنا على السكان الأساسيين؟ 2. ماذا يحدث إذا واصلنا تقييم النماذجفي نفس الاختبار بشكل متكرر؟ 3. لماذا يجب أن نتوقع أن ملاءمة نماذجنا الخطية لمجموعة التدريب يجب أن تكون أفضل من مخطط الحفظ الساذج لدينا؟

بينما قدم القسم 3.6 أساسيات الضبط الزائد overfitting والتعميمgeneralizationفي سياق الانحدار الخطي، فإن هذا الفصل سوف يتعمق قليلاً، حيث يقدم بعض الأفكار التأسيسية لنظرية

التعلم الإحصائي. اتضح أنه يمكننافي كثير من الأحيان ضمان التعميم بشكل مسبق: بالنسبة للعديد من النماذج، ولأي حد أعلى مرغوب فيه على فجوة التعميم ϵ، يمكننافي كثير من الأحيان تحديد عدد معين من العينات n المطلوبة مثل إذا كانت مجموعة التدريب لدينا تحتوي على عينات n على الأقل، ثم يقع خطأنا التجريبيفي نطاق ϵ للخطأ الحقيقي، لأي توزيع لتوليد البيانات data generating distribution. لسوء الحظ، اتضح أيضًا أنه بينما توفر هذه الأنواع من الضمانات مجموعة عميقة من اللبنات الفكرية، إلا أنها ذات فائدة عملية محدودة لممارسي التعلم العميق. باختصار، تشير هذه الضمانات إلى أن ضمان تعميم الشبكات العصبية العميقة بشكل مسبق يتطلب عددًا سخيفًا من الأمثلة (ربما تريليونات أو أكثر)، حتى عندما نجد أنهفي المهام التي نهتم بها تلك الشبكات العصبية العميقة عادةً ما يتم تعميمها جيدًا بشكل ملحوظ مع بعيد. عدد أقل من الأمثلة (بالآلاف). وبالتالي، غالبًا ما يتخلى ممارسو التعلم العميق عن الضمانات المسبقة تمامًا، وبدلاً من ذلك يستخدمون الأساليب على أساس أنهم قد تعمموا جيدًا على مشكلات مماثلةفي الماضي، ويصادقون على التعميم بعد ذلك من خلال التقييمات التجريبية. عندما نصل إلى القسم 5، سنعيد النظرفي التعميم ونقدم مقدمة خفيفة للأدبيات العلمية الواسعة التي نشأت في محاولات لشرح سبب تعميم الشبكات العصبية العميقةفي الممارسة.

4.6.1. مجموعة الاختبار The Test Set

نظرًا لأننا بدأنا بالفعلفي الاعتماد على مجموعات الاختبار كأسلوب معياري ذهبي لتقييم خطأ التعميم، فلنبدأ من خلال مناقشة خصائص تقديرات الخطأ هذه. دعنا نركز على مصنف ثابت f، دون القلق بشأن كيفية الحصول عليه. علاوة على ذلك، افترض أننا نمتلك مجموعة بيانات جديدة من الأمثلة $\mathcal{D} = (\mathbf{x}^{(i)}, y^{(i)})_{i=1}^{n}$ التي لم تستخدم لتدريب المصنف f. الخطأ التجريبي لمصنفنا f على $\mathcal{D}$ هو ببساطة جزء من الحالات التي لا يتفق فيها التنبؤ $f(\mathbf{x}^{(i)})$ مع التسمية الحقيقية $y^{(i)}$، ويعطى بالتعبير التالي:

$$\epsilon_{\mathcal{D}}(f) = \frac{1}{n}\sum_{i=1}^{n} \mathbf{1}\left(f(\mathbf{x}^{(i)}) \neq y^{(i)}\right).$$

على النقيض من ذلك، فإن الخطأ السكاني population error هو الجزء المتوقع من الأمثلة في المجموعة الأساسية (بعض التوزيعات $P(X, Y)$ التي تتميز بدالة كثافة الاحتمال $p(\mathbf{x}, y)$ التي لا يتفق المصنف لدينا مع التسمية الحقيقية true label:

$$\epsilon(f) = E_{(\mathbf{x},y)\sim P}\mathbf{1}(f(\mathbf{x}) \neq y) = \int\int \mathbf{1}(f(\mathbf{x}) \neq y)p(\mathbf{x}, y)d\mathbf{x}dy.$$

بينما $\epsilon(f)$ هي الكمية التي نهتم بها بالفعل، لا يمكننا ملاحظتها مباشرة، تمامًا كما لا يمكننا أن نلاحظ بشكل مباشر متوسط الطولفي عدد كبير من السكان دون قياس كل شخص. يمكننا فقط

تقدير هذه الكمية بناءً على العينات. نظرًا لأن مجموعة الاختبار $\mathcal{D}$ الخاصة بنا ممثلة إحصائيًا للسكان الأساسيين، فيمكننا عرض $\epsilon_{\mathcal{D}}(f)$ كمقدر إحصائي للخطأ السكاني $\epsilon(f)$. علاوة على ذلك، نظرًا لأن كمية الاهتمام $\epsilon(f)$ لدينا هي توقع (للمتغير العشوائي $\mathbf{1}(f(X) \neq Y)$) والمقدر المقابل $\epsilon_{\mathcal{D}}(f)$ هو متوسط العينة، فإن تقدير خطأ السكان هو ببساطة المشكلة الكلاسيكية لتقدير المتوسط، والتي قد تتذكرها من القسم 2.6.

هناك نتيجة كلاسيكية مهمة من نظرية الاحتمالات تسمى نظرية الحد المركزي central limit theorem تضمن أنه كلما امتلكنا n عينات عشوائية مأخوذة من أي توزيع بمتوسط μ وانحراف معياري σ، حيث يقترب عدد العينات n من اللانهاية، فإن متوسط العينة $\hat{\mu}$ يميل تقريبًا نحو التوزيع الطبيعي المتمحور حول الوسط الحقيقي والانحراف المعياري $\sigma/\sqrt{n}$. بالفعل، هذا يخبرنا بشيء مهم: مع تزايد عدد الأمثلة، يجب أن يقترب خطأ الاختبار $\epsilon_{\mathcal{D}}(f)$ لدينا من الخطأ الحقيقي $\epsilon(f)$ بمعدل $\mathcal{O}(1/\sqrt{n})$. وبالتالي، لتقدير خطأ الاختبار لدينا مرتين بدقة، يجب أن نجمع مجموعة اختبار أكبر بأربعة أضعاف. لتقليل خطأ الاختبار لدينا بعامل مائة، يجب أن نجمع مجموعة اختبار أكبر بعشرة آلاف مرة. بشكل عام، غالبًا ما يكون هذا المعدل $\mathcal{O}(1/\sqrt{n})$ هو أفضل ما يمكن أن نأملهفي الإحصائيات.

الآن بعد أن عرفنا شيئًا عن المعدل المقارب asymptotic rate الذي يتقارب عنده خطأ الاختبار $\epsilon_{\mathcal{D}}(f)$ لدينا مع الخطأ الحقيقي $\epsilon(f)$، يمكننا تكبير بعض التفاصيل المهمة. تذكر أن المتغير العشوائي محل الاهتمام $\mathbf{1}(f(X) \neq Y)$ يمكن أن يأخذ القيم 0 و 1 فقط، وبالتالي فهو متغير برنولي العشوائي Bernoulli random variable، يتميز بمعامل يشير إلى احتمال أن يأخذ قيمة 1. هنا، 1 يعني أن المصنف الخاص بنا قد ارتكب خطأ، وبالتالي فإن معلمة متغيرنا العشوائي هيفي الواقع معدل الخطأ الحقيقي $\epsilon(f)$. يعتمد تباين σ^2 برنولي على معاملته (هنا $\epsilon(f)$) وفقًا للتعبير $\epsilon(f)(1-\epsilon(f))$. بينما $\epsilon(f)$ غير معروففي البداية، نعلم أنه لا يمكن أن يكون أكبر من 1. يكشف القليل من الاستقصاء عن هذه الدالة أن تباينا يكون أعلى عندما يكون معدل الخطأ الحقيقي قريبًا من 0 ويمكن أن يكون أقل بكثير عندما يكون قريبًا من 0 أو قريبًا من 1. يخبرنا هذا أن الانحراف المعياري المقارب لتقديرنا $\epsilon_{\mathcal{D}}(f)$ للخطأ $\epsilon(f)$ (على اختيار عينات الاختبار) لا يمكن أن يكون أكبر من $\sqrt{0.25/n}$.

إذا تجاهلنا حقيقة أن هذا المعدل يميز السلوك حيث يقترب حجم مجموعة الاختبار من اللانهاية وليس عندما نمتلك عينات محدودة، فهذا يخبرنا أنه إذا أردنا أن يقترب خطأ الاختبار $\epsilon_{\mathcal{D}}(f)$ الخاص بنا من الخطأ السكاني $\epsilon(f)$ بحيث يتوافق الانحراف المعياري مع فترة زمنية قدرها ± 0.01، ثم يجب أن نجمع ما يقرب من 2500 عينة. إذا أردنا احتواء انحرافين معياريينفي هذا النطاق وبالتالي يكون 95٪ من ذلك $\epsilon_{\mathcal{D}}(f) \in \epsilon(f) \pm 0.01$، فسنحتاج إلى 10000 عينة!

اتضح أن هذا هو حجم مجموعات الاختبار للعديد من المعايير الشائعةفي التعلم الآلي. قد تندهش عندما تكتشف أنه يتم نشر الآلاف من أوراق التعلم العميق التطبيقية كل عام مما يجعل قدرًا كبيرًا من التحسيناتفي معدل الخطأ 0.01 أو أقل. بالطبع، عندما تكون معدلات الخطأ أقرب بكثير لـ 0، فإن تحسين 0.01 يمكن أن يكون بالفعل مشكلة كبيرة.

إحدى السمات المزعجة لتحليلنا حتى الآن هي أنه يخبرنا فقط عن التقارب asymptotics، أي كيف تتطور العلاقة بين $\epsilon_{\mathcal{D}}$ و ϵ تتطور كحجم العينة وتذهب إلى ما لا نهاية. لحسن الحظ، نظرًا لأن متغيرنا العشوائي محدود، يمكننا الحصول على حدود عينة محدودة صالحة من خلال تطبيق متباينة طبقاً لـ Hoeffding (1963):

$$P(\epsilon_{\mathcal{D}}(f) - \epsilon(f) \geq t) < \exp(-2nt^2).$$

إن حل أصغر حجم لمجموعة بيانات من شأنه أن يسمح لنا بالاستنتاج بثقة 95٪ أن المسافة t بين تقديرنا $\epsilon_{\mathcal{D}}(f)$ ومعدل الخطأ الحقيقي $\epsilon(f)$ لا تتجاوز 0.01، ستجد أن الأمثلة 15000 تقريبًا مطلوبة مقارنة بالأمثلة 10000 التي اقترحها التحليل المقارب أعلاه. إذا تعمقتفي الإحصائيات ستجد أن هذا الاتجاه ثابت بشكل عام. عادةً ما تكون الضمانات التي يتم الاحتفاظ بها حتىفي العينات المحدودة أكثر تحفظًا قليلاً. لاحظ أنهفي مخطط الأشياء، هذه الأرقام ليست متباعدة كثيرًا، مما يعكس الفائدة العامة للتحليل المقارب لإعطائنا أرقام الملعب حتى لو لم يكن هناك ضمانات يمكننا تقديمها إلى المحكمة.

4.6.2. إعادة استخدام مجموعة الاختبار Test Set Reuse

بمعنى ما، أنت الآن جاهز للنجاحفي إجراء بحث تجريبي للتعلم الآلي. تم تطوير جميع النماذج العملية تقريبًا والتحقق من صحتها بناءً على أداء مجموعة الاختبار وأنت الآن خبيرفي مجموعة الاختبار. بالنسبة لأي مصنف ثابت f، فأنت تعلم تقييم خطأ الاختبار $\epsilon_{\mathcal{D}}(f)$ الخاص به، ومعرفة ما يمكن (وما لا يمكن) قوله بشأن الخطأ السكاني $\epsilon(f)$ الخاص به.

فلنفترض أنك تأخذ هذه المعرفة وتستعد لتدريب نموذجك الأول f_1. بمعرفة مدى الثقة التي تحتاجها لتكون على ثقة من أداء معدل الخطأ الخاص بالمصنف، يمكنك تطبيق تحليلنا أعلاه لتحديد عدد مناسب من الأمثلة لتخصيصها لمجموعة الاختبار. علاوة على ذلك، لنفترض أنك أخذت الدروس من القسم 3.6 إلى القلب وتأكدت من الحفاظ على قدسية مجموعة الاختبار من خلال إجراء جميع تحليلك الأولي، وضبط المعلمة الفائقة، وحتى الاختيار من بين العديد من هياكل النماذج المتنافسة على مجموعة التحقق من الصحة. أخيرًا تقوم بتقييم النموذج f_1 الخاص بك على مجموعة الاختبار والإبلاغ عن تقدير غير متحيز unbiased estimate لخطأ السكان مع فاصل ثقة مرتبط.

حتى الآن يبدو أن كل شيء يسير على ما يرام. ومع ذلك،في تلك الليلة، تستيقظفي الثالثة صباحًا بفكرة رائعة لنهج جديد للنمذجة.في اليوم التالي، تقوم بترميز نموذجك الجديد f_2، وضبط المعلمات الفائقة الخاصة به على مجموعة التحقق من الصحة validation set، ولا تجعل نموذجك الجديد يعمل فحسب، بل يبدو أن معدل الخطأ فيه أقل بكثير من معدل الخطأ للنموذج الأول f_1. ومع ذلك، فإن إثارة الاكتشاف تتلاشى فجأة بينما تستعد للتقييم النهائي. ليس لديك مجموعة اختبار!

على الرغم من أن مجموعة الاختبار الأصلية $\mathcal{D}$ لا تزال موجودة على الخادم الخاص بك، فإنك تواجه الآن مشكلتين هائلتين. أولاً، عندما جمعت مجموعة الاختبار الخاصة بك، قمت بتحديد مستوى الدقة المطلوب على افتراض أنك كنت تقيم مصنفًا واحدًا f. ومع ذلك، إذا دخلتفي مجال تقييم المصنفات المتعددة $f_1, \ldots, f_k$في نفس مجموعة الاختبار، فيجب أن تفكرفي مشكلة الاكتشاف الخاطئ. من قبل، ربما كنت متأكدًا بنسبة 95٪ من أنه $\epsilon_{\mathcal{D}}(f) \in \epsilon(f) \pm 0.01$ بالنسبة لمصنف واحد f، وبالتالي فإن احتمال وجود نتيجة مضللة كان 5٪ فقط. مع وجود k من المصنفاتفي المزيج، قد يكون من الصعب ضمان عدم وجود حتى واحد منهم يكون أداء مجموعة الاختبار مضللاً. مع وجود 20 مصنفًا قيد الدراسة، قد لا يكون لديك أي سلطة على الإطلاق لاستبعاد احتمال حصول واحد منهم على الأقل على درجة مضللة. تتعلق هذه المشكلة باختبار الفرضيات المتعددة multiple hypothesis testing، والتي على الرغم من الأدبيات الكثيرةفي الإحصاء، لا تزال مشكلة مستمرة تعصف بالبحث العلمي.

إذا لم يكن ذلك كافيًا للقلق، فهناك سبب خاص لعدم الثقةفي النتائج التي تحصل عليهافي التقييمات اللاحقة. تذكر أن تحليلنا لأداء مجموعة الاختبار استند إلى افتراض أن المصنف قد تم اختياره بدون أي اتصال بمجموعة الاختبار، وبالتالي يمكننا عرض مجموعة الاختبار على أنها مستمدة عشوائيًا من السكان الأساسيين. هنا، لا تختبر دوال متعددة فحسب، بل تم اختيار الدالة اللاحقة f_2 بعد ملاحظة أداء مجموعة الاختبار لـ f_1. بمجرد تسرب المعلومات من مجموعة الاختبار إلى مصمم النماذج، لا يمكن أن تكون مجموعة اختبار حقيقية مرة أخرى بالمعنى الدقيق للكلمة. تسمى هذه المشكلة فرط التجهيز التكيفي adaptive overfitting، وقد ظهرت مؤخرًا كموضوع يثير اهتمامًا شديدًا لمنظري التعلم والإحصائيين (Dwork et al.، 2015). لحسن الحظ،في حين أنه من الممكن تسريب جميع المعلومات من مجموعة الانتظار holdout set، والسيناريوهات النظرية للأسوأ قاتمة، فقد تكون هذه التحليلات متحفظة للغاية. من الناحية العملية، احرص على إنشاء مجموعات اختبار حقيقية، واستشرها بشكل غير متكرر قدر الإمكان، ولمراعاة اختبار الفرضيات المتعددة عند الإبلاغ عن فترات الثقة، ولزيادة يقظتك بشكل أكثر قوة عندما تكون المخاطر عالية وحجم مجموعة البيانات الخاصة بك صغيرًا. عند تشغيل سلسلة من التحديات المعيارية، غالبًا ما يكون من الممارسات الجيدة الاحتفاظ بالعديد من مجموعات

الاختبار بحيث يمكن بعد كل جولة تخفيض مجموعة الاختبار القديمة إلى مجموعة التحقق من الصحة.

4.6.3. نظرية التعلم الإحصائي Statistical Learning Theory

في الحال، مجموعات الاختبار هي كل ما لدينا حقًا، ومع ذلك تبدو هذه الحقيقة غير مرضية بشكل غريب. أولاً، نادرًا ما نمتلك مجموعة اختبار حقيقية ــ ما لم نكن نحن من أنشأ مجموعة البيانات، فمن المحتمل أن شخصًا آخر قد قام بالفعل بتقييم المصنف الخاص به على "مجموعة الاختبار" المزعومة. وحتى عندما نحصل على الدرجات الأولى، سرعان ما نجد أنفسنا محبطين، ونتمنى أن نتمكن من تقييم محاولاتنا اللاحقةفي النمذجة دون الشعور بالضيق بأننا لا نستطيع الوثوق بأرقامنا. علاوة على ذلك، حتى مجموعة الاختبار الحقيقية يمكنها فقط أن تخبرنا لاحقًا عما إذا كان المصنف قد تعمم generalizedفي الواقع على السكان، وليس ما إذا كان لدينا أي سبب لتوقع مقدمًا أنه ينبغي تعميمه.

مع وضع هذه الهواجسفي الاعتبار، قد تكون الآن مستعدًا بشكل كاف لرؤية جاذبية نظرية التعلم الإحصائي statistical learning، الحقل الفرعي الرياضي للتعلم الآلي الذي يهدف ممارسوه إلى توضيح المبادئ الأساسية التي تشرح لماذا / متى يمكن للنماذج المدربة على البيانات التجريبية التعميم على بيانات غير مرئية unseen data. كان أحد الأهداف الأساسية لعدة عقود من الباحثينفي التعلم الإحصائي هو تقييد فجوة التعميم generalization gap، فيما يتعلق بخصائص فئة النموذج، وعدد العيناتفي مجموعة البيانات.

يهدف منظرو التعلم Learning theorists إلى ربط الفرق بين الخطأ التجريبي $\epsilon_S(f_S)$ للمصنف المتعلم f_S، سواء تم تدريبه أو تقييمه على مجموعة التدريب S، والخطأ الحقيقي لنفس المصنف على السكان الأساسيين. قد يبدو هذا مشابهًا لمشكلة التقييم التي تناولناها للتو ولكن هناك فرق كبير. من قبل، تم إصلاح المصنف وكنا بحاجة إلى مجموعة بيانات فقط لأغراض التقييم. وبالفعل، فإن أي مصنف ثابت f لا يعمم: خطأهفي مجموعة بيانات (غير مرئية سابقًا) هو تقدير غير متحيز لخطأ السكان. ولكن ماذا يمكننا أن نقول عندما يتم تدريب المصنف وتقييمه على نفس مجموعة البيانات؟ هل يمكننا أن نكون على ثقة من أن خطأ التدريب سيكون قريبًا من خطأ الاختبار؟

افترض أنه يجب اختيار المصنف f_S الذي تعلمناه من بين مجموعة دوال محددة مسبقًا $\mathcal{F}$. تذكر من مناقشتنا لمجموعات الاختبار أنهفي حين أنه من السهل تقدير خطأ مصنف واحد، فإن الأشياء تصبح صعبة عندما نبدأفي التفكيرفي مجموعات المصنفات. حتى إذا كان الخطأ التجريبي لأي مصنف واحد (ثابت) قريبًا من خطأه الحقيقي مع احتمال كبير، بمجرد أن نفكرفي مجموعة من المصنفات، نحتاج إلى القلق بشأن احتمال أن يتلقى مصنف واحد فقطفي المجموعة خطأً سيئًا

في التقدير خطأ. القلق هو أنه إذا تلقى مصنف واحد فقطفي مجموعتنا خطأ منخفضًا مضللًا، فقد نختاره وبالتالي نقلل بشكل كبير من الخطأ السكاني. علاوة على ذلك، حتى بالنسبة للنماذج الخطية، نظرًا لتقييم معلماتها باستمرار، فإننا نختار عادةً من بين فئة لا حصر لها من الدوال ($|\mathcal{F}| = \infty$).

يتمثل أحد الحلول الطموحة للمشكلةفي تطوير أدوات تحليلية لإثبات التقارب المنتظم uniform convergence، أي أنه مع وجود احتمال كبير، فإن معدل الخطأ التجريبي لكل مصنففي الفئة $f \in \mathcal{F}$ سوف يتقاربفي نفس الوقت مع معدل الخطأ الحقيقي. بعبارة أخرى، نسعى إلى مبدأ نظري من شأنه أن يسمح لنا أن نذكر أنه مع وجود احتمال على الأقل $1 - \delta$ (بالنسبة للبعض الصغير δ)، لن يتم تقدير معدل خطأ المصنف $\epsilon(f)$ (من بين جميع المصنفات في الفئة $\mathcal{F}$) بأكثر من مقدار ضئيل α. من الواضح أنه لا يمكننا إصدار مثل هذه العبارات لجميع فئات النموذج $\mathcal{F}$. تذكر فئة آلات الحفظ التي تحقق دائمًا خطأ تجريبيًا ولكنها لا تتفوق أبدًا على التخمين العشوائي على المجتمع الأساسي.

بمعنى أن طبقة الحفظ مرنة للغاية. لا يمكن لنتيجة تقارب موحدة كهذه أن تصمد. من ناحية أخرى، المصنف الثابت عديم الفائدة ـ فهو معمم تمامًا، لكنه لا يناسب بيانات التدريب ولا بيانات الاختبار. وهكذا تم تأطير السؤال المركزي للتعلم تاريخيًا كمقايضة بين فئات نموذج أكثر مرونة (تباين أعلى) تتلاءم بشكل أفضل مع بيانات التدريب ولكنها تنطوي على مخاطر أكثر من اللازم، مقابل فئات نموذجية أكثر صرامة (تحيز أعلى) تتعمم جيدًا ولكنها تنطوي على مخاطر غير مناسبة. كان السؤال المركزيفي نظرية التعلم هو تطوير التحليل الرياضي المناسب لتحديد مكان وجود نموذج على طول هذا الطيف، وتقديم الضمانات المرتبطة به.

في سلسلة من الأوراق البحثية الأساسية، وسع فابنيك وشيرفونينكيس نظرية تقارب الترددات النسبية إلى فئات دوال أكثر عمومية (Vapnik and Chervonenkis ، 1964 ، Vapnik and Chervonenkis ، 1968 ، Vapnik and Chervonenkis ، 1971 ، Vapnik and Chervonenkis ، 1981 ، Vapnik and Chervonenkis ، 1991، Vapnik and Chervonenkis، 1974). أحد المساهمات الرئيسية لهذا النوع من العمل هو بُعد Vapnik–Chervonenkis (VC)، والذي يقيس (فكرة واحدة عن) مدى تعقيد (المرونة) لفئة النموذج. علاوة على ذلك، فإن إحدى نتائجهم الرئيسية تحدد الفرق بين الخطأ التجريبي وخطأ السكان كدالة لبعد VC وعدد العينات:

$$P(R[p, f] - R_{\text{emp}}[\mathbf{X}, \mathbf{Y}, f] < \alpha) \geq 1 - \delta \text{ for } \alpha \geq c\sqrt{(\text{VC} - \log \delta)/n}.$$

$0 < \delta$ هو احتمال انتهاك الحد، وα هو الحد الأعلى لفجوة التعميم، وn هو حجم مجموعة البيانات. أخيرًا، $0 < c$ هو ثابت يعتمد فقط على حجم الخسارة التي يمكن تكبدها. قد يكون أحد استخدامات الحد هو توصيل القيم المرغوبة لـ δ و α وتحديد عدد العينات المراد جمعها. يحدد بُعد VC أكبر عدد من نقاط البيانات التي يمكننا تعيين أي تصنيف عشوائي (ثنائي) لها ولكل منها تجد نموذجًا f مافي الفئة يتوافق مع هذا التصنيف. على سبيل المثال، النماذج الخطية على المدخلات ذات الأبعاد لها أبعاد VC d. من السهل ملاحظة أن الخط يمكنه تعيين أي تصنيف ممكن لثلاث نقاطفي بعدين، ولكن ليس لأربع. لسوء الحظ، تميل النظرية إلى التشاؤم المفرط بالنسبة للنماذج الأكثر تعقيدًا والحصول على هذا الضمان يتطلب عادةً أمثلة أكثر بكثير مما هو مطلوب بالفعل لتحقيق معدل الخطأ المطلوب. لاحظ أيضًا أن تحديد فئة النموذج وδ . معدل الخطأ لدينا يتحلل مرة أخرى مع المعدل المعتاد $\mathcal{O}(1/\sqrt{n})$. يبدو من غير المحتمل أن نتمكن من القيام بعمل أفضل من حيث. ومع ذلك، نظرًا لأننا نغير فئة النموذج، يمكن أن يقدم بُعد VC صورة متشائمة لفجوة التعميم.

4.6.4. الملخص

الطريقة الأكثر مباشرة لتقييم النموذج هي الرجوع إلى مجموعة اختبار تتألف من بيانات غير مرئية من قبل. توفر تقييمات مجموعة الاختبار تقديرًا غير متحيز للخطأ الحقيقي وتتقارب مع المعدل المطلوب $\mathcal{O}(1/\sqrt{n})$ مع نمو مجموعة الاختبار. يمكننا تقديم فترات ثقة تقريبية بناءً على توزيعات مقاربة دقيقة أو فترات ثقة محدودة صالحة للعينة بناءً على ضمانات عينة محدودة (أكثر تحفظًا). إن تقييم مجموعة الاختباراتفي الواقع هو حجر الأساس لأبحاث التعلم الآلي الحديثة. ومع ذلك، نادرًا ما تكون مجموعات الاختبار مجموعات اختبار حقيقية (يستخدمها باحثون متعددون مرارًا وتكرارًا). بمجرد استخدام نفس مجموعة الاختبار لتقييم نماذج متعددة، قد يكون من الصعب التحكمفي الاكتشاف الخاطئ. هذا يمكن أن يسبب مشاكل ضخمة من الناحية النظرية. من الناحية العملية، تعتمد أهمية المشكلة على حجم مجموعات الانتظار المعنية وما إذا كانت تستخدم فقط لاختيار المعلمات الفائقة أو ما إذا كانت تقوم بتسريب المعلومات بشكل مباشر أكثر. ومع ذلك، فمن الممارسات الجيدة تنظيم مجموعات اختبار حقيقية (أو متعددة) وأن تكون متحفظًا قدر الإمكان بشأن عدد مرات استخدامها.

على أمل تقديم حل أكثر إرضاءً، طور منظرو التعلم الإحصائي طرقًا لضمان التقارب المنتظم على فئة النموذج. إذا اقترب خطأ تجريبي لكل نموذج بالفعل مع خطأه الحقيقيفي وقت واحد، فعندئذ لنا الحريةفي اختيار النموذج الأفضل أداءً، وتقليل خطأ التدريب، مع العلم أنه سيؤدي أيضًا أداءً جيدًا بالمثل على بيانات الانتظار. بشكل حاسم، يجب أن تعتمد أي من هذه النتائج على بعض خصائص فئة النموذج. قدم فلاديمير فابنيك وأليكسي تشيرنوفينكيس بُعد VC، وقدموا نتائج تقارب موحدة تنطبق على جميع الطرزفي فئة VC. إن أخطاء التدريب لجميع

النماذجفي الفصل مضمونة (في نفس الوقت) لتكون قريبة من أخطائهم الحقيقية، ومضمونة لتقترب من معدلاتها $\mathcal{O}(1/\sqrt{n})$. بعد الاكتشاف الثوري لبعد VC، تم اقتراح العديد من تدابير التعقيد البديلة، كل منها يسهل ضمان التعميم المماثل analogous generalization. انظر Boucheron et al. (2005) لمناقشة تفصيلية للعديد من الطرق المتقدمة لقياس تعقيد الدالة. لسوء الحظ، بينما أصبحت مقاييس التعقيد هذه أدوات مفيدة على نطاق واسعفي النظرية الإحصائية، فقد تبين أنها عاجزة (كما تم تطبيقها بشكل مباشر) لشرح سبب تعميم الشبكات العصبية العميقة. غالبًا ما تحتوي الشبكات العصبية العميقة على ملايين المعلمات (أو أكثر)، ويمكنها بسهولة تعيين تسميات عشوائية لمجموعات كبيرة من النقاط. ومع ذلك، فإنها تعمم جيدًا على المشكلات العملية، ومن المدهش أنها غالبًا ما تعمم بشكل أفضل، عندما تكون أكبر وأعمق، على الرغم من تكبدها أبعادًا أكبر لـ VC.في الفصل التالي، سوف نعيد النظرفي التعميمفي سياق التعلم العميق.

4.6.5. التمارين

1. إذا كنا نرغبفي تقدير الخطأ لنموذج ثابت f مع 0.0001 واحتمال أكبر من 99.9٪، فكم عدد العينات التي نحتاجها؟
2. افترض أن شخصًا آخر يمتلك مجموعة اختبار معنونة $\mathcal{D}$ ولا يوفر سوى المدخلات (الميزات) غير المسماة unlabeled. افترض الآن أنه لا يمكنك الوصول إلى تسميات مجموعة الاختبار إلا عن طريق تشغيل نموذج f (لا توجد قيود مفروضة على فئة النموذج) على كل من المدخلات غير المسماة وتلقي الخطأ المقابل $\epsilon_{\mathcal{D}}(f)$. كم عدد النماذج التي تحتاج إلى تقييمها قبل تسريب مجموعة الاختبار بأكملها وبالتالي قد يبدو أنها تحتوي على خطأ 0، بغض النظر عن خطأك الحقيقي؟
3. ما هو بُعد VC لفئة كثيرات الحدود من الدرجة الخامسة 5^{th} -order polynomials؟
4. ما هو بُعد VC للمستطيلات المحاذية للمحور axis-aligned rectangles في البيانات ثنائية الأبعاد؟

4.7 التحول البيئي والتوزيع Environment and Distribution Shift

في الأقسام السابقة، عملنا من خلال عدد من التطبيقات العملية للتعلم الآلي، ونلائم النماذج لمجموعة متنوعة من مجموعات البيانات. ومع ذلك، لم نتوقف أبدًا عن التفكيرفي مصدر البياناتفي المقام الأول أو ما نخطط لفعلهفي النهاية بمخرجات نماذجنا.في كثير من الأحيان، يندفع مطورو التعلم الآلي الذين يمتلكون البيانات لتطوير نماذج دون التوقف مؤقتًا للنظرفي هذه المشكلات الأساسية.

يمكن إرجاع العديد من عمليات نشر التعلم الآلي الفاشلة إلى هذا النمط.في بعض الأحيان، يبدو أن النماذج تعمل بشكل رائع كما تم قياسها من خلال دقة مجموعة الاختبار ولكنها تفشل بشكل كارثيفي النشر عندما يتغير توزيع البيانات فجأة. بشكل أكثر مكرًا،في بعض الأحيان، يمكن أن يكون نشر نموذج ما هو العامل المحفز الذي يزعج توزيع البيانات. لنفترض، على سبيل المثال، أننا دربنا نموذجًا للتنبؤ بمن سيسدد مقابل التخلف عن سداد القرض، ووجدنا أن اختيار مقدم الطلب للأحذية كان مرتبطًا بمخاطر التخلف عن السداد (تشير أوكسفورد إلى السداد، وتشير الأحذية الرياضية إلى التقصير). قد نميل بعد ذلك إلى منح قروض لجميع المتقدمين الذين يرتدون أحذية أوكسفورد ورفض ارتداء جميع المتقدمين للأحذية الرياضية.

في هذه الحالة، قد يكون لقفزة غير مدروسة من التعرف على الأنماط إلى اتخاذ القرار وفشلنافي التفكير النقديفي البيئة عواقب وخيمة. بالنسبة للمبتدئين، بمجرد أن بدأنافي اتخاذ القرارات بناءً على الأحذية، سيتعرف العملاء على سلوكهم ويغيرونه. قبل مضي وقت طويل، كان جميع المتقدمين يرتدون أحذية أوكسفورد، دون أي تحسن متزامنفي الجدارة الائتمانية. يستغرق الأمر دقيقة لاستيعاب هذا لأن مشكلات مماثلة تكثرفي العديد من تطبيقات التعلم الآلي: من خلال تقديم قراراتنا المستندة إلى النموذج للبيئة، قد نكسر النموذج.

بينما لا يمكننا إعطاء هذه الموضوعات معالجة كاملةفي قسم واحد، فإننا نهدف هنا إلى الكشف عن بعض الاهتمامات المشتركة، وتحفيز التفكير النقدي المطلوب لاكتشاف هذه المواقف مبكرًا، وتخفيف الضرر، واستخدام التعلم الآلي بمسؤولية. بعض الحلول بسيطة (اسأل عن البيانات "الصحيحة")، وبعضها صعب تقنيًا (تنفيذ نظام التعلم المعزز reinforcement learning system)، والبعض الآخر يتطلب أن نتخطى مجال التنبؤ الإحصائي تمامًا ونكافح الأسئلة الفلسفية الصعبة المتعلقة بالأخلاق. تطبيق الخوارزميات.

4.7.1. أنواع تحول التوزيع Types of Distribution Shift

للبدء، نتمسك بإعداد التنبؤ السلبي مع الأخذفي الاعتبار الطرق المختلفة التي قد تتغير بها توزيعات البيانات وما يمكن فعله لإنقاذ أداء النموذج.في أحد الإعدادات الكلاسيكية، نفترض أنه تم أخذ عينات من بيانات التدريب الخاصة بنا من بعض التوزيعات $p_S(\mathbf{x}, y)$ ولكن بيانات الاختبار الخاصة بنا ستتألف من أمثلة غير مسماة مأخوذة من توزيع مختلف $p_T(\mathbf{x}, y)$. بالفعل، يجب أن نواجه حقيقة واقعية.في غياب أي افتراضات حول كيفية ارتباط p_Sو p_T ببعضها البعض، فإن تعلم مصنف قوي أمر مستحيل.

النظرفي مشكلة التصنيف الثنائي binary classification problem، حيث نرغبفي التمييز بين الكلاب والقطط. إذا كان التوزيع يمكن أن يتغير بطرق عشوائية، فإن إعدادنا يسمح بالحالة المرضية التي يظل فيها التوزيع على المدخلات ثابتًا: $p_S(\mathbf{x}) = p_T(\mathbf{x})$ ولكن جميع التسميات

مقلوبة: $p_S(y \mid \mathbf{x}) = 1 - p_T(y \mid \mathbf{x})$. بعبارة أخرى، إذا استطاع الله أن يقرر فجأة أن كل "القطط" أصبحت الآن كلابًا وأن ما نطلق عليه سابقًا "كلاب" أصبح الآن قططًا ـ دون أي تغيير في توزيع المدخلات $p(\mathbf{x})$ ، فلا يمكننا تمييز هذا الإعداد عن واحد التي لم يتغير فيها التوزيع على الإطلاق.

لحسن الحظ،في ظل بعض الافتراضات المقيدة حول الطرق التي قد تتغير بها بياناتنافي المستقبل، يمكن للخوارزميات المبدئية أن تكتشف التحول shift وأحيانًا تتكيف بشكل سريع، مما يحسن دقة المصنف الأصلي.

4.7.1.1. التحول المتغير Covariate Shift

من بين فئات تحول التوزيع distribution shift، قد يكون التحول المتغير covariate shift هو الأكثر دراسة على نطاق واسع. هنا، نفترض أنه بينما قد يتغير توزيع المدخلات بمرور الوقت، فإن دالة وضع العلامات (التسميات)، أي التوزيع الشرطي $P(y \mid \mathbf{x})$ لا تتغير. يسمي الإحصائيون هذا التحول المتغير covariate shift لأن المشكلة تنشأ بسبب تحولفي توزيع المتغيرات المشتركة (الميزات). بينما يمكننا أحيانًا التفكيرفي تحول التوزيع دون التذرع بالسببية، نلاحظ أن التحول المتغير هو الافتراض الطبيعي الذي يجب استدعاؤهفي الإعدادات التي نعتقد فيها أن x تسبب y .

ضعفي اعتبارك التحدي المتمثلفي التمييز بين القطط والكلاب. قد تتكون بيانات التدريب الخاصة بنا من صور من النوع الموضحفي الشكل 4.7.1.

الشكل 4.7.1 بيانات التدريب للتمييز بين القطط والكلاب.

يطلب منافي وقت الاختبار تصنيف الصورفي الشكل 4.7.2.

الشكل 4.7.2 بيانات الاختبار للتمييز بين القطط والكلاب.

تتكون مجموعة التدريب من صور photos، بينما تحتوي مجموعة الاختبار على رسوم متحركة cartoons فقط. يمكن أن يؤدي التدريب على مجموعة بيانات ذات خصائص مختلفة إلى حد كبير عن مجموعة الاختبار إلى حدوث مشكلةفي غياب خطة متماسكة لكيفية التكيف مع المجال الجديد.

4.7.1.2. تحول التسمية Label Shift

يصف تحول التسمية Label Shift المشكلة العكسية converse problem. هنا، نفترض أن التسمية الهامشية $P(y)$ يمكن أن تتغير ولكن التوزيع الشرطي للفئة $P(\mathbf{x} \mid y)$ يظل ثابتًا عبر المجالات. إن تحول التسمية هو افتراض معقول يجب القيام به عندما نعتقد أن هذه y تسبب x. على سبيل المثال، قد نرغبفي التنبؤ بالتشخيصاتفي ضوء أعراضها (أو غيرها من المظاهر)، حتى مع تغير الانتشار النسبي للتشخيصات بمرور الوقت. تحول التسمية هو الافتراض المناسب هنا لأن الأمراض تسبب الأعراض.في بعض الحالات المتدهورة، يمكن أن يحدث تحول التسمية وافتراضات التحول المتغيرفي وقت واحد. على سبيل المثال، عندما تكون التسمية حتمية، سيتم استيفاء افتراض التحول المتغير، حتى عندما تكون y تسبب x. ومن المثير للاهتمام،في هذه الحالات، أنه غالبًا ما يكون من المفيد العمل بالطرق التي تتدفق من افتراض تحول التسمية. وذلك لأن هذه الأساليب تميل إلى التعامل مع الكائنات التي تبدو وكأنها تسميات (غالبًا ما تكون منخفضة الأبعاد)، على عكس الكائنات التي تشبه المدخلات، والتي تميل إلى أن تكون عالية الأبعادفي التعلم العميق.

4.7.1.3. تحول المفهوم Concept Shift

قد نواجه أيضًا مشكلة تحول Concept Shift المفهوم ذات الصلة، والتي تنشأ عندما تتغير تعريفات التسميات ذاتها. هذا يبدو غريبًا ــ القطة قطة، أليس كذلك؟ ومع ذلك، تخضع الفئات الأخرى للتغييراتفي الاستخدام بمرور الوقت. تخضع المعايير التشخيصية للمرض العقلي، والمسميات العصرية، والوظائف، لقدر كبير من تغيير المفهوم. اتضح أننا إذا تجولنافي جميع أنحاء الولايات المتحدة، وقمنا بتغيير مصدر بياناتنا حسب المنطقة الجغرافية، فسنجد تحولًا كبيرًافي المفهوم فيما يتعلق بتوزيع أسماء المشروبات الغازية كما هو موضحفي الشكل 4.7.3.

إذا أردنا بناء نظام ترجمة آلية machine translation system، فقد يختلف التوزيع $P(y \mid \mathbf{x})$ حسب موقعنا. قد يكون من الصعب اكتشاف هذه المشكلة. قد نأملفي استغلال المعرفة التي لا تحدث إلا بشكل تدريجي إما بالمعنى الزمني أو الجغرافي.

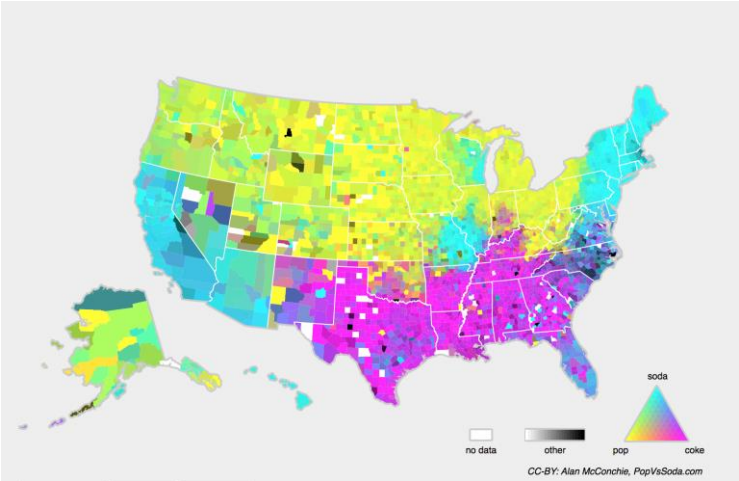

الشكل 4.7.3 تحول المفهومفي أسماء المشروبات الغازيةفي الولايات المتحدة.

4.7.2. أمثلة على تحول التوزيع Examples of Distribution Shift

قبل الخوضفي الشكليات والخوارزميات، يمكننا مناقشة بعض المواقف الملموسة التي قد لا يكون فيها المتغير المشترك أو تحول المفهوم واضحًا.

4.7.2.1. التشخيصات الطبية Medical Diagnostics

تخيل أنك تريد تصميم خوارزمية لاكتشاف السرطان. تقوم بجمع البيانات من الأشخاص الأصحاء والمرضى وتقوم بتدريب الخوارزمية الخاصة بك. إنه يعمل بشكل جيد، مما يمنحك دقة عالية وتخلص إلى أنك مستعد لمهنة ناجحةفي التشخيص الطبي. ليس بهذه السرعة.

قد تختلف التوزيعات التي أدت إلى بيانات التدريب وتلك التي ستواجههافي البرية اختلافًا كبيرًا. حدث هذا لشركة ناشئة مؤسفة عمل معها بعضنا (المؤلفون) منذ سنوات. كانوا يطورون اختبارًا للدم لمرض يصيبفي الغالب كبار السن من الرجال ويأملونفي دراسته باستخدام عينات الدم التي جمعوها من المرضى. ومع ذلك، فإن الحصول على عينات دم من الرجال الأصحاء أكثر صعوبة بكثير من المرضى الموجودين بالفعلفي النظام. للتعويض، طلبت الشركة الناشئة التبرع بالدم من الطلابفي الحرم الجامعي لتكون بمثابة ضوابط صحيةفي تطوير اختباراتهم. ثم سألوا عما إذا كان بإمكاننا مساعدتهمفي بناء مصنف لاكتشاف المرض.

كما أوضحنا لهم، سيكون من السهل بالفعل التمييز بين الأفواج الصحية والمريضة بدقة شبه كاملة. ومع ذلك، هذا لأن الأشخاص الخاضعين للاختبار اختلفوافي العمر ومستويات الهرمونات والنشاط البدني والنظام الغذائي واستهلاك الكحول والعديد من العوامل الأخرى غير المرتبطة

بالمرض. لم يكن هذا هو الحال مع المرضى الحقيقيين. نظرًا لإجراءات أخذ العينات الخاصة بهم، يمكننا أن نتوقع مواجهة تحول متغير شديد. علاوة على ذلك، من غير المحتمل أن تكون هذه الحالة قابلة للتصحيح بالطرق التقليدية. باختصار، لقد أهدروا مبلغًا كبيرًا من المال.

4.7.2.2. السيارات ذاتية القيادة Self-Driving Cars

لنفترض أن شركة ما أرادت الاستفادة من التعلم الآلي لتطوير سيارات ذاتية القيادة. أحد المكونات الرئيسية هنا هو جهاز الكشف roadside detector على جانب الطريق. نظرًا لأن الحصول على البيانات المشروحة الحقيقية باهظ التكلفة، فقد كانت لديهم فكرة (ذكية ومشكوك فيها) لاستخدام البيانات التركيبية synthetic data من محرك عرض الألعاب كبيانات تدريب إضافية. لقد نجح هذا الأمر جيدًافي "بيانات الاختبار" المستمدة من محرك العرض. للأسف، داخل سيارة حقيقية كانت كارثة. كما اتضح، تم تقديم جانب الطريق بنسيج بسيط للغاية. والأهم من ذلك، أن كل جوانب الطريق قد تم تقديمها بنفس الملمس وتعرف كاشف جانب الطريق على هذه "الميزة" بسرعة كبيرة.

حدث شيء مشابه للجيش الأمريكي عندما حاولوا اكتشاف الدباباتفي الغابة لأول مرة. التقطوا صورًا جوية للغابة بدون دبابات، ثم قادوا الدبابات إلى الغابة والتقطوا مجموعة أخرى من الصور. يبدو أن المصنف يعمل بشكل مثالي. لسوء الحظ، فقد تعلمت فقط كيفية التمييز بين الأشجار ذات الظلال من الأشجار التي ليس لها ظلال ــ تم التقاط المجموعة الأولى من الصورفي الصباح الباكر، والمجموعة الثانية عند الظهر.

4.7.2.3. التوزيعات غير الثابتة Nonstationary Distributions

ينشأ موقف أكثر دقة عندما يتغير التوزيع ببطء (يُعرف أيضًا بالتوزيع غير الثابت) ولا يتم تحديث النموذج بشكل كافٍ. فيما يلي بعض الحالات النموذجية.

- نقوم بتدريب نموذج إعلان حسابي ثم نفشلفي تحديثه بشكل متكرر (على سبيل المثال، ننسى أن ندمج جهازًا جديدًا غامضًا يسمى iPad تم إطلاقه للتو).
- نحن نبني عامل تصفية البريد العشوائي spam filter. إنه يعمل جيدًافي اكتشاف جميع الرسائل غير المرغوب فيها التي رأيناها حتى الآن. ولكن بعد ذلك، يستيقظ مرسلو البريد العشوائي ويصنعون رسائل جديدة تبدو مختلفة عن أي شيء رأيناه من قبل.
- نحن نبني نظام توصية المنتج product recommendation system. إنه يعمل طوال فصل الشتاء ولكنه يستمر بعد ذلكفي التوصية بقبعات سانتا لفترة طويلة بعد عيد الميلاد.

4.7.2.4. المزيد من الحكايات More Anecdotes

- نبني جهاز كشف الوجه face detector. يعمل بشكل جيد على جميع المعايير. لسوء الحظ، فشلفي بيانات الاختبار ــ الأمثلة المخالفة هي لقطات قريبة حيث يملأ الوجه الصورة بأكملها (لم تكن مثل هذه البيانات موجودةفي مجموعة التدريب).
- نحن نبني محرك بحث على شبكة الإنترنت لسوق الولايات المتحدة ونريد نشرهفي المملكة المتحدة.
- نقوم بتدريب مصنف الصور عن طريق تجميع مجموعة بيانات كبيرة حيث يتم تمثيل كل مجموعة من مجموعة كبيرة من الفئات بالتساويفي مجموعة البيانات، لنقل 1000 فئة، ممثلة بـ 1000 صورة لكل منها. ثم ننشر النظامفي العالم الحقيقي، حيث يكون التوزيع الفعلي للتسميات للصور الفوتوغرافية غير منتظم بالتأكيد.

4.7.3. تصحيح تحول التوزيع Correction of Distribution Shift

كما ناقشنا، هناك العديد من الحالات التي يختلف فيها توزيع التدريب والاختبار $P(\mathbf{x}, y)$.في بعض الحالات، نكون محظوظين وتعمل النماذج على الرغم من تغيير المتغير أو التسمية أو المفهوم.في حالات أخرى، يمكننا أن نفعل ما هو أفضل من خلال استخدام استراتيجيات قائمة على المبادئ للتعامل مع هذا التحول. ينمو الجزء المتبقي من هذا القسم بدرجة أكبر من الناحية الفنية. يمكن للقارئ الذي نفد صبره المتابعة إلى القسم التالي لأن هذه المادة ليست شرطًا أساسيًا للمفاهيم اللاحقة.

4.7.3.1. الخطر التجريبية والخطر Empirical Risk and Risk

دعنا نفكر أولاً فيما يحدث بالضبط أثناء تدريب النموذج: نحن نكرر الميزات والتسميات المرتبطة ببيانات التدريب $\{(\mathbf{x}_1, y_1), \ldots, (\mathbf{x}_n, y_n)\}$ ونحدِّث معلمات النموذج f بعد كل دفعات صغيرة. من أجل التبسيط، لا نفكرفي التنظيم regularization، لذلك فإننا نقلل إلى حد كبير الخطأفي التدريب:

$$\underset{f}{\text{minimize}} \frac{1}{n}\sum_{i=1}^{n} l(f(\mathbf{x}_i), y_i),$$

حيث l هي دالة الخطأ التي تقيس "مدى سوء" التنبؤ $f(\mathbf{x}_i)$ الذي يُعطى التسمية المرتبطة به y_i. يسمي الإحصائيون المصطلحفي (4.7.1) الخطر التجريبية empirical risk. الخطر التجريبي هو متوسط الخطأ على بيانات التدريب لتقريب الخطر، وهو توقع الخسارة على مجموعة البيانات بأكملها المستمدة من توزيعها الحقيقي $p(\mathbf{x}, y)$:

$$E_{p(\mathbf{x},y)}[l(f(\mathbf{x}), y)] = \int\int l(f(\mathbf{x}), y)p(\mathbf{x}, y)d\mathbf{x}dy.$$

ومع ذلك، من الناحية العملية، لا يمكننا عادةً الحصول على مجموعة البيانات بالكامل. وبالتالي، فإن تقليل الخطر التجريبي empirical risk minimization، والذي يقلل من المخاطر التجريبيةفي (4.7.1)، هو استراتيجية عملية للتعلم الآلي، على أمل التقريب من تقليل المخاطر.

4.7.3.2. تصحيح التحول المتغير Covariate Shift Correction

افترض أننا نريد تقدير بعض التبعية $P(y \mid \mathbf{x})$ التي قمنا بتسمية البيانات $(\mathbf{x}_i, y_i)$ الخاصة بها. لسوء الحظ، يتم استخلاص الملاحظات $\mathbf{x}_i$ من توزيع بعض المصادر بدلاً من التوزيع المستهدف. لحسن الحظ، فإن افتراض التبعية يعني أن التوزيع المشروط لا يتغير: $p(y \mid \mathbf{x}) = q(y \mid \mathbf{x})$. إذا كان توزيع المصدر $q(\mathbf{x})$ "خاطئًا"، فيمكننا تصحيح ذلك باستخدام الهوية البسيطة التاليةفي المخاطرة:

$$\int \int l(f(\mathbf{x}), y)p(y \mid \mathbf{x})p(\mathbf{x})d\mathbf{x}dy = \int \int l(f(\mathbf{x}), y)q(y \mid \mathbf{x})q(\mathbf{x})\frac{p(\mathbf{x})}{q(\mathbf{x})}d\mathbf{x}dy.$$

بعبارة أخرى، نحتاج إلى إعادة وزن reweigh كل مثال من البيانات بنسبة احتمالية استخلاصه من التوزيع الصحيح إلى التوزيع الخطأ:

$$\beta_i \stackrel{\text{def}}{=} \frac{p(\mathbf{x}_i)}{q(\mathbf{x}_i)}.$$

بتوصيل الوزن β_i لكل مثال بيانات $(\mathbf{x}_i, y_i)$ يمكننا تدريب نموذجنا باستخدام تقليل المخاطر التجريبية الموزونة weighted empirical risk minimization:

$$\underset{f}{\text{minimize}} \frac{1}{n}\sum_{i=1}^{n} \beta_i l(f(\mathbf{x}_i), y_i).$$

للأسف، لا نعرف هذه النسبة، لذا قبل أن نتمكن من فعل أي شيء مفيد نحتاج إلى تقديرها. تتوفر العديد من الطرق، بمافي ذلك بعض الأساليب النظرية المشغلة التي تحاول إعادة معايرة عامل التوقع مباشرة باستخدام الحد الأدنى من المعايير أو الحد الأقصى لمبدأ الانتروبيا. لاحظ أنه لأي نهج من هذا القبيل، نحتاج إلى عينات مأخوذة من كلا التوزيعين - "صحيح" p، على سبيل المثال، من خلال الوصول إلى بيانات الاختبار، وتلك المستخدمة لإنشاء مجموعة التدريب q (الأخير متاح بشكل ضئيل). لاحظ مع ذلك، أننا نحتاج فقط إلى ميزات $\mathbf{x} \sim p(\mathbf{x})$؛ لا نحتاج للوصول إلى التسميات $y \sim p(y)$.

في هذه الحالة، يوجد نهج فعال للغاية سيعطي نتائج جيدة تقريبًا مثل الأصل: الانحدار اللوجستي logistic regression، وهو حالة خاصة من انحدار softmax (انظر القسم 4.1) للتصنيف الثنائي. هذا هو كل ما هو مطلوب لحساب نسب الاحتمال المقدرة. نتعلم المصنف للتمييز بين

البيانات المستمدة من $p(\mathbf{x})$ والبيانات المستمدة من $q(\mathbf{x})$. إذا كان من المستحيل التمييز بين التوزيعين، فهذا يعني أن الحالات المرتبطة من المرجح أن تأتي من أحد التوزيعين. من ناحية أخرى، فإن أي حالات يمكن تمييزها بشكل جيد يجب أن يكون لها وزن زائد أو ناقص بشكل كبير وفقًا لذلك.

من أجل التبسيط، افترض أن لدينا عددًا متساويًا من المثيلات من كلا التوزيعين $p(\mathbf{x})$ و$q(\mathbf{x})$ على التوالي. قم الآن بالإشارة إلى التسميات z الى 1 للبيانات المستمدة من p للبيانات المستمدة من q. ثم يتم إعطاء الاحتمالفي مجموعة بيانات مختلطة بواسطة

$$P(z = 1 \mid \mathbf{x}) = \frac{p(\mathbf{x})}{p(\mathbf{x}) + q(\mathbf{x})} \text{ and hence } \frac{P(z = 1 \mid \mathbf{x})}{P(z = -1 \mid \mathbf{x})} = \frac{p(\mathbf{x})}{q(\mathbf{x})}.$$

وبالتالي، إذا استخدمنا نهج الانحدار اللوجستي، حيث $P(z = 1 \mid \mathbf{x}) = \frac{1}{1+\exp(-h(\mathbf{x}))}$ h هي دالة ذات معلمات)، يتبع ذلك

$$\beta_i = \frac{1/(1 + \exp(-h(\mathbf{x}_i)))}{\exp(-h(\mathbf{x}_i))/(1 + \exp(-h(\mathbf{x}_i)))} = \exp(h(\mathbf{x}_i)).$$

نتيجة لذلك، نحتاج إلى حل مشكلتين: الأولى للتمييز بين البيانات المستمدة من كلا التوزيعين، ثم مشكلة تقليل المخاطر التجريبية الموزونةفي (4.7.5) حيث نزن المصطلحات حسب β_i.

الآن نحن جاهزون لوصف خوارزمية التصحيح. افترض أن لدينا مجموعة تدريب $\{(\mathbf{x}_1, y_1), \ldots, (\mathbf{x}_n, y_n)\}$ ومجموعة اختبار غير مسماة $\{\mathbf{u}_1, \ldots, \mathbf{u}_m\}$. بالنسبة إلى تحول المتغير covariate shift، نفترض أن يتم استخلاص $\mathbf{x}_i$ لكل من $1 \leq i \leq n$ بعض توزيعات المصدر و$\mathbf{u}_i$ لكل $1 \leq i \leq m$ مستمدون من التوزيع المستهدف. فيما يلي خوارزمية نموذجية لتصحيح التحول المتغير:

1. إنشاء مجموعة تدريب التصنيف الثنائي:

$$\{(\mathbf{x}_1, -1), \ldots, (\mathbf{x}_n, -1), (\mathbf{u}_1, 1), \ldots, (\mathbf{u}_m, 1)\}.$$

2. تدريب مصنف ثنائي باستخدام الانحدار اللوجستي للحصول على دالة h.
3. وزن بيانات التدريب باستخدام $\beta_i = \exp(h(\mathbf{x}_i))$ أو أفضل $\beta_i = min(\exp(h(\mathbf{x}_i)), c)$ لبعض ثابت c.
4. استخدام الأوزان β_i للتدريب على $\{(\mathbf{x}_1, y_1), \ldots, (\mathbf{x}_n, y_n)\}$في (4.7.5).

لاحظ أن الخوارزمية أعلاه تعتمد على افتراض حاسم. لكي يعمل هذا المخطط، نحتاج إلى أن يكون لكل مثال بياناتفي الهدف (على سبيل المثال، وقت الاختبار) احتمالية غير صفرية

لحدوثهافي وقت التدريب. إذا وجدنا نقطة حيث $p(\mathbf{x}) > 0$ ولكن $q(\mathbf{x}) = 0$ ، فإن وزن الأهمية المقابل يجب أن يكون لانهائي.

4.7.3.3. تصحيح تحول التسمية Label Shift Correction

افترض أننا نتعامل مع مهمة تصنيف مع الفئات k. باستخدام نفس الترميزفي القسم 4.7.3.2، q و p هما توزيع المصدر (على سبيل المثال، وقت التدريب training time) والتوزيع المستهدف (على سبيل المثال، وقت الاختبار test time)، على التوالي. افترض أن توزيع التسميات يتغير بمرور الوقت:$q(y) \neq p(y)$ ، لكن التوزيع الشرطي للفئة يظل كما هو: $q(\mathbf{x} \mid y) = p(\mathbf{x} \mid y)$. إذا كان توزيع المصدر $q(y)$ "خاطئًا"، فيمكننا تصحيح ذلك وفقًا للهوية التاليةفي الخطر كما هو محددفي (4.7.2):

$$\int \int l(f(\mathbf{x}), y) p(\mathbf{x} \mid y) p(y) d\mathbf{x} dy = \int \int l(f(\mathbf{x}), y) q(\mathbf{x} \mid y) q(y) \frac{p(y)}{q(y)} d\mathbf{x} dy.$$

هنا، سوف تتوافق أوزان الأهمية الخاصة بنا مع نسب احتمالية التسمية

$$\beta_i \stackrel{\text{def}}{=} \frac{p(y_i)}{q(y_i)}.$$

أحد الأشياء اللطيفة حول تحول التسمية label shift هو أنه إذا كان لدينا نموذج جيد بشكل معقول لتوزيع المصدر، فيمكننا الحصول على تقديرات متسقة لهذه الأوزان دون الحاجة إلى التعامل مع البعد المحيط.في التعلم العميق، تميل المدخلات إلى أن تكون كائنات عالية الأبعاد مثل الصور،في حين أن التسميات غالبًا ما تكون كائنات أبسط مثل الفئات.

لتقدير توزيع التسمية المستهدف، نأخذ أولاً المصنف الجيد الجاهز لدينا (عادةً ما يتم تدريبه على بيانات التدريب) ونحسب مصفوفة الارتباك confusion matrix الخاصة به باستخدام مجموعة التحقق من الصحة (أيضًا من توزيع التدريب). مصفوفة الارتباك (confusion matrix) $\mathbf{C}$، هي مجرد مصفوفة، حيث يتوافق كل عمود مع فئة التسمية (الحقيقة الأساسية) ويتوافق كل صف مع الفئة المتوقعة لنموذجنا. تمثل قيمة كل خلية c_{ij} جزءًا من إجمالي التوقعات في مجموعة التحقق حيث كان التسمية الحقيقية كانت j وتوقع نموذجنا i.

الآن، لا يمكننا حساب مصفوفة الارتباك على البيانات الهدف مباشرةً، لأننا لا نرى تسميات الأمثلة التي نراهافي البرية، إلا إذا استثمرنافي خط أنابيب معقد للتعليقات التوضيحيةفي الوقت الفعلي. ومع ذلك، ما يمكننا القيام به هو متوسط جميع تنبؤاتنافي وقت الاختبار معًا، مما يؤدي إلى متوسط مخرجات النموذج $\hat{\mu}(\mathbf{y}) \in \mathbb{R}^k$ الذي i^{th}عنصر $\hat{\mu}(y_i)$ هو جزء من التوقعات الإجماليةفي مجموعة الاختبار حيث توقع نموذجنا.

اتضح أنهفي ظل بعض الظروف المعتدلة ــ إذا كان المصنف لدينا دقيقًا بشكل معقولفي المقام الأول، وإذا كانت البيانات المستهدفة تحتوي فقط على الفئات التي رأيناها من قبل، وإذا كان افتراض تحول التسمية ثابتًافي المقام الأول (أقوى افتراض هنا) ، ثم يمكننا تقدير توزيع تسمية مجموعة الاختبار عن طريق حل نظام خطي بسيط

$$\mathbf{C}p(\mathbf{y}) = \mu(\hat{\mathbf{y}}),$$

لأنه كتقدير $\sum_{j=1}^{k} c_{ij}p(y_j) = \mu(\hat{y}_i)$ يحمل لكل $1 \leq i \leq k$ ، حيث $p(y_j)$ هو j^{th}عنصر متجه توزيع التسمية ذي kأبعاد $p(\mathbf{y})$. إذا كان المصنف لدينا دقيقًا بما يكفي لتبدأ به، فستكون مصفوفة الارتباك $\mathbf{C}$ قابلة للعكس، وسنحصل على حل $p(\mathbf{y}) = \mathbf{C}^{-1}\mu(\hat{\mathbf{y}})$

نظرًا لأننا نلاحظ التسميات على بيانات المصدر، فمن السهل تقدير التوزيع $q(y)$. ثم بالنسبة لأي مثال تدريبي i مع التسمية y_i، يمكننا أن نأخذ النسبة المقدرة لدينا $p(y_i)/q(y_i)$ لحساب الوزن β_i، ونعوض هذافي تقليل المخاطر التجريبية الموزونةفي (4.7.5).

4.7.3.4. تصحيح تحول المفهوم Concept Shift Correction

من الصعب إصلاح تحول المفهوم بطريقة مبدئية. على سبيل المثال،في حالة تغيرت فيها المشكلة فجأة من تمييز القطط عن الكلاب إلى تمييز بين الحيوانات البيضاء والسوداء، سيكون من غير المعقول افتراض أنه يمكننا القيام بعمل أفضل بكثير من مجرد جمع تسميات جديدة والتدريب من نقطة الصفر. لحسن الحظ،في الممارسة العملية، مثل هذه التحولات المتطرفة نادرة. بدلاً من ذلك، ما يحدث عادةً هو أن المهمة تتغير ببطء. لجعل الأمور أكثر واقعية، إليك بعض الأمثلة:

- في الإعلانات الحاسوبية، يتم إطلاق منتجات جديدة، وتصبح المنتجات القديمة أقل شعبية. هذا يعني أن التوزيع على الإعلانات وشعبيتها يتغيران تدريجيًا وأي متنبئ بنسبة النقر إلى الظهور يجب أن يتغير تدريجيًا معه.
- تتدهور عدسات كاميرات المرور تدريجيًا بسبب التآكل البيئي، مما يؤثر على جودة الصورة بشكل تدريجي.
- يتغير محتوى الأخبار تدريجيًا (على سبيل المثال، تظل معظم الأخبار دون تغيير ولكن تظهر قصص جديدة).

في مثل هذه الحالات، يمكننا استخدام نفس النهج الذي استخدمناه لشبكات التدريب لجعلها تتكيف مع التغييرفي البيانات. بمعنى آخر، نستخدم أوزان الشبكة الحالية ونقوم ببساطة ببعض خطوات التحديث باستخدام البيانات الجديدة بدلاً من التدريب من البداية.

4.7.4. تصنيف مشاكل التعلم A Taxonomy of Learning Problems

مسلحين بالمعرفة حول كيفية التعامل مع التغييراتفي التوزيعات، يمكننا الآن النظرفي بعض الجوانب الأخرى لصياغة مشكلة التعلم الآلي.

4.7.4.1. التعلم الجماعي Batch Learning

في التعلم الجماعي Batch Learning، لدينا إمكانية الوصول إلى ميزات التدريب والتسميات $\{(\mathbf{x}_1, y_1), \ldots, (\mathbf{x}_n, y_n)\}$، والتي نستخدمها لتدريب نموذج $f(\mathbf{x})$.في وقت لاحق، قمنا بنشر هذا النموذج لتسجيل بيانات جديدة $(\mathbf{x}, y)$ مستمدة من نفس التوزيع. هذا هو الافتراض الافتراضي لأي من المشاكل التي نناقشها هنا. على سبيل المثال، قد نقوم بتدريب جهاز الكشف عن القطط بناءً على الكثير من صور القطط والكلاب. بمجرد أن نقوم بتدريبه، نقوم بشحنه كجزء من نظام الرؤية الحاسوبية الذكي الذي يسمح للقطط بالدخول. ثم يتم تثبيتهفي منزل العميل ولا يتم تحديثه مرة أخرى (باستثناء الظروف القصوى).

4.7.4.2. التعلم الاونلاين Online Learning

تخيل الآن أن البيانات $(\mathbf{x}_i, y_i)$ تصل عينة واحدةفي كل مرة. بشكل أكثر تحديدًا، افترض أننا نلاحظ $\mathbf{x}_i$ أولاً، ثم نحتاج إلى التوصل إلى تقدير $f(\mathbf{x}_i)$ وفقط بمجرد قيامنا بذلك، نلاحظه ونتلقى مكافأة أو نتحمل خسارة، نظرًا لقرارنا. تقع العديد من المشاكل الحقيقيةفي هذه الفئة. على سبيل المثال، نحتاج إلى توقع سعر سهم الغد، وهذا يسمح لنا بالتداول بناءً على هذا التقدير وفي نهاية اليوم نكتشف ما إذا كان تقديرنا يسمح لنا بتحقيق ربح. بعبارة أخرى،في التعلم الاونلاين Online Learning، لدينا الدورة التالية حيث نعمل باستمرار على تحسين نموذجنا في ضوء الملاحظات الجديدة.

$$\text{model } f_t \longrightarrow \text{data } \mathbf{x}_t \longrightarrow \text{estimate } f_t(\mathbf{x}_t) \longrightarrow \text{observation } y_t \longrightarrow \text{loss } l(y_t, f_t(\mathbf{x}_t)) \longrightarrow \text{model } f_{t+1}$$

4.7.4.3. Bandits

Bandits هي حالة خاصة للمشكلة المذكورة أعلاه. بينمافي معظم مشاكل التعلم لدينا دالة fذات معلمات باستمرار حيث نريد معرفة معلماتها (على سبيل المثال، شبكة عميقة)،في مشكلة Bandits لدينا فقط عدد محدود من الأسلحة التي يمكننا سحبها، أي عدد محدود من الإجراءات يمكننا أخذه. ليس من المستغرب جدًا أنه يمكن الحصول على ضمانات نظرية أقوى من حيث الأمثلية لهذه المشكلة الأبسط. ندرجها بشكل أساسي لأن هذه المشكلة غالبًا ما يتم التعامل معها (بشكل مربك) كما لو كانت بيئة تعليمية مميزة.

4.7.4.4. وحدات التحكم Control

في كثير من الحالات تتذكر البيئة ما فعلناه. ليس بالضرورة بطريقة عدائية ولكنها ستتذكر فقط وستعتمد الاستجابة على ما حدث من قبل. على سبيل المثال، ستلاحظ وحدة التحكمفي غلاية القهوة درجات حرارة مختلفة اعتمادًا على ما إذا كانت تسخن الغلاية مسبقًا. تعد خوارزميات وحدة التحكم PID (تناسبي تكاملي تفاضلي proportional–integral–derivative) خيارًا شائعًا هناك. وبالمثل، سيعتمد سلوك المستخدم على موقع الأخبار على ما أظهرناه له سابقًا (على سبيل المثال، سيقرأ معظم الأخبار مرة واحدة فقط). تشكل العديد من هذه الخوارزميات نموذجًا للبيئة التي تعمل فيها بحيث تجعل قراراتها تبدو أقل عشوائية.في الآونة الأخيرة، تم أيضًا استخدام نظرية التحكم (على سبيل المثال، متغيرات PID) لضبط المعلمات الفائقة تلقائيًا لتحقيق جودة أفضل لفك التشابك وإعادة البناء، وتحسين تنوع النص الذي تم إنشاؤه وجودة إعادة بناء الصور التي تم إنشاؤها (Shao et al.، 2020).

4.7.4.5. التعلم المعزز Reinforcement Learning

في الحالة العامة لبيئة ذات ذاكرة، قد نواجه مواقف تحاول فيها البيئة التعاون معنا (ألعاب تعاونية cooperative games، على وجه الخصوص للألعاب ذات المجموع غير الصفري non-zero-sum games)، أو حالات أخرى حيث ستحاول البيئة الفوز. الشطرنج أو Go أو Backgammon أو StarCraft هي بعض الحالاتفي التعلم المعزز Reinforcement Learning. وبالمثل، قد نرغبفي بناء وحدة تحكم جيدة للسيارات ذاتية القيادة. من المحتمل أن تستجيب السيارات الأخرى لأسلوب قيادة السيارة المستقلة بطرق غير بديهية، على سبيل المثال، محاولة تجنبها ومحاولة التسببفي وقوع حادث ومحاولة التعاون معها.

4.7.4.6. مراعاة البيئة Considering the Environment

أحد الفروق الرئيسية بين المواقف المختلفة المذكورة أعلاه هو أن نفس الإستراتيجية التي ربما نجحت طوال الوقتفي حالة البيئة الثابتة، قد لا تعمل طوال الوقت عندما تكون البيئة قادرة على التكيف. على سبيل المثال، من المرجح أن تختفي فرصة المراجحة arbitrage opportunity التي اكتشفها المتداول بمجرد أن يبدأفي استغلالها. تحدد السرعة والطريقة التي تتغير بها البيئة إلى حد كبير نوع الخوارزميات التي يمكننا استخدامها. على سبيل المثال، إذا علمنا أن الأشياء قد تتغير ببطء فقط، فيمكننا إجبار أي تقدير على التغيير ببطء فقط أيضًا. إذا علمنا أن البيئة قد تتغير على الفور، ولكن بشكل نادر جدًا، فيمكننا السماح بذلك. هذه الأنواع من المعرفة ضرورية لعالم البيانات الطموح للتعامل مع تحول المفهوم، أي عندما تكون المشكلة التي يحاول حلها مع مرور الوقت.

4.7.5. الإنصاف والمساءلة والشفافية في التعلم الآلي Fairness, Accountability, and Transparency in Machine Learning

أخيرًا، من المهم أن تتذكر أنه عند نشر أنظمة التعلم الآلي، فأنت لا تقوم فقط بتحسين نموذج تنبؤي ـ فأنت تقدم عادةً أداة ستُستخدم (جزئيًا أو كليًا) لأتمتة القرارات. يمكن أن تؤثر هذه الأنظمة التقنية على حياة الأفراد الخاضعين للقرارات الناتجة. لا تثير القفزة من التفكيرفي التنبؤات إلى القرارات أسئلة فنية جديدة فحسب، بل تثير أيضًا عددًا كبيرًا من الأسئلة الأخلاقية التي يجب مراعاتها بعناية. إذا كنا ننشر نظامًا تشخيصيًا طبيًا، فنحن بحاجة إلى معرفة الفئات السكانية التي قد يعمل بها وأيها قد لا يعمل. قد يؤدي التغاضي عن المخاطر المتوقعة على رفاهية مجموعة سكانية فرعية إلى تقديم رعاية أدنى. علاوة على ذلك، بمجرد التفكيرفي أنظمة صنع القرار، يجب أن نتراجع ونعيد النظرفي كيفية تقييمنا لتقنيتنا. من بين النتائج الأخرى لهذا التغيير في النطاق، سنجد أن الدقة نادراً ما تكون المقياس الصحيح. على سبيل المثال، عند ترجمة التنبؤات إلى أفعال، غالبًا ما نرغبفي مراعاة حساسية التكلفة المحتملة للخطأ بطرق مختلفة. إذا كان من الممكن النظر إلى إحدى طرق سوء تصنيف صورة ما على أنها خفة عرقية،في حين أن التصنيف الخاطئ إلى فئة مختلفة سيكون غير ضار، فقد نرغبفي تعديل عتباتنا وفقًا لذلك، مع مراعاة القيم المجتمعيةفي تصميم بروتوكول اتخاذ القرار. نريد أيضًا توخي الحذر بشأن الكيفية التي يمكن أن تؤدي بها أنظمة التنبؤ إلى حلقات التغذية الراجعة. على سبيل المثال، ضعفي اعتبارك أنظمة الشرطة التنبؤية predictive policing systems، التي تخصص ضباط الدورياتفي المناطق التي ترتفع فيها معدلات الجريمة المتوقعة. من السهل أن ترى كيف يمكن أن يظهر نمط مقلق:

1. الأحياء التي بها جرائم أكثر تحصل على المزيد من الدوريات.
2. وبالتالي، تم اكتشاف المزيد من الجرائمفي هذه الأحياء، وإدخال بيانات التدريب المتاحة للتكرارفي المستقبل.
3. يتعرض النموذج لمزيد من الإيجابيات، ويتوقع المزيد من الجرائمفي هذه الأحياء.
4. في التكرار التالي، يستهدف النموذج المحدث الحي نفسه بشكل أكبر مما يؤدي إلى اكتشاف المزيد من الجرائم، وما إلى ذلك.

في كثير من الأحيان، لا يتم احتساب الآليات المختلفة التي يتم من خلالها اقتران تنبؤات النموذج ببيانات التدريب الخاصة بهفي عملية النمذجة. يمكن أن يؤدي هذا إلى ما يسميه الباحثون حلقات التغذية الراجعة الجامحة runaway feedback loops. بالإضافة إلى ذلك، نريد توخي الحذر بشأن ما إذا كنا نعالج المشكلة الصحيحةفي المقام الأول. تلعب الخوارزميات التنبؤية الآن دورًا كبيرًافي التوسطفي نشر المعلومات. هل يجب أن يتم تحديد الأخبار التي يواجهها الفرد من خلال

مجموعة صفحات Facebook التي أعجبتهم؟ هذه مجرد أمثلة قليلة من بين العديد من المعضلات الأخلاقية الملحة التي قد تواجههافي مهنة تعلم الآلة.

4.7.6. الملخص

- في كثير من الحالات لا تأتي مجموعات التدريب والاختبار من نفس التوزيع. وهذا ما يسمى تحول التوزيع distribution shift.
- الخطر risk هو توقع الخسارة على مجموع البيانات المستمدة من توزيعها الحقيقي. ومع ذلك، عادة ما تكون هذه المجموعة بأكملها غير متوفرة. الخطر التجريبي Empirical risk هو متوسط الخسارة على بيانات التدريب لتقريب المخاطر.في الممارسة العملية، نقوم بتقليل المخاطر التجريبية empirical risk minimization.
- وفقًا للافتراضات المقابلة، يمكن اكتشاف تحول المتغير covariate shift وتحول التسمية label shift وتصحيحهمافي وقت الاختبار. يمكن أن يصبح الفشلفي تفسير هذا التحيز مشكلةفي وقت الاختبار.
- في بعض الحالات، قد تتذكر البيئة الإجراءات الآلية وتستجيب بطرق مفاجئة. يجب أن نأخذفي الحسبان هذا الاحتمال عند بناء النماذج والاستمرارفي مراقبة الأنظمة الحية، والانفتاح على احتمال أن تصبح نماذجنا والبيئة متشابكة بطرق غير متوقعة.

4.7.7. التمارين

1. ماذا يمكن أن يحدث عندما نغير سلوك محرك البحث؟ ماذا يمكن أن يفعل المستخدمون؟ ماذا عن المعلنين؟
2. نفذ كاشف التحول المتغير covariate shift detector. تلميح: بناء مصنف.
3. استخدم مصحح تحول المتغير covariate shift corrector.
4. إلى جانب تحول التوزيع distribution shift، ما الذي يمكن أن يؤثر أيضًا على كيفية تقريب المخاطر التجريبية للمخاطر؟

5

البيريبترون متعدد الطبقات

5. البيرسيبترون متعدد الطبقات Multilayer Perceptrons

في هذا الفصل، سوف نقدم لك أول شبكة عميقة حقًا. تُعرف أبسط الشبكات العميقة باسم البيرسيبترون متعدد الطبقات Multilayer Perceptrons، وهي تتكون من طبقات متعددة من الخلايا العصبية، كل منها مرتبطة تمامًا بتلك الموجودةفي الطبقة أدناه (التي تتلقى منها المدخلات) وتلك الموجودة أعلاه (والتي بدورها تؤثر عليها). على الرغم من أن التمايز التلقائي يبسط بشكل كبير تنفيذ خوارزميات التعلم العميق، إلا أننا سنتعمقفي كيفية حساب هذه التدرجات gradientsفي الشبكات العميقة. بعد ذلك سنكون مستعدين لمناقشة القضايا المتعلقة بالاستقرار العددي وتهيئة المعلمات التي تعتبر أساسية لتدريب الشبكات العميقة بنجاح. عندما نقوم بتدريب مثل هذه النماذج عالية السعة، فإننا نخاطر بالضبط الزائد overfitting. وبالتالي، سنعيد النظرفي التنظيم regularization والتعميم generalization للشبكات العميقة. طوال الوقت، نهدف إلى منحك فهمًا قويًا ليس فقط للمفاهيم ولكن أيضًا لممارسة استخدام الشبكات العميقة. في نهاية هذا الفصل، نطبق ما قدمناه حتى الآن على حالة حقيقية: التنبؤ بأسعار المنزل. نرسل الأمور المتعلقة بالأداء الحسابي وقابلية التوسع وكفاءة نماذجنا إلى الفصول اللاحقة.

5.1 البيرسيبترون متعدد الطبقات Multilayer Perceptrons

في القسم 4، قدمنا انحدار softmax (القسم 4.1)، وتنفيذ الخوارزمية من البداية (القسم 4.4) واستخدام واجهات برمجة التطبيقات APIs عالية المستوى (القسم 4.5). سمح لنا ذلك بتدريب المصنفات القادرة على التعرف على 10 فئات من الملابس من الصور منخفضة الدقة. على طول الطريق، تعلمنا كيفية تبديل البيانات wrangle data، وإجبار مخرجاتنا على توزيع احتمالي صالح، وتطبيق دالة خطأ مناسبة، وتقليلها فيما يتعلق بمعلمات نموذجنا. الآن وقد أتقننا هذه الميكانيكافي سياق النماذج الخطية البسيطة، يمكننا إطلاق استكشافنا للشبكات العصبية العميقة، فئة النماذج الغنية نسبيًا التي يهتم بها هذا الكتاب بشكل أساسي.

5.1.1. الطبقات المخفية Hidden Layers

وصفنا التحولات الأفينية affine transformationsفي القسم 3.1.1.1 كتحولات خطية مع تحيز إضافي. للبدء، تذكر بنية النموذج المقابلة لمثال انحدار softmax الموضحفي الشكل 4.1.1. يقوم هذا النموذج بتعيين المدخلات مباشرة إلى المخرجات عبر تحويل أفيني واحد، متبوعًا بعملية softmax. إذاكانت تسمياتنا مرتبطة حقًا ببيانات الإدخال عن طريق تحويل أفيني بسيط، فسيكون هذا النهج كافيًا. ومع ذلك، فإن الخطية (في التحولات الأفينية) هي افتراض قوي.

5.1.1.1. عيوب النماذج الخطية Limitations of Linear Models

على سبيل المثال، تشير الخطية linearity إلى الافتراض الأضعف للرتابة weaker assumption of monotonicity، أي أن أي زيادةفي ميزتنا يجب أن تتسبب دائمًافي زيادة ناتج نموذجنا (إذا كان الوزن المقابل موجبًا)، أو يتسبب دائمًافي انخفاض ناتج نموذجنا (إذا كان الوزن المقابل سلبي).في بعض الأحيان يكون هذا منطقيًا. على سبيل المثال، إذا كنا نحاول التنبؤ بما إذا كان الفرد سوف يسدد قرضًا، فقد نفترض بشكل معقول أن جميع الأشياء الأخرى متساوية، فمن المرجح دائمًا أن يسدد مقدم الطلب ذو الدخل المرتفع أكثر من الشخص ذي الدخل المنخفض.في حين أن هذه العلاقة رتيبة، من المحتمل ألا تكون مرتبطة خطيًا باحتمال السداد. من المحتمل أن تتوافق الزيادةفي الدخل من 0 دولار إلى 50000 دولار مع زيادة أكبرفي احتمالية السداد مقارنة بالزيادة من 1 مليون دولار إلى 1.05 مليون دولار. قد تكون إحدى طرق التعامل مع هذا هي المعالجة اللاحقة لنتائجنا بحيث تصبح الخطية أكثر منطقية، باستخدام الخريطة اللوجيستية logistic map (وبالتالي لوغاريتم احتمالية النتيجة).

لاحظ أنه يمكننا بسهولة التوصل إلى أمثلة تنتهك الرتابة monotonicity. قل على سبيل المثال أننا نريد التنبؤ بالصحة كدالةفي درجة حرارة الجسم. بالنسبة للأفراد الذين تزيد درجة حرارة الجسم عن 37 درجة مئوية (98.6 درجة فهرنهايت)، تشير درجات الحرارة المرتفعة إلى مخاطر أكبر. ومع ذلك، بالنسبة للأفراد الذين تقل درجة حرارة أجسامهم عن 37 درجة مئوية، فإن درجات الحرارة المنخفضة تشير إلى مخاطر أكبر! مرة أخرى، قد نحل المشكلة ببعض المعالجة المسبقة الذكية، مثل استخدام المسافة من 37 درجة مئوية كميزة.

ولكن ماذا عن تصنيف صور القطط والكلاب؟ هل يجب أن تؤدي زيادة كثافة البكسلفي الموقع (13، 17) دائمًا إلى زيادة (أو تقليل دائمًا) احتمالية أن الصورة تصور كلبًا؟ يتوافق الاعتماد على نموذج خطي مع الافتراض الضمني بأن المطلب الوحيد للتمييز بين القطط والكلاب هو تقييم سطوع وحدات البكسل الفردية. هذا النهج محكوم عليه بالفشلفي عالم يحافظ فيه عكس الصورة على الفئة.

ومع ذلك، على الرغم من العبث الواضح للخطية هنا، مقارنةً بأمثلتنا السابقة، فمن غير الواضح أنه يمكننا معالجة المشكلة بإصلاح بسيط للمعالجة المسبقة. وذلك لأن أهمية أي بكسل تعتمد بطرق معقدة على سياقها (قيم وحدات البكسل المحيطة).في حين أنه قد يكون هناك تمثيل لبياناتنا يأخذفي الاعتبار التفاعلات ذات الصلة بين ميزاتنا، وعلى رأسها سيكون النموذج الخطي مناسبًا، فنحن ببساطة لا نعرف كيفية حسابه يدويًا. مع الشبكات العصبية العميقة، استخدمنا بيانات المراقبة لتعلم بشكل مشترك كلا من التمثيل عبر الطبقات المخفية والمتنبئ الخطي الذي يعمل على هذا التمثيل.

تمت دراسة مشكلة اللاخطية nonlinearity هذه لمدة قرن على الأقل (Fisher، 1928). على سبيل المثال، تستخدم أشجار القرار decision trees في أبسط أشكالها سلسلة من القرارات الثنائية لاتخاذ قرار بشأن عضوية الفئة (Quinlan، 2014). وبالمثل، تم استخدام طرق النواة kernel methods لعقود عديدة لنمذجة التبعيات غير الخطية (Aronszajn، 1950). وقد وجد هذا طريقه، على سبيل المثال،في نماذج الخيوط اللامعلمية nonparametric spline models (Wahba، 1990) وطرق النواة (Schölkopf and Smola ، 2002). إنه أيضًا شيء يحله الدماغ بشكل طبيعي تمامًا. بعد كل شيء، تتغذى الخلايا العصبيةفي الخلايا العصبية الأخرى التي بدورها تغذي الخلايا العصبية الأخرى مرة أخرى (y Cajal and Azoulay، 1894). وبالتالي لدينا سلسلة من التحولات البسيطة نسبيًا.

5.1.1.2. دمج الطبقات المخفية Incorporating Hidden Layers

يمكننا التغلب على قيود النماذج الخطية من خلال دمج طبقة مخفية واحدة أو أكثر. أسهل طريقة للقيام بذلك هي تكديس العديد من الطبقات المتصلة بالكامل فوق بعضها البعض. تتغذى كل طبقةفي الطبقة التي فوقها، حتى ننتج النواتج. يمكننا أن نفكرفي الطبقات الأولى $L-1$ على أنها تمثيلنا والطبقة الأخيرة على أنها متنبئ خطي. يُطلق على هذه البنية عادةً اسم بيرسيبترون متعدد الطبقات Multilayer perceptron، وغالبًا ما يتم اختصاره باسم MLP (الشكل 5.1.1).

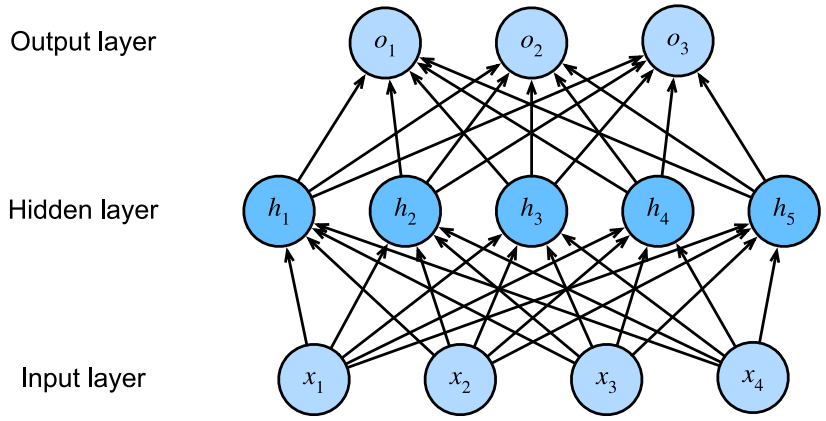

الشكل 5.1.1 MLP مع طبقة مخفية من 5 وحدات مخفية.

يحتوي MLP هذا على 4 مدخلات و3 مخرجات، وتحتوي طبقته المخفية على 5 وحدات مخفية. نظرًا لأن طبقة الإدخال input layer لا تتضمن أي حسابات، فإن إنتاج مخرجات بهذه الشبكة يتطلب تنفيذ الحسابات لكل من الطبقات المخفية والمخرجات؛ وبالتالي، فإن عدد

الطبقاتفي MLP هذا هو 2. لاحظ أن كلا الطبقتين متصلتان بالكامل fully connected. يؤثر كل إدخال على كل خلية عصبيةفي الطبقة المخفية hidden layer، ويؤثر كل منها بدوره على كل خلية عصبيةفي طبقة الإخراج output layer. للأسف، لم ننتهي بعد.

5.1.1.3. من الخطي إلى غير الخطي From Linear to Nonlinear

كما كان من قبل، نشير بواسطة المصفوفة $\mathbf{X} \in \mathbb{R}^{n \times d}$ إلى دفعة صغيرة من n من الأمثلة حيث يحتوي كل مثال على d مدخلات (ميزات). بالنسبة إلى MLP ذات الطبقة المخفية الواحدة والتي تحتوي طبقتها المخفية على h وحدات مخفية hidden units، فإننا نشير إلى مخرجات الطبقة المخفية $\mathbf{H} \in \mathbb{R}^{n \times h}$، والتي تمثل تمثيلات مخفية hidden representations. نظرًا لأن كلا من الطبقات المخفية والمخرجة متصلتان تمامًا fully connected، فلدينا أوزان وتحيزات طبقة مخفية $\mathbf{W}^{(1)} \in \mathbb{R}^{d \times h}$ و $\mathbf{b}^{(1)} \in \mathbb{R}^{1 \times h}$ على التوالي وأوزان وتحيزات طبقة المخرجات $\mathbf{W}^{(2)} \in \mathbb{R}^{h \times q}$ و $\mathbf{b}^{(2)} \in \mathbb{R}^{1 \times q}$ على التوالي. هذا يسمح لنا بحساب مخرجات MLP $\mathbf{O} \in \mathbb{R}^{n \times q}$ ذات الطبقة الواحدة المخفية على النحو التالي:

$$\begin{aligned} \mathbf{H} &= \mathbf{X}\mathbf{W}^{(1)} + \mathbf{b}^{(1)}, \\ \mathbf{O} &= \mathbf{H}\mathbf{W}^{(2)} + \mathbf{b}^{(2)}. \end{aligned}$$

لاحظ أنه بعد إضافة الطبقة المخفية، يتطلب نموذجنا الآن تتبع مجموعات إضافية من المعلمات وتحديثها. إذن ما الذي ربحناهفي المقابل؟ قد تتفاجأ عندما تكتشف ـ في النموذج المحدد أعلاه ـ أننا لا نكسب شيئًا مقابل مشاكلنا! السبب واضح. يتم إعطاء الوحدات المخفية أعلاه بواسطة دالة أفينية للمدخلات، والمخرجات (pre-softmax) هي مجرد دالة أفينية للوحدات المخفية. علاوة على ذلك، كان نموذجنا الخطي قادرًا بالفعل على تمثيل أي دالة أفيني.

لرؤية هذا بشكل رسمي، يمكننا فقط طي الطبقة المخفيةفي التعريف أعلاه، مما ينتج عنه نموذج طبقة واحدة مكافئ مع معلمات $\mathbf{W} = \mathbf{W}^{(1)}\mathbf{W}^{(2)}$ و $\mathbf{b} = \mathbf{b}^{(1)}\mathbf{W}^{(2)} + \mathbf{b}^{(2)}$:

$$\mathbf{O} = (\mathbf{X}\mathbf{W}^{(1)} + \mathbf{b}^{(1)})\mathbf{W}^{(2)} + \mathbf{b}^{(2)} = \mathbf{X}\mathbf{W}^{(1)}\mathbf{W}^{(2)} + \mathbf{b}^{(1)}\mathbf{W}^{(2)} + \mathbf{b}^{(2)} = \mathbf{X}\mathbf{W} + \mathbf{b}.$$

من أجل إدراك إمكانات البنى متعددة الطبقات، نحتاج إلى عنصر رئيسي آخر: دالة تنشيط غير خطية σ (nonlinear activation function) يتم تطبيقها على كل وحدة مخفية بعد التحويل الأفيني affine transformation. على سبيل المثال، الخيار الشائع هو دالة التنشيط ReLU (Rectified Linear Unit) (Nair and Hinton، 2010) التي $\sigma(x) = \max(0, x)$ تعمل على عناصرها من حيث العناصر element-wise. تسمى مخرجات دوال التنشيط $\sigma(\cdot)$ عمليات التنشيط activations. بشكل عام، مع وجود دوال التنشيطفي مكانها الصحيح، لم يعد من الممكن طي MLP الخاص بنا في نموذج خطي:

$$\begin{aligned}\mathbf{H} &= \sigma(\mathbf{X}\mathbf{W}^{(1)} + \mathbf{b}^{(1)}),\\ \mathbf{O} &= \mathbf{H}\mathbf{W}^{(2)} + \mathbf{b}^{(2)}.\end{aligned}$$

نظرًا لأن كل صف في $\mathbf{X}$ يتوافق مع مثال في الدفعات الصغيرة minibatch، مع بعض إساءة استخدام الترميز، فإننا نحدد اللاخطية σ لتطبيقها على مدخلاته بطريقة row-wise، أي مثال واحد في كل مرة. لاحظ أننا استخدمنا نفس الترميز لـ softmax عندما أشرنا إلى row-wise في القسم 4.1.1.3. في كثير من الأحيان، لا تنطبق دوال التنشيط التي نستخدمها فقط على الصفوف ولكن من حيث العناصر. هذا يعني أنه بعد حساب الجزء الخطي من الطبقة، يمكننا حساب كل تنشيط دون النظر إلى القيم التي اتخذتها الوحدات المخفية الأخرى.

لبناء MLPs أكثر عمومية، يمكننا الاستمرار في تكديس هذه الطبقات المخفية، على سبيل المثال $\mathbf{H}^{(1)} = \sigma_1(\mathbf{X}\mathbf{W}^{(1)} + \mathbf{b}^{(1)})$، و$\mathbf{H}^{(2)} = \sigma_2(\mathbf{H}^{(1)}\mathbf{W}^{(2)} + \mathbf{b}^{(2)})$ إحداها فوق الأخرى، مما يؤدي إلى إنتاج المزيد من النماذج التعبيرية.

5.1.1.4. المقربين العالميين Universal Approximators

نحن نعلم أن الدماغ قادر على تحليل إحصائي متطور للغاية. على هذا النحو، يجدر بنا أن نسأل، إلى أي مدى يمكن أن تكون قوة الشبكة العميقة. تمت الإجابة على هذا السؤال عدة مرات، على سبيل المثال، في Cybenko (1989) في سياق MLPs، وفي Micchelli (1984) في سياق إعادة إنتاج مساحات kernel Hilbert بطريقة يمكن اعتبارها شبكات دالة أساس شعاعي (RBF) بطبقة واحدة مخفية. تشير هذه (والنتائج ذات الصلة) إلى أنه حتى مع وجود شبكة ذات طبقة واحدة مخفية، مع توفير عدد كافٍ من العقد (ربما بشكل سخيف)، ومجموعة الأوزان الصحيحة، يمكننا نمذجة أي دالة. في الواقع، تعلم هذه الدالة هو الجزء الصعب. قد تعتقد أن شبكتك العصبية تشبه إلى حد ما لغة البرمجة سي. اللغة، مثل أي لغة حديثة أخرى، قادرة على التعبير عن أي برنامج محوسب. لكن في الواقع، فإن الخروج ببرنامج يلبي المواصفات الخاصة بك هو الجزء الصعب.

علاوة على ذلك، لمجرد أن شبكة الطبقة الواحدة المخفية يمكن أن تتعلم أي دالة لا يعني أنه يجب عليك محاولة حل جميع مشاكلك مع شبكات الطبقة المفردة المخفية. في الواقع، تعتبر طرق النواة kernel methods في هذه الحالة أكثر فاعلية، لأنها قادرة على حل المشكلة تمامًا حتى في المساحات ذات الأبعاد اللانهائية (Kimeldorf and Wahba، 1971، Schölkopf et al.، 2001). في الواقع، يمكننا تقريب العديد من الدوال بشكل أكثر إحكاما باستخدام شبكات أعمق (مقابل شبكات أوسع) (Simonyan and Zisserman، 2014). سنتطرق إلى حجج أكثر صرامة في الفصول اللاحقة.

5.1.2. دوال التنشيط Activation Functions

تحدد دوال التنشيط Activation functions ما إذا كان يجب تنشيط الخلية العصبية أم لا عن طريق حساب مجموع الاوزان وإضافة المزيد من التحيز معه. هم مشغلون قابلون للتفاضل لتحويل إشارات الإدخال إلى مخرجات، بينما يضيف معظمهم اللاخطية. نظرًا لأن دوال التنشيط أساسية للتعلم العميق، فلنستعرض بإيجاز بعض دوال التنشيط الشائعة.

```
%matplotlib inline
import tensorflow as tf
from d2l import tensorflow as d2l
```

5.1.2.1. دالة ReLU

الخيار الأكثر شيوعًا، نظرًا لبساطة التنفيذ وأدائه الجيدفي مجموعة متنوعة من المهام التنبؤية، هو الوحدة الخطية المصححة (ReLU)، (Nair and Hinton، 2010). يوفر ReLU عملية تحويل غير خطية بسيطة للغاية. بالنظر لعنصر ما x، يتم تعريف الدالة على أنها الحد الأقصى لهذا العنصر و 0:

$$\text{ReLU}(x) = max(x, 0).$$

بشكل غير رسمي، تحتفظ دالة ReLU بالعناصر الإيجابية فقط وتتجاهل جميع العناصر السلبية عن طريق ضبط التنشيطات المقابلة على 0. لاكتساب بعض الحدس، يمكننا رسم الدالة. كما ترى، فإن دالة التنشيط خطية متعددة التعريف activation function is piecewise linear.

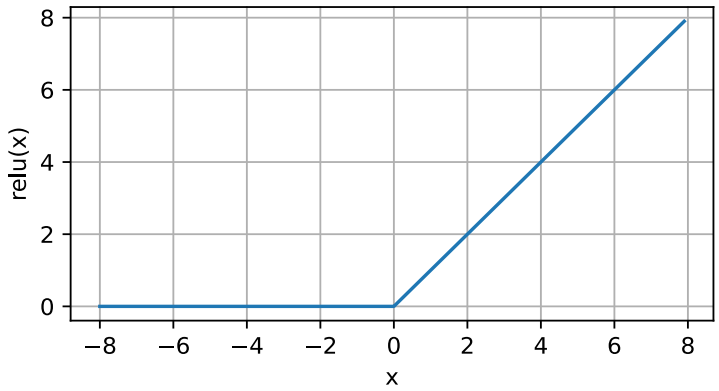

عندما يكون الإدخال سالبًا، يكون مشتق الدالة ReLU هو 0، وعندما يكون الإدخال موجبًا، يكون مشتق دالة ReLU هو 1. لاحظ أن دالة ReLU غير قابلة للاشتقاق not differentiable عندما يأخذ الإدخال قيمة تساوي بالضبط 0.في هذه الحالات، نستخدم مشتق الجانب الأيسر افتراضيًا ونقول إن المشتق يساوي 0 عندما يكون الإدخال 0. يمكننا التخلص من هذا لأن المدخلات قد لا تكون أبدًا صفرًا (قد يقول علماء الرياضيات أنه لا يمكن تمييزها

في مجموعة من قياس الصفر). هناك قول مأثور قديم مفاده أنه إذا كانت الظروف الحدودية الدقيقة مهمة، فربما نقوم بعمل رياضيات (حقيقية)، وليس هندسة.

"There is an old adage that if subtle boundary conditions matter, we are probably doing (*real*) mathematics, not engineering"

قد تنطبق هذه الحكمة التقليدية هنا، أو على الأقل، حقيقة أننا لا نقوم بإجراء تحسين مقيد (Mangasarian، 1965 ، Rockafellar، 1970). نرسم مشتق دالة ReLU الموضحة أدناه.

```
with tf.GradientTape() as t:
    y = tf.nn.relu(x)
d2l.plot(x.numpy(), t.gradient(y, x).numpy(), 'x', 'grad
of relu',
         figsize=(5, 2.5))
```

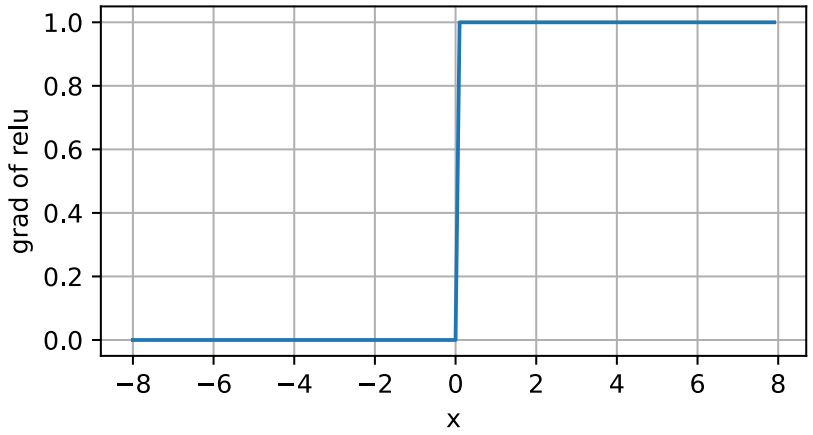

سبب استخدام ReLU هو أن مشتقاته حسنة التصرف بشكل خاص: إما أنها تتلاشى أو تترك المدخل تمر. هذا يجعل التحسين يتصرف بشكل أفضل ويخفف من المشكلة الموثقة جيدًا المتمثلةفي اختفاء التدرجات vanishing gradients التي ابتليت بها الإصدارات السابقة من الشبكات العصبية (المزيد حول هذا لاحقًا).

لاحظ أن هناك العديد من المتغيرات لدالة ReLU، بمافي ذلك دالة ReLU (pReLU) ذات المعلمات (parameterized ReLU) (He et al.، 2015). يضيف هذا الاختلاف مصطلحًا خطيًا إلى ReLU، لذلك لا تزال بعض المعلومات تصل، حتى عندما تكون الوسيطة سلبية:

$$\text{pReLU}(x) = max(0, x) + \alpha min(0, x).$$

5.1.2.2. دالة Sigmoid

تعمل دالة Sigmoid على تحويل مدخلاتها، والتي تكمن القيمفي المجال، إلى مخرجات تقع على الفاصل الزمني (0، 1). لهذا السبب، غالبًا ما يُطلق على Sigmoid دالة سحق squashing function: إنه يسحق أي إدخالفي النطاق (-inf, inf) إلى بعض القيمةفي النطاق (0 ، 1):

$$\text{sigmoid}(x) = \frac{1}{1 + \exp(-x)}.$$

في أقدم الشبكات العصبية، كان العلماء مهتمين بنمذجة الخلايا العصبية البيولوجية التي إما تطلق fire أو لا تطلق not fire. وهكذا ركز رواد هذا المجال، بالعودة إلى McCulloch وPitts، مخترعي الخلايا العصبية الاصطناعية، على وحدات العتبة thresholding units (McCulloch and Pitts، 1943). يأخذ تنشيط العتبة القيمة 0 عندما يكون إدخاله أقل من بعض العتبة والقيمة 1 عندما يتجاوز الإدخال الحد.

عندما تحول الانتباه إلى التعلم القائم على التدرج gradient based learning، كانت دالة Sigmoid اختيارًا طبيعيًا لأنها تقريب سلس وقابل للتفاضل لوحدة العتبة. لا تزال Sigmoid تستخدم على نطاق واسع كدوال تنشيطفي وحدات الإخراج، عندما نريد تفسير المخرجات على أنها احتمالات لمشاكل التصنيف الثنائي: يمكنك التفكيرفي Sigmoid كحالة خاصة من softmax. ومع ذلك، تم استبدال Sigmoidفي الغالب بـ ReLU الأبسط والأكثر سهولةفي التدريب لمعظم الاستخداماتفي الطبقات المخفية. يتعلق الكثير من هذا بحقيقة أن Sigmoid يفرض تحديات على التحسين (LeCun et al.، 1998) نظرًا لأن تدرجه يتلاشى بسبب المدخلات الإيجابية والسلبية الكبيرة. هذا يمكن أن يؤدي إلى الهضاب plateaus التي يصعب الهروب منها. ومع ذلك، فإن Sigmoid مهمة.في الفصول اللاحقة (على سبيل المثال، القسم 10.1) حول الشبكات العصبية المتكررة، سنصف البنى التي تستفيد من وحدات Sigmoid للتحكمفي تدفق المعلومات عبر الوقت.

أدناه، نرسم دالة Sigmoid. لاحظ أنه عندما يكون الإدخال قريبًا من 0، تقترب دالة Sigmoid من التحويل الخطي linear transformation.

```
y = tf.nn.sigmoid(x)
d2l.plot(x.numpy(), y.numpy(), 'x', 'sigmoid(x)',
figsize=(5, 2.5))
```

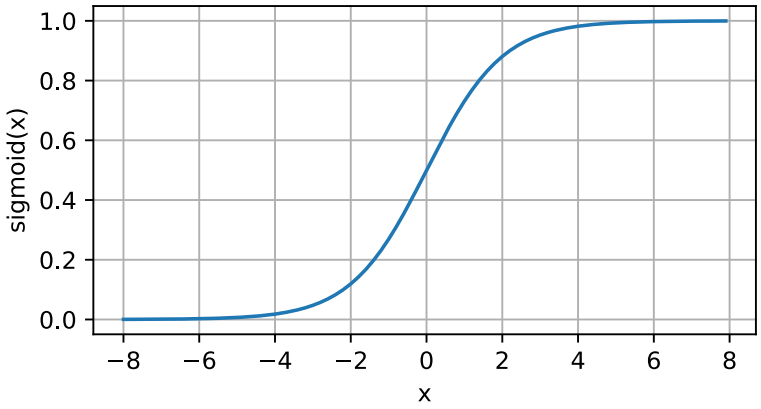

يتم الحصول على مشتق دالة Sigmoid بالمعادلة التالية:

$$\frac{d}{dx}\text{sigmoid}(x) = \frac{\exp(-x)}{(1+\exp(-x))^2} = \text{sigmoid}(x)(1-\text{sigmoid}(x)).$$

تم رسم مشتق دالة Sigmoid أدناه. لاحظ أنه عندما يكون الإدخال 0، فإن مشتق دالة Sigmoid يصل إلى 0.25 كحد أقصى. عندما ينحرف المدخل عن 0في أي اتجاه، يقترب المشتق من 0.

```
with tf.GradientTape() as t:
    y = tf.nn.sigmoid(x)
d2l.plot(x.numpy(), t.gradient(y, x).numpy(), 'x', 'grad
of sigmoid',
         figsize=(5, 2.5))
```

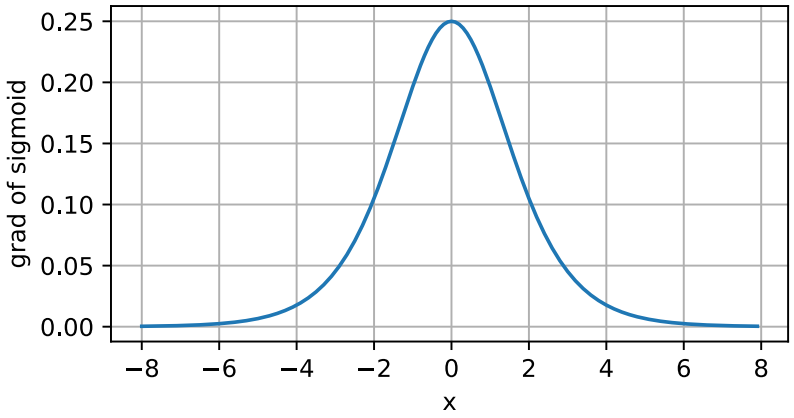

5.1.2.3. دالة Tanh

مثل الدالة sigmoid، تقوم دالة tanh (الظل الزائدي hyperbolic tangent) أيضًا بسحق مدخلاتها، وتحويلها إلى عناصرفي الفترة بين ـ1 و1:

$$\tanh(x) = \frac{1 - \exp(-2x)}{1 + \exp(-2x)}.$$

نرسم دالة tanh أدناه. لاحظ أنه عندما يقترب الإدخال من الصفر، تقترب الدالة tanh من التحويل الخطي. على الرغم من أن شكل الدالة مشابه لشكل دالة Sigmoid، إلا أن دالة tanh تُظهر تناظرًا نقطيًا حول أصل نظام الإحداثيات (Kalman and Kwasny، 1992).

```
y = tf.nn.tanh(x)
d2l.plot(x.numpy(), y.numpy(), 'x', 'tanh(x)',
figsize=(5, 2.5))
```

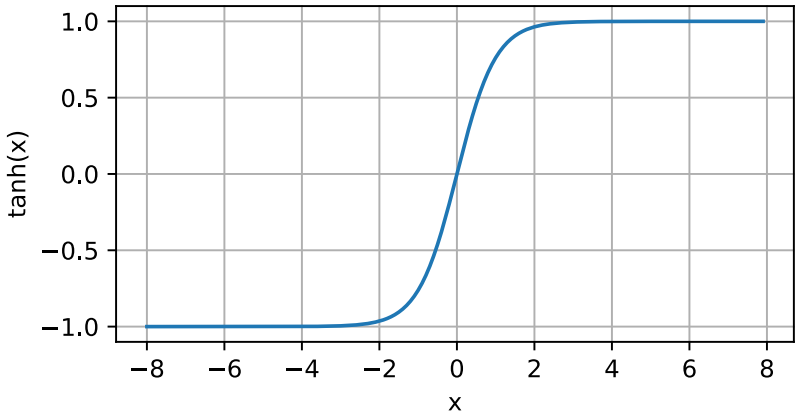

مشتق التابع tanh هو:

$$\frac{d}{dx}\tanh(x) = 1 - \tanh^2(x).$$

تم رسمه أدناه. عندما يقترب المدخل من الصفر، يقترب مشتق الدالة tanh من 1 كحد أقصى. وكما رأينا مع دالة Sigmoid، حيث يتحرك الإدخال بعيدًا عن الصفرفي أي من الاتجاهين، يقترب مشتق الدالة tanh من الصفر.

```
with tf.GradientTape() as t:
    y = tf.nn.tanh(x)
d2l.plot(x.numpy(), t.gradient(y, x).numpy(), 'x', 'grad
of tanh',
         figsize=(5, 2.5))
```

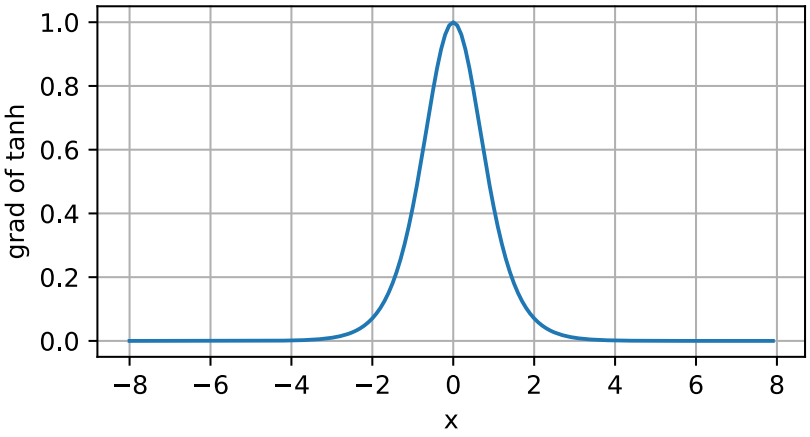

5.1.3 .الملخص

نحن نعرف الآن كيفية دمج اللاخطية لبناء بنيات شبكة عصبية معبرة متعددة الطبقات. كملاحظة جانبية، فإن معرفتك تضعك بالفعل في قيادة مجموعة أدوات مماثلة للممارس حوالي عام 1990. في بعض النواحي، لديك ميزة على أي شخص يعمل في التسعينيات، لأنه يمكنك الاستفادة من أطر التعلم العميق القوية مفتوحة المصدر لبناء النماذج بسرعة، باستخدام بضعة أسطر فقط من التعليمات البرمجية. في السابق، كان تدريب هذه الشبكات يتطلب من الباحثين ترميز الطبقات والمشتقات بشكل صريح في C أو Fortran أو حتى Lisp (في حالة LeNet).

فائدة ثانوية هي أن ReLU أكثر قابلية للتحسين بشكل ملحوظ من Sigmoid أو دالة tanh. يمكن للمرء أن يجادل في أن هذا كان أحد الابتكارات الرئيسية التي ساعدت على عودة التعلم العميق خلال العقد الماضي. لاحظ، مع ذلك، أن البحث في دوال التنشيط لم يتوقف. على سبيل المثال، يمكن أن تؤدي دالة تنشيط Swish $\sigma(x) = x\text{sigmoid}(\beta x)$ كما هو مقترح في (Ramachandran et al.، 2017) إلى دقة أفضل في كثير من الحالات.

5.1.4 .التمارين

1. أظهر أن إضافة طبقات إلى شبكة عميقة خطية linear deep network، أي شبكة بدون اللاخطية لا يمكنها أبدًا زيادة القوة التعبيرية للشبكة. أعط مثالا حيث يقلل ذلك بنشاط.
2. احسب مشتق من دالة التنشيط pReLU.
3. احسب مشتق من دالة التنشيط Swish $x\text{sigmoid}(\beta x)$.
4. أظهر أن MLP باستخدام ReLU فقط (أو pReLU) يبني دالة خطية مستمرة متعددة التعريفات continuous piecewise linear function.
5. Sigmoid و tanh متشابهان جدا.

1. اظهر $\tanh(x) + 1 = 2\text{sigmoid}(2x)$.
2. إثبت أن فئات الدوال المحددة بواسطة كلا اللاخطيين متطابقة. تلميح: الطبقات الافينية affine layers لها مصطلحات متحيزة أيضًا.
6. افترض أن لدينا خاصية غير خطية تنطبق على الدفعات الصغيرة واحدفي كل مرة، مثل تسوية الدُفعات batch normalization (Ioffe and Szegedy، 2015). ما أنواع المشاكل التي تتوقع أن يسببها هذا؟
7. قدم مثالاً حيث تختفي التدرجات لدالة التنشيط Sigmoid.

5.2 تنفيذ البيرسيبترون متعدد الطبقات Implementation of Multilayer Perceptron

البيرسيبترون متعدد الطبقات (MLPs) ليس أكثر تعقيدًافي التنفيذ من النماذج الخطية البسيطة. يتمثل الاختلاف المفاهيمي الرئيسيفي أننا نجمع طبقات متعددة الآن.

```
import tensorflow as tf
from d2l import tensorflow as d2l
```

5.2.1. التنفيذ من البداية Implementation from Scratch

لنبدأ مرة أخرى بتنفيذ مثل هذه الشبكة من البداية.

5.2.1.1. تهيئة معلمات النموذج Initializing Model Parameters

تذكر أن Fashion-MNIST يحتوي على 10 فئات، وأن كل صورة تتكون من شبكة $28 \times 28 = 784$ من قيم البكسل الرمادية. كما كان من قبل، سوف نتجاهل البنية المكانية بين وحدات البكسلفي الوقت الحالي، لذلك يمكننا التفكيرفي هذا على أنه مجموعة بيانات تصنيف تحتوي على 784 ميزة إدخال و10 فئات. للبدء، سنقوم بتطبيق MLP بطبقة مخفية واحدة و256 وحدة مخفية. يمكن ضبط كل من عدد الطبقات وعرضها (تعتبر معلمات فائقة). عادة، نختار عروض الطبقة لتكون قابلة للقسمة على قوى أكبر من 2. وهذا فعال من الناحية الحسابية نظرًا للطريقة التي يتم بها تخصيص الذاكرة ومعالجتهافي الأجهزة.

مرة أخرى، سنقوم بتمثيل معلماتنا بعدة موترات tensors. لاحظ أنه بالنسبة لكل طبقة، يجب أن نتتبع مصفوفة وزن weight matrix واحدة ومتجه تحيز bias vector واحد. كما هو الحال دائمًا، نخصص ذاكرة لتدرجات الخطأ gradients of the loss فيما يتعلق بهذه المعلمات.

```
class MLPScratch(d2l.Classifier):
    def __init__(self, num_inputs, num_outputs, num_hiddens,
lr, sigma=0.01):
        super().__init__()
        self.save_hyperparameters()
        self.W1 = tf.Variable(
            tf.random.normal((num_inputs, num_hiddens)) *
sigma)
```

```
        self.b1 = tf.Variable(tf.zeros(num_hiddens))
        self.W2 = tf.Variable(
            tf.random.normal((num_hiddens, num_outputs)) *
sigma)
        self.b2 = tf.Variable(tf.zeros(num_outputs))
```

5.2.1.2. النموذج Model

للتأكد من أننا نعرف كيف يعمل كل شيء، سنقوم بتنفيذ تنشيط ReLU بأنفسنا بدلاً من استدعاء دالة relu المدمجة مباشرةً.

```
def relu(X):
    return tf.math.maximum(X, 0)
```

نظرًا لأننا نتجاهل البنية المكانية، فنحن نعيد تشكيل كل صورة ثنائية الأبعاد إلى متجه مسطح بطول عدد المدخلات num_inputs. أخيرًا، نطبق نموذجنا ببضعة أسطر من التعليمات البرمجية. نظرًا لأننا نستخدم إطار عمل autograd المدمج، فهذا كل ما يتطلبه الأمر.

```
@d2l.add_to_class(MLPScratch)
def forward(self, X):
    X = tf.reshape(X, (-1, self.num_inputs))
    H = relu(tf.matmul(X, self.W1) + self.b1)
    return tf.matmul(H, self.W2) + self.b2
```

5.2.1.3. التدريب Training

لحسن الحظ، فإن حلقة التدريب لـ MLPs هي نفسها تمامًا لانحدار softmax. نحدد النموذج والبيانات والمدرب وأخيراً نستدعي الدالة fit في النموذج والبيانات.

```
model = MLPScratch(num_inputs=784, num_outputs=10,
num_hiddens=256, lr=0.1)
data = d2l.FashionMNIST(batch_size=256)
trainer = d2l.Trainer(max_epochs=10)
trainer.fit(model, data)
```

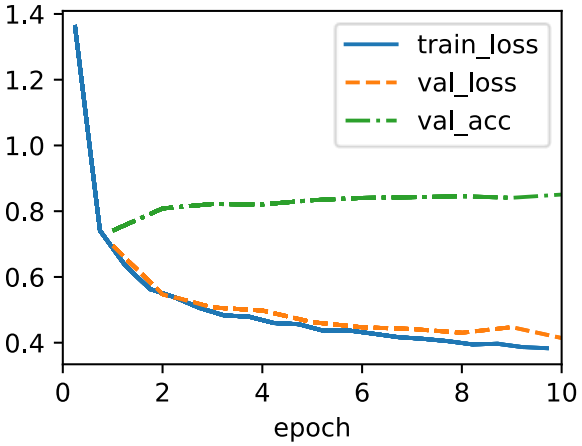

5.2.2. التنفيذ المختصر Concise Implementation

كما قد تتوقع، من خلال الاعتماد على واجهات برمجة التطبيقات APIs عالية المستوى، يمكننا تنفيذ MLPs بشكل أكثر دقة.

5.2.2.1. النموذج Model

بالمقارنة مع تنفيذنا المختصر لتطبيق انحدار softmax (القسم 4.5)، فإن الاختلاف الوحيد هو أننا نضيف طبقتين متصلتين تمامًا fully connected حيث أضفنا سابقًا واحدة فقط. الأولى هي الطبقة المخفية hidden layer، والثانية هي الطبقة الناتجة output layer.

```
class MLP(d2l.Classifier):
    def __init__(self, num_outputs, num_hiddens, lr):
        super().__init__()
        self.save_hyperparameters()
        self.net = tf.keras.models.Sequential([
            tf.keras.layers.Flatten(),
            tf.keras.layers.Dense(num_hiddens,
activation='relu'),
            tf.keras.layers.Dense(num_outputs)])
```

5.2.2.2. التدريب Training

حلقة التدريب هي نفسها تمامًا عندما طبقنا انحدار softmax. تمكننا هذه النمطية من فصل الأمور المتعلقة بهندسة النموذج عن الاعتبارات المتعامدة.

```
model = MLP(num_outputs=10, num_hiddens=256, lr=0.1)
trainer.fit(model, data)
```

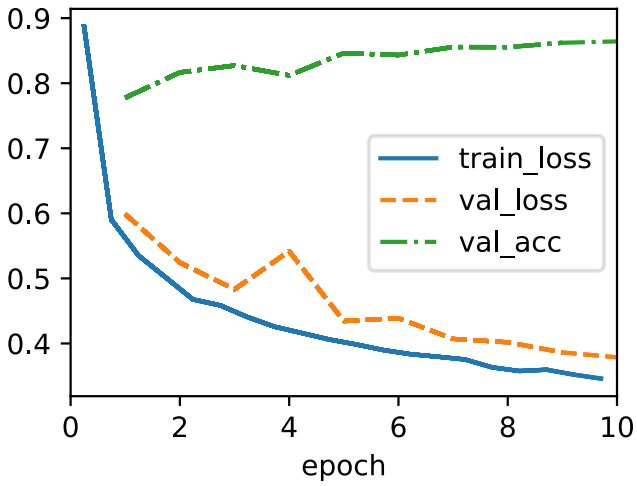

5.2.3. الملخص

الآن بعد أن أصبح لدينا مزيد من الممارسةفي تصميم الشبكات العميقة، فإن الخطوة من طبقة واحدة إلى طبقات متعددة من الشبكات العميقة لم تعد تشكل تحديًا كبيرًا بعد الآن. على وجه الخصوص، يمكننا إعادة استخدام خوارزمية التدريب ومحمل البيانات. لاحظ، على الرغم من ذلك، أن تنفيذ MLPs من الصفر مع ذلك فوضوي: تسمية معلمات النموذج وتتبعها تجعل من الصعب توسيع النماذج. على سبيل المثال، تخيل أنك ترغبفي إدراج طبقة أخرى بين الطبقتين 42 و 43. قد تكون هذه الآن طبقة 42b، إلا إذا كنا على استعداد لإجراء إعادة تسمية متسلسلة. علاوة على ذلك، إذا قمنا بتنفيذ الشبكة من البداية، فسيكون من الصعب جدًا على إطار العمل إجراء تحسينات مفيدةفي الأداء.

ومع ذلك ، فقد وصلت الآن إلى أحدث ما توصلت إليه التكنولوجيافي أواخر الثمانينيات عندما كانت الشبكات العميقة المتصلة بالكامل هي الطريقة المفضلة لنمذجة الشبكة العصبية. ستكون خطوتنا المفاهيمية التالية هي النظرفي الصور. قبل القيام بذلك، نحتاج إلى مراجعة عدد من الأساسيات الإحصائية والتفاصيل حول كيفية حساب النماذج بكفاءة.

5.2.4. التمارين

1. قم بتغيير عدد الوحدات المخفية ورسم كيف يؤثر عددها على دقة النموذج. ما هي أفضل قيمة لهذا المعامل الفائق؟
2. حاول إضافة طبقة مخفية لترى كيف تؤثر على النتائج.
3. لماذا يعتبر إدخال طبقة مخفية ذات خلية عصبية واحدة فكرة سيئة؟ ما الخطأ الذي يمكن أن يحدث؟
4. كيف تغيير معدل التعلم يغير نتائجك؟ مع إصلاح جميع المعلمات الأخرى، ما هو معدل التعلم الذي يمنحك أفضل النتائج؟ كيف يرتبط هذا بعدد الفترات؟
5. دعنا نقوم بالتحسين عبر جميع المعلمات الفائقة معًا، أي معدل التعلم وعدد الفترات وعدد الطبقات المخفية وعدد الوحدات المخفية لكل طبقة.
    1. ما هي أفضل نتيجة يمكنك الحصول عليها من خلال تحسينها جميعًا؟
    2. لماذا يعتبر التعامل مع العديد من المعلمات الفائقة أكثر صعوبة؟
    3. صِف إستراتيجية فعالة للتحسين عبر معايير متعددة بشكل مشترك.
6. قارن بين سرعة إطار العمل والتنفيذ من الصفر لمشكلة صعبة. كيف تتغير مع تعقيد الشبكة؟
7. قم بقياس سرعة عمليات ضرب مصفوفة الموتر للحصول على مصفوفات جيدة المحاذاة well-aligned وغير المحاذاة misaligned. على سبيل المثال، اختبر المصفوفات ذات الأبعاد 1024 و1025 و1026 و1028 و1032.
    1. كيف يتغير هذا بين وحدات معالجة الرسومات GPUs ووحدات المعالجة المركزية CPUs؟

2. حدد عرض ناقل الذاكرة memory bus width لوحدة المعالجة المركزية CPU ووحدة معالجة الرسومات GPU.
8. جرب دوال التنشيط المختلفة. أيهما أفضل؟
9. هل هناك فرق بين التهيئة للوزن للشبكة؟ هل يهم؟

5.3 الانتشار الأمامي Forward Propagation، والانتشار الخلفي Backward Propagation، والرسوم البيانية الحسابية Computational Graphs

حتى الآن، قمنا بتدريب نماذجنا باستخدام التدرج الاشتقاقي العشوائي المصغر minibatch SGD. ومع ذلك، عندما قمنا بتطبيق الخوارزمية، كنا قلقين فقط بشأن الحسابات التي ينطوي عليها الانتشار الأمامي Forward Propagation من خلال النموذج. عندما حان الوقت لحساب التدرجات، استدعينا للتو دالة الانتشار الخلفي backpropagation التي يوفرها إطار عمل التعلم العميق.

يعمل الحساب التلقائي للتدرجات (التمايز التلقائي automatic differentiation) على تبسيط تطبيق خوارزميات التعلم العميق بشكل كبير. قبل التفاضل التلقائي، كانت التغييرات الصغيرة على النماذج المعقدة تتطلب إعادة حساب المشتقات المعقدة يدويًا.في كثير من الأحيان، كان من المثير للدهشة أن الأوراق الأكاديمية كان عليها تخصيص العديد من الصفحات لاشتقاق قواعد التحديث. بينما يجب أن نستمرفي الاعتماد على التفاضل التلقائي حتى نتمكن من التركيز على الأجزاء المثيرة للاهتمام، يجب أن تعرف كيف يتم حساب هذه التدرجات gradients إذا كنت تريد تجاوز الفهم الضحل للتعلم العميق.

في هذا القسم، نلقي نظرة عميقة على تفاصيل الانتشار الخلفي backward propagation (يُطلق عليه أكثر شيوعًا backpropagation). لنقل بعض البصيرة لكل من التقنيات وتطبيقاتها، نعتمد على بعض الرياضيات الأساسية والرسوم البيانية الحسابية computational graphs. للبدء، نركز عرضنا على طبقة MLP ذات طبقة واحدة مخفية مع تناقص الوزن weight decay (التنظيم ℓ_2 ، على أن يتم وصفهفي الفصول اللاحقة).

5.3.1. الانتشار الامامي Forward Propagation

يشير الانتشار الأمامي Forward Propagation (أو التمرير الأمامي) إلى حساب وتخزين المتغيرات الوسيطة (بمافي ذلك المخرجات) للشبكة العصبية بالترتيب من طبقة الإدخال إلى طبقة الإخراج. نحن نعمل الآن خطوة بخطوة من خلال آليات الشبكة العصبية بطبقة مخفية واحدة. قد يبدو هذا مملاً، لكن بالكلمات الأبدية للمبدع الفانك جيمس براون، يجب أن "تدفع الثمن لتكون الرئيس".

من أجل البساطة، دعنا نفترض أن مثال الإدخال هو $\mathbf{x} \in \mathbb{R}^d$ وأن الطبقة المخفية لا تتضمن مصطلح التحيز. هنا المتغير الوسيط هو:

$$\mathbf{z} = \mathbf{W}^{(1)}\mathbf{x},$$

حيث $\mathbf{W}^{(1)} \in \mathbb{R}^{h \times d}$ هي معلمة وزن الطبقة المخفية. بعد تشغيل المتغير الوسيط $\mathbf{z} \in \mathbb{R}^h$ من خلال دالة التنشيط ϕ، نحصل على متجه التنشيط المخفي للطول h،

$$\mathbf{h} = \phi(\mathbf{z}).$$

ناتج الطبقة المخفية $\mathbf{h}$ هو أيضًا متغير وسيط. بافتراض أن معلمات الطبقة المخرجة تمتلك وزنًا فقط $\mathbf{W}^{(2)} \in \mathbb{R}^{q \times h}$، فيمكننا الحصول على متغير طبقة الإخراج مع متجه الطول q:

$$\mathbf{o} = \mathbf{W}^{(2)}\mathbf{h}.$$

بافتراض أن دالة الخطأ l ومثال التسمية y، يمكننا بعد ذلك حساب مصطلح الخطأ لمثال بيانات واحد،

$$L = l(\mathbf{o}, y).$$

وفقًا لتعريف التنظيم ℓ_2 الذي سنقدمه لاحقًا، نظرًا للمعلمة الفائقة، فإن مصطلح التنظيم هو

$$J = L + s.$$

نشير إلى J كدالة الهدف objective function في المناقشة التالية.

5.3.2. الرسم البياني الحسابي للانتشار الأمامي Computational Graph of Forward Propagation

يساعدنا رسم الرسوم البيانية الحسابية computational graphs على تصور تبعيات المشغلين والمتغيرات في الحساب. يحتوي الشكل 5.3.1 على الرسم البياني المرتبط بالشبكة البسيطة الموضحة أعلاه، حيث تشير المربعات إلى المتغيرات variables وتشير الدوائر إلى العوامل operators. الزاوية اليسرى السفلية تشير إلى الإدخال والزاوية اليمنى العلوية هي الإخراج. لاحظ أن اتجاهات الأسهم (التي توضح تدفق البيانات data flow) هي في المقام الأول إلى اليمين والصعود.

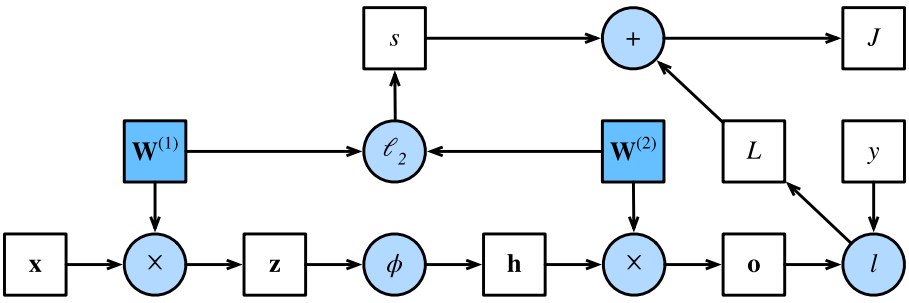

الشكل 5.3.1 رسم بياني حسابي للانتشار الأمامي.

يشير الانتشار الخلفي Backpropagation إلى طريقة حساب التدرج gradient لمعلمات الشبكة العصبية. باختصار، تعبر الطريقة الشبكة بترتيب عكسي، من المخرجات إلى طبقة الإدخال، وفقًا لقاعدة السلسلة chain rule من حساب التفاضل والتكامل. تقوم الخوارزمية بتخزين أي متغيرات وسيطة (مشتقات جزئية) مطلوبة أثناء حساب التدرج فيما يتعلق ببعض المعلمات. افترض أن لدينا دوال $\mathsf{Y} = f(\mathsf{X})$ و$\mathsf{Z} = g(\mathsf{Y})$ ، أن المدخلات والمخرجات $\mathsf{X}, \mathsf{Y}, \mathsf{Z}$ عبارة عن موتر لأشكال عشوائية. باستخدام قاعدة السلسلة، يمكننا حساب مشتقة Z بالنسبة إلى X بواسطة:

$$\frac{\partial \mathsf{Z}}{\partial \mathsf{X}} = \text{prod}\left(\frac{\partial \mathsf{Z}}{\partial \mathsf{Y}}, \frac{\partial \mathsf{Y}}{\partial \mathsf{X}}\right).$$

هنا نستخدم عامل التشغيل prod لمضاعفة وسيطاته بعد تنفيذ العمليات الضرورية، مثل التحويل وتبديل مواضع الإدخال. بالنسبة إلى المتجهات، هذا واضح ومباشر: إنه ببساطة ضرب مصفوفة–مصفوفة. بالنسبة للموترات ذات الأبعاد الأعلى، نستخدم النظير counterpart المناسب. يخفي عامل التشغيل prod كل الرموز العلوية.

تذكر أن معلمات الشبكة البسيطة ذات الطبقة المخفية، والتي يوجد رسمها البياني الحسابيفي الشكل 5.3.1، هي $\mathbf{W}^{(1)}$ و$\mathbf{W}^{(2)}$. الهدف من الانتشار الخلفي backpropagation هو حساب التدرجات $\partial J/\partial \mathbf{W}^{(1)}$ و$\partial J/\partial \mathbf{W}^{(2)}$. لتحقيق ذلك، نطبق قاعدة السلسلة ونحسب، بدورنا، التدرج لكل متغير وسيط ومعلمة. يتم عكس ترتيب الحسابات بالنسبة إلى تلك التي يتم إجراؤهافي الانتشار الأمامي، نظرًا لأننا نحتاج إلى البدء بنتيجة الرسم البياني الحسابي والعملفي طريقنا نحو المعلمات. الخطوة الأولى هي حساب تدرجات دالة الهدف $J = L + s$ فيما يتعلق بمصطلح الخطأ L ومصطلح التنظيم s.

$$\frac{\partial J}{\partial L} = 1 \text{and} \frac{\partial J}{\partial s} = 1.$$

بعد ذلك، نحسب التدرج لدالة الهدف فيما يتعلق بمتغير طبقة المخرجات $\mathbf{o}$ وفقًا لقاعدة السلسلة:

$$\frac{\partial J}{\partial \mathbf{o}} = \text{prod}\left(\frac{\partial J}{\partial L}, \frac{\partial L}{\partial \mathbf{o}}\right) = \frac{\partial L}{\partial \mathbf{o}} \in \mathbb{R}^q.$$

بعد ذلك، نحسب تدرجات مصطلح التنظيم فيما يتعلق بكل من المعلمتين:

$$\frac{\partial s}{\partial \mathbf{W}^{(1)}} = \lambda \mathbf{W}^{(1)} \text{and} \frac{\partial s}{\partial \mathbf{W}^{(2)}} = \lambda \mathbf{W}^{(2)}.$$

الآن نحن قادرون على حساب التدرج $\partial J/\partial \mathbf{W}^{(2)} \in \mathbb{R}^{q\times h}$ لمعلمات النموذج الأقرب إلى طبقة الإخراج. ينتج عن استخدام قاعدة السلسلة:

$$\frac{\partial J}{\partial \mathbf{W}^{(2)}} = \text{prod}(\frac{\partial J}{\partial \mathbf{o}}, \frac{\partial \mathbf{o}}{\partial \mathbf{W}^{(2)}}) + \text{prod}(\frac{\partial J}{\partial s}, \frac{\partial s}{\partial \mathbf{W}^{(2)}}) = \frac{\partial J}{\partial \mathbf{o}} \mathbf{h}^\top + \lambda \mathbf{W}^{(2)}.$$

للحصول على التدرج فيما يتعلق $\mathbf{W}^{(1)}$ ، نحتاج إلى مواصلة backpropagation على طول طبقة الإخراج إلى الطبقة المخفية. يتم إعطاء التدرج فيما يتعلق بإخراج الطبقة المخفية $\partial J/\partial \mathbf{h} \in \mathbb{R}^h$ بواسطة

$$\frac{\partial J}{\partial \mathbf{h}} = \text{prod}(\frac{\partial J}{\partial \mathbf{o}}, \frac{\partial \mathbf{o}}{\partial \mathbf{h}}) = \mathbf{W}^{(2)\top} \frac{\partial J}{\partial \mathbf{o}}.$$

نظرًا لأن دالة التنشيط ϕ تنطبق على العناصر، فإن حساب التدرج $\partial J/\partial \mathbf{z} \in \mathbb{R}^h$ للمتغير الوسيط $\mathbf{z}$يتطلب أن نستخدم عامل الضرب العنصري elementwise multiplication operator، والذي نشير إليه بـ $\odot$:

$$\frac{\partial J}{\partial \mathbf{z}} = \text{prod}(\frac{\partial J}{\partial \mathbf{h}}, \frac{\partial \mathbf{h}}{\partial \mathbf{z}}) = \frac{\partial J}{\partial \mathbf{h}} \odot \phi'(\mathbf{z}).$$

أخيرًا، يمكننا الحصول على التدرج $\partial J/\partial \mathbf{W}^{(1)} \in \mathbb{R}^{h\times d}$ لمعلمات النموذج الأقرب إلى طبقة الإدخال. وفقًا لقاعدة السلسلة، نحصل على

$$\frac{\partial J}{\partial \mathbf{W}^{(1)}} = \text{prod}(\frac{\partial J}{\partial \mathbf{z}}, \frac{\partial \mathbf{z}}{\partial \mathbf{W}^{(1)}}) + \text{prod}(\frac{\partial J}{\partial s}, \frac{\partial s}{\partial \mathbf{W}^{(1)}}) = \frac{\partial J}{\partial \mathbf{z}} \mathbf{x}^\top + \lambda \mathbf{W}^{(1)}.$$

5.3.4. تدريب الشبكات العصبية Training Neural Networks

عند تدريب الشبكات العصبية، يعتمد الانتشار الأمامي والخلفي على بعضهما البعض. على وجه الخصوص، من أجل الانتشار الأمامي، نجتاز الرسم البياني الحسابيفي اتجاه التبعيات ونحسب جميع المتغيرات على مسارها. ثم يتم استخدام هذه من أجل الانتشار الخلفي حيث يتم عكس ترتيب الحساب على الرسم البياني.

خذ الشبكة البسيطة المذكورة أعلاه كمثال للتوضيح. من ناحية أخرى، يعتمد حساب مصطلح التنظيم (5.3.5) أثناء الانتشار الأمامي على القيم الحالية لمعلمات النموذج $\mathbf{W}^{(1)}$ و $\mathbf{W}^{(2)}$. يتم تقديمها بواسطة خوارزمية التحسين وفقًا للانتشار الخلفيفي التكرار الأخير. من ناحية أخرى، يعتمد حساب التدرج للمعامل (5.3.11) أثناء الانتشار الخلفي على القيمة الحالية لمخرجات الطبقة المخفية $\mathbf{h}$، والتي يتم تقديمها عن طريق الانتشار الأمامي.

لذلك عند تدريب الشبكات العصبية، بعد تهيئة معلمات النموذج، نتبادل الانتشار الأمامي مع الانتشار الخلفي، وتحديث معلمات النموذج باستخدام التدرجات المعطاة عن طريق الانتشار الخلفي. لاحظ أن الانتشار الخلفي يعيد استخدام القيم الوسيطة المخزنة من الانتشار الأمامي لتجنب الحسابات المكررة. إحدى العواقب هي أننا بحاجة إلى الاحتفاظ بالقيم الوسيطة حتى يكتمل الانتشار الخلفي. هذا أيضًا أحد الأسباب التي تجعل التدريب يتطلب ذاكرة أكبر بكثير من التوقع البسيط. إلى جانب ذلك، يتناسب حجم هذه القيم الوسيطة تقريبًا مع عدد طبقات الشبكة وحجم الدُفعة. وبالتالي، فإن تدريب شبكات أعمق باستخدام أحجام دفعات أكبر يؤدي بسهولة أكبر إلى نفاد أخطاء الذاكرة.

5.3.5. الملخص

- يحسب الانتشار الأمامي المتغيرات الوسيطة ويخزنها بالتسلسل داخل الرسم البياني الحسابي المحدد بواسطة الشبكة العصبية. ينطلق من المدخلات إلى طبقة الإخراج.
- يقوم الانتشار الخلفي بحساب وتخزين تدرجات المتغيرات والمعلمات الوسيطة بشكل تسلسلي داخل الشبكة العصبية بالترتيب المعكوس.
- عند تدريب نماذج التعلم العميق، فإن الانتشار الأمامي والانتشار الخلفي مترابطان.
- يتطلب التدريب ذاكرة أكبر بكثير من التوقع.

5.3.6. التمارين

1. افترض أن مدخلات $\mathbf{X}$ بعض الدوال العددية f عبارة عن مصفوفات $n \times m$. ما هي أبعاد التدرج f بالنسبة لـ $\mathbf{X}$؟
2. أضف تحيزًا إلى الطبقة المخفية من النموذج الموضحفي هذا القسم (لا تحتاج إلى تضمين التحيزفي مصطلح التنظيم).
    1. ارسم الرسم البياني الحسابي المطابق.
    2. اشتق معادلات الانتشار الأمامية والخلفية.
3. احسب بصمة الذاكرة memory footprint للتدريب والتنبؤفي النموذج الموضحفي هذا القسم.
4. افترض أنك تريد حساب المشتقات الثانية. ماذا يحدث للرسم البياني الحسابي؟ كم من الوقت تتوقع أن تستغرق العملية الحسابية؟
5. افترض أن الرسم البياني الحسابي كبير جدًا بالنسبة لوحدة معالجة الرسومات GPU الخاصة بك.
    1. هل يمكنك تقسيمها على أكثر من وحدة معالجة رسومات GPU؟
    2. ما هي مزايا وعيوب التدريب على minibatch أصغر؟

5.4. الاستقرار العددي والتهيئة Numerical Stability and Initialization

حتى الآن، كل نموذج قمنا بتطبيقه يتطلب أن نقوم بتهيئة معلماته وفقًا لبعض التوزيعات المحددة مسبقًا. حتى الآن، أخذنا مخطط التهيئة كأمر مسلم به، مع إخفاء تفاصيل كيفية اتخاذ هذه الخيارات. قد يكون لديك انطباع بأن هذه الخيارات ليست مهمة بشكل خاص. على العكس من ذلك، يلعب اختيار مخطط التهيئة دورًا مهمًافي تعلم الشبكة العصبية، ويمكن أن يكون حاسمًا للحفاظ على الاستقرار العددي. علاوة على ذلك، يمكن ربط هذه الاختيارات بطرق مثيرة باختيار دالة التنشيط اللاخطي. يمكن أن تحدد الدالة التي نختارها وكيف نهيئ المعلمات مدى سرعة تقارب خوارزمية التحسين الخاصة بنا. قد تؤدي الخيارات السيئة هنا إلى مواجهة تدرجات متدرجة أو متلاشية أثناء التدريب.في هذا القسم، نتعمقفي هذه الموضوعات بمزيد من التفاصيل ونناقش بعض الاستدلالات المفيدة التي ستجدها مفيدة طوال حياتك المهنيةفي التعلم العميق.

5.4.1. تلاشي وانفجار التدرجات Vanishing and Exploding Gradients

ضعفي اعتبارك شبكة عميقة ذات طبقات L ومدخلات $\mathbf{x}$ ومخرجات $\mathbf{o}$. مع تحديد كل طبقة l من خلال تحويل f_l يتم تحديد معلماته بواسطة الأوزان $\mathbf{W}^{(l)}$، والتي يكون ناتج الطبقة المخفية $\mathbf{h}^{(l)}$ (ليكن $\mathbf{h}^{(0)} = \mathbf{x}$)، يمكن التعبير عن شبكتنا على النحو التالي:

$$\mathbf{h}^{(l)} = f_l(\mathbf{h}^{(l-1)}) \text{ and thus } \mathbf{o} = f_L \circ \ldots \circ f_1(\mathbf{x}).$$

إذا كانت جميع مخرجات ومدخلات الطبقة المخفية عبارة عن متجهات، فيمكننا كتابة التدرج $\mathbf{o}$ فيما يتعلق بأي مجموعة من المعلمات $\mathbf{W}^{(l)}$ على النحو التالي:

$$\partial_{\mathbf{W}^{(l)}} \mathbf{o} = \underbrace{\partial_{\mathbf{h}^{(L-1)}} \mathbf{h}^{(L)}}_{\mathbf{M}^{(L)} \stackrel{\text{def}}{=}} \cdot \ldots \cdot \underbrace{\partial_{\mathbf{h}^{(l)}} \mathbf{h}^{(l+1)}}_{\mathbf{M}^{(l+1)} \stackrel{\text{def}}{=}} \underbrace{\partial_{\mathbf{W}^{(l)}} \mathbf{h}^{(l)}}_{\mathbf{v}^{(l)} \stackrel{\text{def}}{=}}.$$

بمعنى آخر، هذا التدرج هو ناتج ضرب $L - l$ مصفوفات $\mathbf{M}^{(L)} \cdot \ldots \cdot \mathbf{M}^{(l+1)}$ ومتجه التدرج $\mathbf{v}^{(l)}$. وبالتالي نحن عرضة لنفس مشاكل التدفق العددي numerical underflow الذي غالبًا ما يظهر عند ضرب العديد من الاحتمالات معًا. عند التعامل مع الاحتمالات، فإن الحيلة الشائعة هي التبديل إلى مساحة اللوغارتيم log-space، أي تحويل الضغط من الجزء العشري إلى أس التمثيل العددي. لسوء الحظ، فإن مشكلتنا أعلاه أكثر خطورة:في البداية قد تحتوي المصفوفات $\mathbf{M}^{(l)}$ على مجموعة متنوعة من القيم الذاتية eigenvalues. قد تكون صغيرة أو كبيرة، وقد يكون منتجها كبيرًا جدًا أو صغيرًا جدًا.

تتجاوز المخاطر التي تشكلها التدرجات غير المستقرة التمثيل العددي. كما تهدد التدرجات ذات الحجم غير المتوقع أيضًا استقرار خوارزميات التحسين الخاصة بنا. قد نواجه تحديثات

للمعلمات إما (1) كبيرة جدًا، مما يؤدي إلى تدمير نموذجنا (مشكلة التدرج exploding gradient problem)؛ أو (2) صغيرة للغاية (مشكلة التدرج المتلاشي vanishing gradient problem)، مما يجعل التعلم مستحيلاً لأن المعلمات بالكاد تتحرك في كل تحديث.

5.4.1.1. تلاشي التدرجات Vanishing Gradients

أحد الأسباب المتكررة لمشكلة تلاشي التدرج vanishing gradient هو اختيار دالة التنشيط التي يتم إلحاقها بعد العمليات الخطية لكل طبقة. تاريخيا، كانت دالة sigmoid $1/(1+\exp(-x))$ (المقدمة في القسم 5.1) شائعة لأنها تشبه دالة العتبة thresholding function. نظرًا لأن الشبكات العصبية الاصطناعية المبكرة كانت مستوحاة من الشبكات العصبية البيولوجية، فإن فكرة الخلايا العصبية التي تطلق fire إما بشكل كامل أو لا تطلق not fire (مثل الخلايا العصبية البيولوجية) تبدو جذابة. دعونا نلقي نظرة فاحصة على دالة sigmoid لنرى لماذا يمكن أن يتسبب في تلاشي التدرجات.

```
%matplotlib inline
import tensorflow as tf
from d2l import tensorflow as d2l

x = tf.Variable(tf.range(-8.0, 8.0, 0.1))
with tf.GradientTape() as t:
    y = tf.nn.sigmoid(x)
d2l.plot(x.numpy(), [y.numpy(), t.gradient(y,
x).numpy()],
         legend=['sigmoid', 'gradient'], figsize=(4.5,
2.5))
```

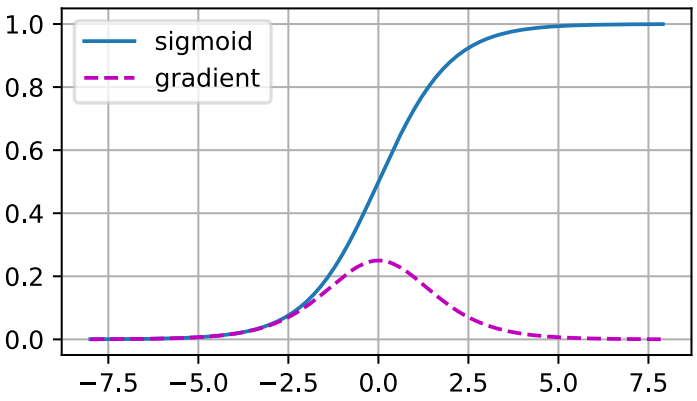

كما ترون، يتلاشى تدرج sigmoid عندما تكون مدخلاته كبيرة وعندما تكون صغيرة. علاوة على ذلك، عند الانتشار الخلفي عبر العديد من الطبقات، ما لم نكن في منطقة معتدلة ، حيث تقترب مدخلات العديد من sigmoid من الصفر ، فقد تختفي تدرجات المنتج الكلي. عندما تفتخر شبكتنا بالعديد من الطبقات، ما لم نتوخى الحذر، فمن المحتمل أن يتم قطع التدرج في طبقة ما.في الواقع، كانت هذه المشكلة تصيب التدريب الشبكي العميق. وبالتالي، فإن ReLU، التي هي أكثر استقرارًا (ولكنها أقل قبولًا من الناحية العصبية)، ظهرت كخيار افتراضي للممارسين.

5.4.1.2. انفجار التدرجات Exploding Gradients

المشكلة المعاكسة، عندما تنفجر التدرجات، يمكن أن تكون محيرة بالمثل. لتوضيح هذا بشكل أفضل قليلاً، نرسم 100 مصفوفة عشوائية غاوسية ونضربها ببعض المصفوفة الأولية. بالنسبة للمقياس الذي اخترناه (اختيار التباين $\sigma^2 = 1$)، ينفجر منتج المصفوفة. عندما يحدث هذا بسبب تهيئة شبكة عميقة، فليس لدينا فرصة للحصول على مُحسِّن هبوط التدرج gradient descent optimizer ليتقارب.

```
M = tf.random.normal((4, 4))
print('a single matrix \n', M)
for i in range(100):
    M = tf.matmul(M, tf.random.normal((4, 4)))

print('after multiplying 100 matrices\n', M.numpy())
```

```
a single matrix
 tf.Tensor(
[[-3.7870526e-01 -8.8691898e-02 -1.1780064e+00
4.2226687e-01]
 [ 1.5102199e+00  2.2903053e-01 -9.1348571e-01 -
2.0801425e-01]
 [-1.3337844e-03  8.2335420e-02 -2.4707975e+00 -
1.1889901e+00]
 [ 7.2899163e-01 -7.2341427e-02  9.2103463e-01 -
1.6827035e-01]], shape=(4, 4), dtype=float32)
after multiplying 100 matrices
 [[-1.4607350e+24 -5.4140549e+23 -1.7785702e+23
1.0161147e+24]
 [ 2.3161050e+24  8.5843912e+23  2.8200557e+23 -
1.6111261e+24]
 [-1.0695384e+24 -3.9641278e+23 -1.3022544e+23
7.4399098e+23]
```

```
 [ 1.6060195e+24  5.9525373e+23  1.9554657e+23 -
1.1171773e+24]]
```

5.4.1.3. كسر التماثل Breaking the Symmetry

مشكلة أخرىفي تصميم الشبكة العصبية هي التناظر او التماثل symmetry المتأصلفي معاملاتهم. افترض أن لدينا MLP بسيطًا بطبقة مخفية واحدة ووحدتين.في هذه الحالة، يمكننا تبديل أوزان $\mathbf{W}^{(1)}$ الطبقة الأولى وكذلك تبديل أوزان طبقة المخرجات للحصول على الدالة نفسها. لا يوجد شيء مميز يفرق بين الوحدة المخفية الأولى والوحدة المخفية الثانية. بعبارة أخرى، لدينا تناظر تبادلي بين الوحدات المخفية لكل طبقة.

هذا أكثر من مجرد مصدر إزعاج نظري. ضعفي اعتبارك MLP ذات الطبقة المخفية الواحدة المذكورة أعلاه مع وحدتين مخفيتين. للتوضيح، افترض أن طبقة المخرجات تحول الوحدتين المخفيتين إلى وحدة إخراج واحدة فقط. تخيل ما سيحدث إذا قمنا بتهيئة جميع معلمات الطبقة المخفيةكـ $\mathbf{W}^{(1)} = c$ بالنسبة لبعض الثوابت c.في هذه الحالة، أثناء الانتشار الأمامي، تأخذ إما الوحدة المخفية نفس المدخلات والمعلمات، وتنتج نفس التنشيط، الذي يتم تغذيته إلى وحدة الإخراج. أثناء الانتشار الخلفي، فإن التمييز بين وحدة الإخراج فيما يتعلق بالمعلمات $\mathbf{W}^{(1)}$ يعطي التدرج الذي تأخذ جميع عناصره نفس القيمة. وهكذا، بعد التكرار القائم على التدرج (على سبيل المثال، التدرج الاشتقاقي العشوائي المصغر)، لا تزال جميع العناصر تأخذ نفس القيمة. لن تكسر مثل هذه التكرارات التناظر من تلقاء نفسها وقد لا نتمكن أبدًا من إدراك القوة التعبيرية للشبكة. تتصرف الطبقة المخفيةكما لو كانت تحتوي على وحدة واحدة فقط. لاحظ أنهفي حين أن التدرج الاشتقاقي العشوائي المصغر لن يكسر هذا التناظر، فإن تسوية التسرب dropout regularization (التي سيتم تقديمها لاحقًا) ستفعل!

5.4.2. تهيئة المعلمة Parameter Initialization

إحدى طرق معالجة ـ أو على الأقل التخفيف ـ المشكلات التي أثيرت أعلاه هي من خلال التهيئة الدقيقة careful initialization. كما سنرى لاحقًا، يمكن أن تؤدي الرعاية الإضافية أثناء التحسين والتنظيم المناسب إلى زيادة تعزيز الاستقرار.

5.4.2.1. التهيئة الافتراضية Default Initialization

في الأقسام السابقة، على سبيل المثال،في القسم 3.5، استخدمنا التوزيع الطبيعي normal distribution لتهيئة قيم الأوزان الخاصة بنا. إذا لم نحدد طريقة التهيئة، فسيستخدم إطار العمل طريقة تهيئة عشوائية افتراضية، والتي غالبًا ما تعمل جيدًافي الممارسة العملية لأحجام المشكلات المعتدلة.

5.4.2.2. تهيئة Xavier

دعنا نلقي نظرة على توزيع مقياس الناتج o_i لبعض الطبقات المتصلة بالكامل بدون اللاخطية. مع n_{in} المدخلات x_j والأوزان w_{ij} المرتبطة بها لهذه الطبقة، يتم إعطاء الإخراج بواسطة

$$o_i = \sum_{j=1}^{n_{\text{in}}} w_{ij} x_j.$$

يتم رسم جميع الأوزان w_{ij} بشكل مستقل عن نفس التوزيع. علاوة على ذلك، لنفترض أن هذا التوزيع ليس له أي متوسط وتباين σ^2. لاحظ أن هذا لا يعني أن التوزيع يجب أن يكون غاوسيًا، فقط أن المتوسط والتباين يجب أن يكونا موجودين.في الوقت الحالي، لنفترض أن مدخلات الطبقة x_j لها أيضًا متوسط صفر وتباين γ^2 وأنها مستقلة عن w_{ij} ومستقلة عن بعضها البعض. في هذه الحالة، يمكننا حساب المتوسط والتباين o_i على النحو التالي:

$$\begin{aligned}
E[o_i] &= \sum_{j=1}^{n_{\text{in}}} E[w_{ij} x_j] \\
&= \sum_{j=1}^{n_{\text{in}}} E[w_{ij}] E[x_j] \\
&= 0, \\
\text{Var}[o_i] &= E[o_i^2] - (E[o_i])^2 \\
&= \sum_{j=1}^{n_{\text{in}}} E[w_{ij}^2 x_j^2] - 0 \\
&= \sum_{j=1}^{n_{\text{in}}} E[w_{ij}^2] E[x_j^2] \\
&= n_{\text{in}} \sigma^2 \gamma^2.
\end{aligned}$$

طريقة واحدة للحفاظ على التباين ثابتًا هي تعيين $n_{\text{in}}\sigma^2 = 1$. الآن النظرفي الانتشار الخلفي. هناك نواجه مشكلة مماثلة، وإن كان يتم نشر التدرجات من الطبقات الأقرب إلى الإخراج. باستخدام نفس المنطق الخاص بالانتشار الأمامي، نرى أن تباين التدرجات يمكن أن ينفجر ما لم يكن $n_{\text{out}}\sigma^2 = 1$ حيث n_{out} عدد مخرجات هذه الطبقة، أين. هذا يتركنافي مأزق: لا يمكننا تلبية كلا الشرطينفي وقت واحد. بدلاً من ذلك، نحاول ببساطة أن نحقق

$$\frac{1}{2}(n_{\text{in}} + n_{\text{out}})\sigma^2 = 1 \text{ or equivalently } \sigma = \sqrt{\frac{2}{n_{\text{in}} + n_{\text{out}}}}.$$

هذا هو السبب الكامن وراء تهيئة Xavier الحالية والمفيدة عمليًا، والتي سميت على اسم المؤلف الأول لمنشئيها (Glorot and Bengio، 2010). نموذجياً، عينات التهيئة Xavier الأوزان من توزيع غاوسي بمتوسط صفر وتباين $\sigma^2 = \frac{2}{n_{\text{in}}+n_{\text{out}}}$. يمكننا أيضًا تكييف حدس Xavier لاختيار التباين عند أخذ عينات من الأوزان من توزيع منتظم. لاحظ أن التوزيع المنتظم $U(-a, a)$ له تباين $\frac{a^2}{3}$. يؤدي توصيل $\frac{a^2}{3}$ في حالتنا على σ^2 إلى اقتراح التهيئة وفقًا لـ

$$U(-\sqrt{\frac{6}{n_{\text{in}}+n_{\text{out}}}}, \sqrt{\frac{6}{n_{\text{in}}+n_{\text{out}}}}).$$

على الرغم من أن افتراض عدم وجود اللاخطيةفي التفكير الرياضي أعلاه يمكن انتهاكه بسهولةفي الشبكات العصبية، إلا أن طريقة تهيئة Xavier تعمل بشكل جيدفي الممارسة العملية.

5.4.2.3. وَرَاءَ Beyond

المنطق أعلاه بالكاد يخدش سطح الأساليب الحديثة لتهيئة المعلمة parameter initialization. غالبًا ما ينفذ إطار التعلم العميق أكثر من اثنتي عشرة عملية استكشاف مختلفة. علاوة على ذلك، لا تزال تهيئة المعلمة منطقة ساخنة للبحث الأساسيفي التعلم العميق. من بين هذه الاستدلالات المتخصصة للمعلمات المقيدة (المشتركة) والدقة الفائقة super-resolution ونماذج التسلسل sequence models وغيرها من المواقف. على سبيل المثال، Xiao et al. أظهر إمكانية تدريب 10000 طبقة من الشبكات العصبية بدون حيل معمارية باستخدام طريقة تهيئة مصممة بعناية (Xiao et al.، 2018).

إذا كان الموضوع يثير اهتمامك، فإننا نقترح التعمقفي عروض هذه الوحدة، وقراءة الأوراق التي اقترحت وحلل كل إرشادية، ثم استكشاف أحدث المنشورات حول هذا الموضوع. ربما سوف تتعثر أو تخترع فكرة ذكية وتساهمفي تنفيذ أطر التعلم العميق.

5.4.3. الملخص

- يعد تلاشي وانفجار التدرجات من المشكلات الشائعةفي الشبكات العميقة. مطلوب عناية كبيرةفي تهيئة المعلمات لضمان أن تظل التدرجات والمعلمات خاضعة للرقابة بشكل جيد.
- هناك حاجة إلى أساليب التهيئة الاستدلال الحدسية Initialization heuristics للتأكد من أن التدرجات الأولية ليست كبيرة جدًا ولا صغيرة جدًا.
- تعمل دوال تنشيط ReLU على تخفيف مشكلة تلاشي التدرج. هذا يمكن أن يسرع من التقارب.

- التهيئة العشوائية Random initialization هي المفتاح لضمان كسر التناظر symmetry قبل التحسين.
- تشير تهيئة Xavier إلى أنه، لكل طبقة، لا يتأثر التباينفي أي ناتج بعدد المدخلات، ولا يتأثر تباين أي تدرج بعدد المخرجات.

5.4.4. التمارين

1. هل يمكنك تصميم حالات أخرى قد تعرض فيها الشبكة العصبية تناظرًا يتطلب كسرًا breaking إلى جانب تناظر التقليب permutation symmetryفي طبقات MLP؟
2. هل يمكننا تهيئة جميع معلمات الوزنفي الانحدار الخطي أوفي انحدار softmax إلى نفس القيمة؟
3. ابحث عن الحدود التحليلية للقيم الذاتية لحاصل ضرب مصفوفتين. ماذا يخبرك هذا عن ضمان تكييف التدرجات بشكل جيد؟
4. إذا علمنا أن بعض المصطلحات تتباعد diverge، فهل يمكننا إصلاح هذا بعد الحقيقة؟ انظر إلى الورقة حول مقياس المعدل التكيفي للطبقات للإلهام (You et al.، 2017).

5.5 التعميم في التعلم العميق Generalization in Deep Learning

في القسم 3 والقسم 4، عالجنا مشاكل الانحدار والتصنيف من خلال ملاءمة fitting النماذج الخطية لبيانات التدريب.في كلتا الحالتين، قدمنا خوارزميات عملية للعثور على المعلمات التي زادت من احتمالية تسميات التدريب المرصودة. وبعد ذلك، قرب نهاية كل فصل، تذكرنا أن ملاءمة بيانات التدريب كانت مجرد هدف وسيط. كان سعينا الحقيقي طوال الوقت هو اكتشاف الأنماط العامة التي يمكننا على أساسها إجراء تنبؤات دقيقة حتى على الأمثلة الجديدة المستمدة من نفس المجموعة الأساسية. باحثو التعلم الآلي هم مستهلكون لخوارزميات التحسين.في بعض الأحيان، يجب علينا تطوير خوارزميات تحسين جديدة. ولكنفي نهاية المطاف، فإن التحسين هو مجرد وسيلة لتحقيق غاية. يعد التعلم الآليفي جوهره نظامًا إحصائيًا ونرغبفي تحسين خطأ التدريب فقط بقدر ما يؤدي بعض المبادئ الإحصائية (المعروفة أو غير المعروفة) إلى التعميم الناتج عن مجموعة التدريب.

على الجانب المشرق، اتضح أن الشبكات العصبية العميقة المدربة عن طريق التدرج الاشتقاقي العشوائي SGD تعمم جيدًا بشكل ملحوظ عبر مشاكل التنبؤ التي لا تعد ولا تحصى، والتي تشمل الرؤية الحاسوبية computer vision؛ معالجة اللغة الطبيعية natural language processing ؛ بيانات السلاسل الزمنية time series data ؛ أنظمة التوصية recommender systems؛ السجلات الصحية الإلكترونية electronic health records؛ طي البروتين

Protein folding؛ تقريب دالة القيمةفي ألعاب الفيديو وألعاب الطاولة ؛ ومجالات أخرى لا حصر لها. على الجانب السلبي، إذا كنت تبحث عن حساب مباشر إما لقصة التحسين (لماذا يمكننا ملاءمتها لبيانات التدريب) أو قصة التعميم (لماذا تعمم النماذج الناتجة على أمثلة غير مرئية)، إذن قد ترغبفي سكب شاي لنفسك.في حين أن إجراءاتنا لتحسين النماذج الخطية والخصائص الإحصائية للحلول موصوفة جيداً من خلال مجموعة نظرية شاملة، فإن فهمنا للتعلم العميق لا يزال يشبه الغرب المتوحش على كلا الجبهتين.

تتطور نظرية وممارسة التعلم العميق بسرعة على كلا الجبهتين، حيث يتبنى المنظرون استراتيجيات جديدة لشرح ما يحدث، حتى مع استمرار الممارسينفي الابتكار بوتيرة مذهلة، وبناء ترسانات من الاستدلال لتدريب الشبكات العميقة ومجموعة من البديهيات والمعارف الشعبية التي تقدم إرشادات لتحديد التقنيات التي يجب تطبيقهافي أي مواقف.

لفترة طويلة ، لم نقرأ في الوقت الحالي هو أن نظرية التعلم العميق قد أنتجت خطوط هجوم واعدة ونتائج رائعة متفرقة ، لكنها لا تزال بعيدة كل البعد عن تفسير شامل لكل من (1) سبب قدرتنا على تحسين الشبكات العصبية و (2)) كيف تمكنت النماذج التي تم تعلمها من خلال SGD من التعميم جيداً ، حتىفي المهام عالية الأبعاد. ومع ذلك، من الناحية العملية، (1) نادرًا ما يمثل مشكلة (يمكننا دائمًا العثور على المعلمات التي تناسب جميع بيانات التدريب لدينا) وبالتالي فإن فهم التعميم هو المشكلة الأكبر. من ناحية أخرى، حتىفي غياب الراحة التي توفرها النظرية العلمية المتماسكة، فقد طور الممارسون مجموعة كبيرة من التقنيات التي قد تساعدك على إنتاج نماذج تُعمم جيداًفي الممارسة.في حين أنه لا يمكن لأي ملخص بليغ أن ينصف موضوع التعميم الكبيرفي التعلم العميق، وبينما لا تزال الحالة العامة للبحث بعيدة عن الحل، نأمل،في هذا القسم، أن نقدم نظرة عامة واسعة عن حالة البحث والممارسة.

5.5.1. إعادة النظر في فرط التجهيز والتنظيم Revisiting Overfitting and Regularization

تذكر أن نهجنافي تدريب نماذج التعلم الآلي يتكون عادةً من مرحلتين: (1) ملاءمة fit بيانات التدريب؛ و (2) تقدير خطأ التعميم generalization error (الخطأ الحقيقي على السكان الأساسيين) من خلال تقييم النموذج على بيانات الانتظار. يُطلق على الفرق بين ملاءمتنا لبيانات التدريب ومدى ملاءمتنا لبيانات الاختبار فجوة التعميم generalization gap وعندما تكون فجوة التعميم كبيرة، نقول إن نماذجنا تتلاءم مع بيانات التدريب.في الحالات القصوى من فرط التجهيز overfitting، قد نلائم بيانات التدريب تمامًا، حتى عندما يظل خطأ الاختبار كبيرًا. ومن وجهة النظر الكلاسيكية، فإن التفسير هو أن نماذجنا معقدة للغاية، وتتطلب إما تقليص عدد

الميزات، أو عدد المعلمات غير الصفرية التي تم تعلمها، أو حجم المعلمات كما تم تحديدها كمياً. تذكر مخطط تعقيد النموذج مقابل الخطأ (الشكل 3.6.1) من القسم 3.6.

لكن التعلم العميق يعقد هذه الصورة بطرق غير بديهية. أولاً، بالنسبة إلى مشاكل التصنيف، عادةً ما تكون نماذجنا معبرة بما يكفي لتناسب تمامًا كل مثال تدريبي، حتىفي مجموعات البيانات التي تتكون من الملايين (Zhang et al.، 2021).في الصورة الكلاسيكية، قد نعتقد أن هذا الإعداد يقعفي أقصى اليمين المتطرف لمحور تعقيد النموذج، وأن أي تحسيناتفي خطأ التعميم يجب أن تأتي عن طريق التنظيم regularization، إما عن طريق تقليل تعقيد فئة النموذج، أو عن طريق تطبيق عقوبة penalty، تقيد بشدة مجموعة القيم التي قد تتخذها معلماتنا. ولكن هذا هو المكان الذي تبدأ فيه الأمورفي أن تصبح غريبة.

الغريب، بالنسبة للعديد من مهام التعلم العميق (على سبيل المثال، التعرف على الصور وتصنيف النص) نختار عادةً من بين البنى النموذجية، والتي يمكن أن تحقق جميعها خطأ تدريب منخفض بشكل تعسفي (وخطأ تدريب صفري). نظرًا لأن جميع النماذج قيد الدراسة لا تحقق أي خطأفي التدريب، فإن السبيل الوحيد لتحقيق المزيد من المكاسب هو تقليل الضبط الزائد (فرط التجهيز). والأغرب من ذلك، أنه على الرغم من ملاءمة بيانات التدريب بشكل مثالي، يمكنناقي الواقع تقليل خطأ التعميم بشكل أكبر عن طريق جعل النموذج أكثر تعبيرًا، على سبيل المثال، إضافة طبقات أو عقد أو تدريب لعدد أكبر من الفترات epochs. الغريب حتى الآن، أن النمط الذي يربط فجوة التعميم بتعقيد النموذج (كما تم التقاطه، على سبيل المثال،في عمق أو عرض الشبكات) يمكن أن يكون غير رتيب non-monotonic، مع تعقيد أكبر يضرفي البداية ولكنه يساعد لاحقًا فيما يسمى نمط "النسب المزدوج double-descent" ((Nakkiran et al.، 2021). وبالتالي فإن ممارس التعلم العميق يمتلك مجموعة من الحيل، والتي يبدو أن بعضها يقيد النموذج بطريقة ما والبعض الآخر يجعله يبدو أكثر تعبيراً، وكلها، بمعنى ما، يتم تطبيقها لتخفيف فرط التجهيز.

ومما يزيد الأمور تعقيدًا،في حين أن الضمانات التي توفرها نظرية التعلم الكلاسيكية يمكن أن تكون متحفظة حتى بالنسبة للنماذج الكلاسيكية، فإنها تبدو عاجزة عن تفسير سبب تعميم الشبكات العصبية العميقةفي المقام الأول. نظرًا لأن الشبكات العصبية العميقة قادرة على تركيب تسميات عشوائية حتى لمجموعات البيانات الكبيرة، وعلى الرغم من استخدام طرق مألوفة مثل التنظيم، فإن حدود التعميم التقليدية القائمة على التعقيد، على سبيل المثال، تلك القائمة على بُعد VC أو تعقيد Rademacher لفئة فرضية لا يمكنها تفسير السبب تعمم الشبكات العصبية.

5.5.2. إلهام من غير البارامترية Inspiration from Nonparametrics

عند الاقتراب من التعلم العميق لأول مرة، من المغري اعتبارها نماذج بارامترية. بعد كل شيء، النماذج لديها الملايين من المعلمات. عندما نقوم بتحديث النماذج، نقوم بتحديث معلماتها. عندما نحفظ النماذج، نكتب معلماتها على القرص. ومع ذلك، فإن الرياضيات وعلوم الكمبيوتر مليئة بالتغييرات غير البديهيةفي المنظور، وتبدو التشابهات المفاجئة مشاكل مختلفة على ما يبدو. بينما تحتوي الشبكات العصبية بوضوح على معلمات، من بعض النواحي، قد يكون من المفيد التفكير فيها على أنها تتصرف مثل النماذج اللامعلمية (غير البارامترية). إذن ما الذي يجعل نموذجًا غير معلمي على وجه التحديد؟ بينما يغطي الاسم مجموعة متنوعة من الأساليب، فإن أحد الموضوعات الشائعة هو أن الأساليب اللامعلمية تميل إلى أن يكون لها مستوى من التعقيد ينمو مع زيادة كمية البيانات المتاحة.

ربما يكون أبسط مثال على نموذج غير معلمي هو خوارزمية الجار الأقرب k-nearest neighbor(سنغطي المزيد من النماذج اللامعلمية لاحقًا، كمافي القسم 11.2). هنا،في وقت التدريب، يحفظ المتعلم ببساطة مجموعة البيانات. ثم،في وقت التنبؤ، عندما يواجه المتعلم نقطة جديدة $\mathbf{x}$ ، يبحث عن أقرب الجيران (k) من النقاط $\mathbf{x}_i'$ تقلل من بعض المسافة $(d(\mathbf{x}, \mathbf{x}_i'))$. عندما $k = 1$ ، تسمى هذه الخوارزمية 1-nearest neighbors، وستحقق الخوارزمية دائمًا خطأ تدريب قدره صفر. لكن هذا لا يعني أن الخوارزمية لن تعمم.في الواقع، اتضح أنهفي ظل بعض الظروف المعتدلة، تكون خوارزمية الجار الأقرب متسقة (تتقاربفي النهاية إلى المتنبئ الأمثل).

لاحظ أن أحد الجيران الأقرب يتطلب أن نحدد بعض دوال المسافة d ، أو بشكل مكافئ، أن نحدد بعض دوال الأساس ذات القيمة المتجهية $\phi(\mathbf{x})$ لتمييز بياناتنا. لأي اختيار لمقياس المسافة، سنحقق 0 خطأ تدريب ونصلفي النهاية إلى متنبئ مثالي، لكن مقاييس المسافة المختلفة d تشفر تحيزات استقرائية مختلفة وبكمية محدودة من البيانات المتاحة ستنتج تنبؤات مختلفة. تمثل الاختيارات المختلفة لمقياس المسافة d افتراضات مختلفة حول الأنماط الأساسية وسيعتمد أداء المتنبئين المختلفين على مدى توافق الافتراضات مع البيانات المرصودة.

بمعنى ما، نظرًا لأن الشبكات العصبية مفرطةفي المعلمات، وتمتلك العديد من المعلمات أكثر مما هو مطلوب لملاءمة بيانات التدريب، فإنها تميل إلى استيفاء بيانات التدريب (لتناسبها تمامًا) وبالتالي تتصرف،في بعض النواحي، مثل النماذج اللامعلمية nonparametric models. أثبتت الأبحاث النظرية الحديثة ارتباطًا عميقًا بين الشبكات العصبية الكبيرة والطرق اللامعلمية، ولا سيما طرق النواة kernel methods. على وجه الخصوص، أظهر (Jacot et al.، 2018) أنه في الحد الأقصى، مع نمو البيرسيبترون متعدد الطبقات مع أوزان مُهيأة عشوائيًا بشكل لا نهائي، تصبح مكافئة لطرق النواة (اللابارامترية) لاختيار معين لدالة النواة kernel (بشكل أساسي، دالة

المسافة)، والتي يسمونها نواة المماس العصبية neural tangent kernel.في حين أن نماذج نواة المماس العصبية الحالية قد لا تفسر بشكل كامل سلوك الشبكات العميقة الحديثة، فإن نجاحها كأداة تحليلية يؤكد فائدة النمذجة اللامعلمية لفهم سلوك الشبكات العميقة ذات المعلمات المفرطة.

5.5.3. التوقف المبكر Early Stopping

في حين أن الشبكات العصبية العميقة قادرة على ملائمة fitting تسميات عشوائية، حتى عندما يتم تعيين التسميات بشكل غير صحيح أو عشوائي (Zhang et al.، 2021)، فإن هذه القدرة تظهر فقط عبر العديد من تكرارات التدريب. كشف خط عمل جديد (Rolnick et al.، 2017) أنهفي إعداد ضوضاء التسمية، تميل الشبكات العصبية إلى احتواء البيانات المصنفة بشكل نظيف أولاً وبعد ذلك فقط لاستيفاء البيانات ذات التسمية الخاطئة mislabeled data. علاوة على ذلك، فقد ثبت أن هذه الظاهرة تُترجم مباشرة إلى ضمان على التعميم: فكلما كان النموذج مناسبًا للبيانات المصنفة بشكل واضح ولكن ليس الأمثلة المعنونة عشوائيًا المدرجةفي مجموعة التدريب، فقد تم تعميمهفي الواقع (Garg et al.، 2021).

تساعد هذه النتائج معًافي تحفيز التوقف المبكر early stopping، وهي تقنية كلاسيكية لتنظيم الشبكات العصبية العميقة. هنا، بدلاً من تقييد قيم الأوزان بشكل مباشر، يقيد المرء عدد فترات التدريب. الطريقة الأكثر شيوعًا لتحديد معايير التوقف هي مراقبة خطأ التحقق من الصحة خلال التدريب (عادةً عن طريق التحقق مرة واحدة بعد كل فترة) وقطع التدريب عندما لا ينخفض خطأ التحقق بأكثر من مقدار صغير لبعض الفترات. هذا يسمى أحيانًا معايير الصبر patience criteria. إلى جانب إمكانية أن يؤدي إلى تعميم أفضل،في وضع التسميات الصاخبة noisy labels، هناك فائدة أخرى للتوقف المبكر وهي الوقت الذي يتم توفيره. بمجرد استيفاء معايير الصبر، يمكن للمرء إنهاء التدريب. بالنسبة للنماذج الكبيرة التي قد تتطلب أيامًا من التدريبفي وقت واحد عبر 8 وحدات معالجة رسومات أو أكثر، يمكن أن يوفر التوقف المبكر الذي يتم ضبطه جيدًا على الباحثين أيامًا من الوقت ويمكن أن يوفر على أصحاب العمل عدة آلاف من الدولارات.

والجدير بالذكر أنهفي حالة عدم وجود ضوضاء على التسمية وتكون مجموعات البيانات قابلة للتحقيق (يمكن فصل الفئات حقًا، على سبيل المثال، التمييز بين القطط والكلاب)، فإن التوقف المبكر لا يؤدي إلى تحسينات كبيرةفي التعميم. من ناحية أخرى، عندما يكون هناك ضوضاءفي التسمية، أو تباين جوهريفي التسمية (على سبيل المثال، التنبؤ بالوفيات بين المرضى)، فإن التوقف المبكر أمر بالغ الأهمية. عادة ما تكون نماذج التدريب حتى تستكمل البيانات المزعجة فكرة سيئة.

5.5.4. طرق التنظيم الكلاسيكية للشبكات العميقة Classical Regularization Methods for Deep Networks

في القسم 3، وصفنا العديد من تقنيات التنظيم الكلاسيكية لتقييد تعقيد نماذجنا. على وجه الخصوص، قدم القسم 3.7 طريقة تسمى انحلال الوزن weight decay، والتي تتكون من إضافة مصطلح تنظيم إلى دالة الخطأ لمعاقبة القيم الكبيرة للأوزان. اعتمادًا على معيار الوزن الذي يتم المعاقبة عليه، تُعرف هذه التقنية إما باسم تنظيم ridge (للعقوبة ℓ_2) أو تنظيم lasso (للعقوبة ℓ_1).في التحليل الكلاسيكي لهؤلاء المنظمين، يُنظر إليهم على أنهم يقيدون القيم التي يمكن أن تأخذها الأوزان بشكل كافٍ لمنع النموذج من ملاءمة التسميات العشوائية.

في تطبيقات التعلم العميق، يظل انحلال الوزن أداة شائعة. ومع ذلك، فقد لاحظ الباحثون أن نقاط القوة النموذجية للتنظيم غير كافية لمنع الشبكات من استيفاء البيانات (Zhang et al.، 2021). وبالتالي فإن الفوائد إذا فُسرت على أنها تنظيم قد تكون منطقية فقط بالاقتران مع معايير التوقف المبكر.في غياب التوقف المبكر، من الممكن أن تؤدي هذه الأساليب إلى تعميم أفضل، ليس لأنها تقيد بشكل هادف قوة الشبكة العصبية ولكن لأنها تقوم بطريقة ما بتشفير التحيزات الاستقرائية inductive biases التي تتوافق بشكل أفضل مع الأنماط الموجودةفي مجموعات بيانات الاهتمامات. وهكذا، يظل المنظمون الكلاسيكيون شائعينفي تطبيقات التعلم العميق، حتى لو كان الأساس المنطقي النظري لفعاليتهم مختلفًا جذريًا.

والجدير بالذكر أن باحثي التعلم العميق قد اعتمدوا أيضًا على التقنيات التي تم تعميمها لأول مرة في سياقات التنظيم الكلاسيكية، مثل إضافة الضوضاء إلى مدخلات النموذج.في القسم التالي، سنقدم تقنية الحذف العشوائي(التسرب) dropout الشهيرة (التي ابتكرها سريفاستافا وآخرون (2014))، والتي أصبحت الدعامة الأساسية للتعلم العميق، حتى مع بقاء الأساس النظري لفعاليتها غامضًا بالمثل.

5.5.5. الملخص

على عكس النماذج الخطية الكلاسيكية، التي تميل إلى أن تحتوي على معلمات أقل من الأمثلة، تميل الشبكات العميقة إلى الإفراطفي تحديد المعلمات، وفي معظم المهام تكون قادرة على ملاءمة مجموعة التدريب بشكل مثالي. يتحدى نظام الاستيفاء interpolation regime هذا العديد من البديهيات الشديدة السرعة. من الناحية الوظيفية، تبدو الشبكات العصبية مثل النماذج البارامترية. لكن التفكير فيها كنماذج غير معلمية يمكن أن يكون أحيانًا مصدرًا أكثر موثوقية للحدس. نظرًا لأنه غالبًا ما تكون جميع الشبكات العميقة قيد الدراسة قادرة على ملاءمة جميع تسميات التدريب، يجب أن تأتي جميع المكاسب تقريبًا عن طريق التخفيف من فرط التجهيز (سد فجوة التعميم). ومن المفارقات أن التدخلات التي تقلل فجوة التعميم تظهر أحيانًا أنها تزيد

من تعقيد النموذج وفي أوقات أخرى يبدو أنها تقلل من التعقيد. ومع ذلك، نادرًا ما تقلل هذه الأساليب التعقيد بما يكفي للنظرية الكلاسيكية لشرح تعميم الشبكات العميقة، ولماذا تؤدي بعض الخيارات إلى تحسين التعميم يظل في الغالب سؤالًا مفتوحًا كبيرًا على الرغم من الجهود المتضافرة للعديد من الباحثين اللامعين.

5.5.6. التمارين

1. بأي معنى تفشل المقاييس التقليدية القائمة على التعقيد في تفسير تعميم الشبكات العصبية العميقة؟
2. لماذا يمكن اعتبار التوقف المبكر تقنية تنظيم regularization technique؟
3. كيف يحدد الباحثون عادة معايير التوقف stopping criteria؟
4. ما هو العامل المهم الذي يبدو أنه يميز الحالات عندما يؤدي التوقف المبكر إلى تحسينات كبيرة في التعميم generalization؟
5. بعد التعميم، صف فائدة أخرى للتوقف المبكر early stopping.

5.6 الحذف العشوائي Dropout

دعونا نفكر بإيجاز فيما نتوقعه من نموذج تنبؤي جيد good predictive model. نريدها أن تعمل بشكل جيد على البيانات غير المرئية unseen data. تقترح نظرية التعميم الكلاسيكية أنه لسد الفجوة بين أداء التدريب والاختبار، يجب أن نهدف إلى نموذج بسيط. يمكن أن تأتي البساطة في شكل عدد صغير من الأبعاد. اكتشفنا ذلك عند مناقشة دوال الأساس الأحادي monomial basis functions للنماذج الخطية في القسم 3.6. بالإضافة إلى ذلك، كما رأينا عند مناقشة تناقص الوزن (التنظيم ℓ_2) في القسم 3.7، فإن المعيار norm (العكسي) للمعلمات يمثل أيضًا مقياسًا مفيدًا للبساطة. مفهوم آخر مفيد للبساطة هو النعومة smoothness، أي أن الدالة لا ينبغي أن تكون حساسة للتغييرات الصغيرة في مدخلاتها. على سبيل المثال، عندما نصنف الصور، نتوقع أن تكون إضافة بعض الضوضاء العشوائية إلى وحدات البكسل غير ضارة في الغالب.

في عام 1995، صاغ كريستوفر بيشوب هذه الفكرة عندما أثبت أن التدريب باستخدام ضوضاء الإدخال يعادل تنظيم تيخونوف Tikhonov regularization (Bishop، 1995). رسم هذا العمل ارتباطًا رياضيًا واضحًا بين شرط أن تكون الدالة سلسة smooth (وبالتالي بسيطة)، ومتطلبات أن تكون مرنة resilient للاضطرابات في المدخلات.

ثم، في عام 2014، سريفاستافا وآخرون. (Srivastava et al.، 2014) فكرة ذكية عن كيفية تطبيق فكرة بيشوب على الطبقات الداخلية للشبكة أيضًا. تتضمن فكرتهم، المسماة الحذف العشوائي (التسرب) dropout، حقن الضوضاء أثناء حساب كل طبقة داخلية أثناء الانتشار الأمامي، وقد أصبحت تقنية قياسية لتدريب الشبكات العصبية. تسمى هذه الطريقة بـ dropout

لأننا حرفيا نتخلى عن بعض الخلايا العصبية أثناء التدريب. خلال التدريب،في كل تكرار، يتكون الحذف العشوائي القياسي من تصفية جزء من العقدفي كل طبقة قبل حساب الطبقة التالية.

لكي نكون واضحين، نحن نفرض روايتنا الخاصة بالارتباط ببيشوب. تقدم الورقة الأصلية حول dropout حدسًا من خلال تشبيه مدهش للتكاثر الجنسي. يجادل المؤلفون بأن فرط التجهيز للشبكة العصبية يتميز بحالة تعتمد فيها كل طبقة على نمط معين من التنشيطاتفي الطبقة السابقة، مما يطلق على هذا الشرط التكيف المشترك condition co-adaptation. وهم يزعمون أن dropout يؤدي إلى تفكك التكيف المشترك تمامًا كما يُقال إن التكاثر الجنسي يفكك الجينات المتكيفة معًا.في حين أن شرح هذه النظرية مطروح للنقاش بالتأكيد، فقد أثبت أسلوب dropout نفسه أنه ثابت، ويتم تنفيذ أشكال مختلفة من dropoutفي معظم مكتبات التعلم العميق.

التحدي الرئيسي هو كيفية ضخ هذه الضوضاء. تتمثل إحدى الأفكارفي حقن الضوضاء بطريقة غير منحازة بحيث تكون القيمة المتوقعة لكل طبقة ــ أثناء تثبيت الطبقات الأخرى ــ مساوية للقيمة التي كانت ستأخذهافي غياب الضوضاء.في عمل بيشوب، أضاف ضوضاء غاوسية إلى المدخلات إلى نموذج خطي.في كل تكرار تدريبي، أضاف ضوضاء مأخوذة من توزيع بمتوسط صفر $\epsilon \sim \mathcal{N}(0, \sigma^2)$ إلى المدخلات $\mathbf{x}$ ، مما أسفر عن نقطة مضطربة $\mathbf{x}' = \mathbf{x} + \epsilon$.في توقع $E[\mathbf{x}'] = \mathbf{x}$.

في تنظيم dropout القياسي، يقوم أحد الأصفار بإزالة بعض أجزاء العقدفي كل طبقة ثم يقوم بإزالة الحواف من كل طبقة عن طريق التسوية بواسطة جزء العقد التي تم الاحتفاظ بها (غير المسقطة او المحذوفة not dropped out). بمعنى آخر، مع احتمال الحذف العشوائي p ، يتم استبدال كل تنشيط وسيط h بمتغير عشوائي h' على النحو التالي:

$$h' = \begin{cases} 0 & \text{with probability } p \\ \dfrac{h}{1-p} & \text{otherwise} \end{cases}$$

حسب التصميم، يظل التوقع دون تغيير، أي $E[h'] = h$.

5.6.1. الحذف العشوائي في الممارسة Dropout in Practice

تذكر MLP بطبقة مخفية و5 وحدات مخفيةفي الشكل 5.1.1. عندما نطبق dropout على طبقة مخفية، مع استبعاد كل وحدة مخفية باحتمالية، يمكن عرض النتيجة كشبكة تحتوي فقط على مجموعة فرعية من الخلايا العصبية الأصلية.في الشكل 5.6.1،h_2 و h_5 تتم إزالتها. وبالتالي، فإن حساب النواتج لم يعد يعتمد على h_2 أو h_5 والتدرج الخاص بكل منها يختفي

أيضًا عند إجراء الانتشار الخلفي. بهذه الطريقة، لا يمكن أن يعتمد حساب طبقة المخرجات بشكل مفرط على أي عنصر واحد من $h_1, \ldots, h_5$.

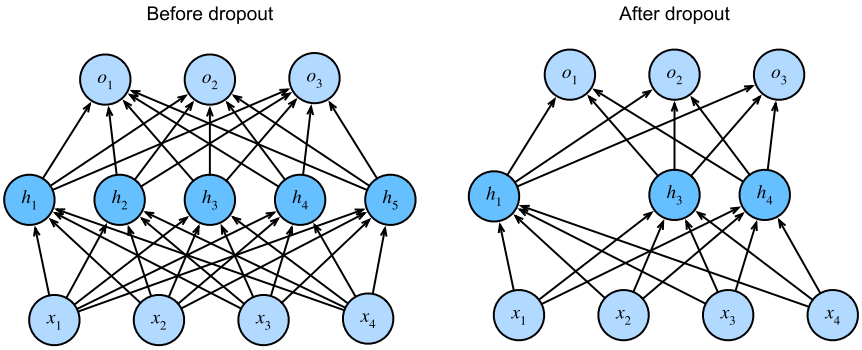

الشكل 5.6.1 MLP قبل وبعد dropout.

عادة، نقوم بتعطيل dropoutفي وقت الاختبار. بالنظر إلى نموذج مدرب ومثال جديد، فإننا لا نتجاهل أي عقد وبالتالي لا نحتاج إلى التسوية normalization. ومع ذلك، هناك بعض الاستثناءات: يستخدم بعض الباحثين dropoutفي وقت الاختبار كإرشاد لتقدير عدم اليقين uncertaintyفي تنبؤات الشبكة العصبية: إذا اتفقت التوقعات عبر العديد من أقنعة dropout المختلفة، فقد نقول إن الشبكة أكثر ثقة.

5.6.2. التنفيذ من البداية Implementation from Scratch

لتنفيذ دالة dropout لطبقة واحدة، يجب علينا سحب أكبر عدد ممكن من العينات من متغير برنولي العشوائي (ثنائي) حيث تحتوي الطبقة الخاصة بنا على أبعاد، حيث يأخذ المتغير العشوائي قيمة 1 (احتفظ بها) مع الاحتمال $1 - p$ و0 (إسقاط dropout) مع الاحتمال p. تتمثل إحدى الطرق السهلة لتنفيذ ذلكفي سحب عينات أولاً من التوزيع المنتظم $U[0,1]$. ثم يمكننا الاحتفاظ بتلك العقد التي تكون العينة المقابلة لها أكبر من p ، وإسقاط الباقي.

في الكود التالي، نقوم بتنفيذ دالة `dropout_layer` التي تسقط العناصرفي إدخال الموتر `X` مع احتمال `dropout`، مع إعادة قياس الباقي كما هو موضح أعلاه: قسمة الناجين على `1.0-dropout`.

```
import tensorflow as tf
from d2l import tensorflow as d2l


def dropout_layer(X, dropout):
    assert 0 <= dropout <= 1
```

```
    if dropout == 1: return tf.zeros_like(X)
    mask = tf.random.uniform(
        shape=tf.shape(X), minval=0, maxval=1) < 1 -
dropout
    return tf.cast(mask, dtype=tf.float32) * X / (1.0 -
dropout)
```

يمكننا اختبار دالة dropout_layer r على بعض الأمثلة.في سطور الكود التالية، نقوم بتمرير الإدخال X الخاص بنا من خلال عملية التسرب dropout، مع الاحتمالات 0 و 0.5 و 1 على التوالي.

```
X = tf.reshape(tf.range(16, dtype=tf.float32), (2, 8))
print('dropout_p = 0:', dropout_layer(X, 0))
print('dropout_p = 0.5:', dropout_layer(X, 0.5))
print('dropout_p = 1:', dropout_layer(X, 1))
```

```
dropout_p = 0: tf.Tensor(
[[ 0.  1.  2.  3.  4.  5.  6.  7.]
 [ 8.  9. 10. 11. 12. 13. 14. 15.]], shape=(2, 8),
dtype=float32)
dropout_p = 0.5: tf.Tensor(
[[ 0.  0.  0.  6.  0.  0. 12.  0.]
 [16. 18. 20.  0.  0.  0.  0.  0.]], shape=(2, 8),
dtype=float32)
dropout_p = 1: tf.Tensor(
[[0. 0. 0. 0. 0. 0. 0. 0.]
 [0. 0. 0. 0. 0. 0. 0. 0.]], shape=(2, 8),
dtype=float32)
```

5.6.2.1. تعريف النموذج Defining the Model

يطبق النموذج أدناه dropout على إخراج كل طبقة مخفية (باتباع دالة التنشيط). يمكننا تعيين احتمالات dropout لكل طبقة على حدة. يتمثل الاتجاه الشائعفي تعيين احتمالية dropout أقل بالقرب من طبقة الإدخال. نحن نضمن أن dropout نشط فقط أثناء التدريب.

```
class DropoutMLPScratch(d2l.Classifier):
    def __init__(self, num_outputs, num_hiddens_1,
num_hiddens_2,
                 dropout_1, dropout_2, lr):
        super().__init__()
        self.save_hyperparameters()
        self.lin1 = tf.keras.layers.Dense(num_hiddens_1,
activation='relu')
```

```
        self.lin2 = tf.keras.layers.Dense(num_hiddens_2,
activation='relu')
        self.lin3 = tf.keras.layers.Dense(num_outputs)

    def forward(self, X):
        H1 = self.lin1(tf.reshape(X, (X.shape[0], -1)))
        if self.training:
            H1 = dropout_layer(H1, self.dropout_1)
        H2 = self.lin2(H1)
        if self.training:
            H2 = dropout_layer(H2, self.dropout_2)
        return self.lin3(H2)
```

5.6.2.2. التدريب Training

ما يلي مشابه لتدريب MLPs الموصوف سابقًا.

```
hparams = {'num_outputs':10, 'num_hiddens_1':256,
'num_hiddens_2':256,
           'dropout_1':0.5, 'dropout_2':0.5, 'lr':0.1}
model = DropoutMLPScratch(**hparams)
data = d2l.FashionMNIST(batch_size=256)
trainer = d2l.Trainer(max_epochs=10)
trainer.fit(model, data)
```

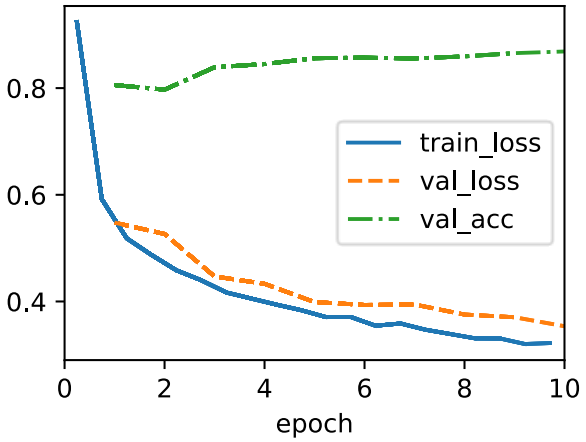

5.6.3. التنفيذ المختصر Concise Implementation

باستخدام واجهات برمجة التطبيقات API عالية المستوى، كل ما نحتاج إلى القيام به هو إضافة طبقة Dropout بعد كل طبقة متصلة بالكامل، لتمرير احتمال Dropout باعتباره الوسيطة الوحيدة لمنشئها. أثناء التدريب، ستسقط طبقة Dropout بشكل عشوائي مخرجات الطبقة السابقة (أو بشكل مكافئ، المدخلات إلى الطبقة اللاحقة) وفقًا لاحتمال Dropout المحدد.

عندما لا تكونفي وضع التدريب، تقوم طبقة Dropout ببساطة بتمرير البيانات من خلالها أثناء الاختبار.

```
class DropoutMLP(d2l.Classifier):
    def __init__(self, num_outputs, num_hiddens_1,
num_hiddens_2,
                 dropout_1, dropout_2, lr):
        super().__init__()
        self.save_hyperparameters()
        self.net = tf.keras.models.Sequential([
            tf.keras.layers.Flatten(),
            tf.keras.layers.Dense(num_hiddens_1,
activation=tf.nn.relu),
            tf.keras.layers.Dropout(dropout_1),
            tf.keras.layers.Dense(num_hiddens_2,
activation=tf.nn.relu),
            tf.keras.layers.Dropout(dropout_2),
            tf.keras.layers.Dense(num_outputs)])
```

بعد ذلك، نقوم بتدريب النموذج.

```
model = DropoutMLP(**hparams)
trainer.fit(model, data)
```

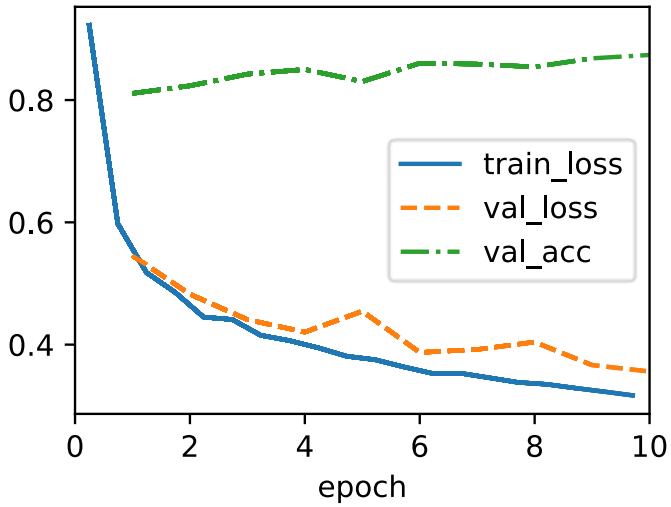

5.6.4. الملخص

- إلى جانب التحكمفي عدد الأبعاد وحجم متجه الوزن weight vector، فإن Dropout هو أداة أخرى لتجنب الضبط الزائد overfitting. غالبا ما يتم استخدامها بشكل مشترك.
- يستبدل Dropout التنشيط h بمتغير عشوائي ذي قيمة متوقعة h.
- يستخدم Dropout فقط أثناء التدريب.

5.6.5. التمارين

1. ماذا يحدث إذا قمت بتغيير احتمالات Dropout للطبقتين الأولى والثانية؟ على وجه الخصوص، ماذا يحدث إذا قمت بتبديل الطبقات لكلتا الطبقتين؟ صمم تجربة للإجابة على هذه الأسئلة، ووصف نتائجك من الناحية الكمية، ولخص النتائج النوعية.
2. قم بزيادة عدد الفترات number of epochs ومقارنة النتائج التي تم الحصول عليها عند استخدام Dropout مع تلك التي تم الحصول عليها عند عدم استخدامها.
3. ما هو تباين التنشيطاتفي كل طبقة مخفية عندما يتم تطبيق Dropout ولا يتم تطبيقه؟ ارسم مخططًا لإظهار كيفية تطور هذه الكمية بمرور الوقت لكلا النموذجين.
4. لماذا لا يتم استخدام Dropout عادةفي وقت الاختبار test time؟
5. باستخدام النموذجفي هذا القسم كمثال، قارن بين تأثيرات استخدام Dropout وتناقص الوزن weight decay. ماذا يحدث عند استخدام Dropout وتناقص الوزن في نفس الوقت؟ هل النتائج مضافة؟ هل هناك عوائد متناقصة (أو أسوأ)؟ هل يلغون بعضهم البعض؟
6. ماذا يحدث إذا طبقنا Dropout على الأوزان الفردية لمصفوفة الوزن بدلاً من التنشيطات؟
7. اخترع تقنية أخرى لحقن ضوضاء عشوائيةفي كل طبقة تختلف عن تقنية Dropout القياسية. هل يمكنك تطوير طريقة تتفوقفي الأداء على مجموعة بيانات Fashion-MNIST (للهندسة المعمارية الثابتة)؟

5.7 توقع أسعار المنازل في كاجل Predicting House Prices on Kaggle

الآن بعد أن قدمنا بعض الأدوات الأساسية لبناء وتدريب شبكات عميقة وتنظيمها باستخدام تقنيات بمافي ذلك تناقص الوزن و dropout، نحن على استعداد لوضع كل هذه المعرفة موضع التنفيذ من خلال المشاركةفي مسابقة Kaggle . تعتبر مسابقة التنبؤ بأسعار المنزل مكانًا رائعًا للبدء. البيانات عامة إلى حد ما ولا تظهر بنية غريبة قد تتطلب نماذج متخصصة (مثل الصوت

أو الفيديو). مجموعة البيانات هذه، التي جمعها Bart de Cock في عام 2011، (De Cock، 2011)، تغطي أسعار المنازلفيAmes ، IAمن الفترة 2006–2010. إنه أكبر بكثير من مجموعة بيانات الإسكان الشهيرةفي بوسطن Boston housing dataset لهاريسون وروبينفيلد (1978)، ويضم المزيد من الأمثلة والمزيد من الميزات.

في هذا القسم، سنرشدك إلى تفاصيل المعالجة المسبقة للبيانات وتصميم النموذج واختيار المعلمة الفائقة. نأمل أن تكتسب من خلال نهج عملي بعض البديهيات التي ستوجهكفي حياتك المهنية كعالم بيانات.

5.7.1. تنزيل البيانات Downloading Data

خلال الكتاب، سنقوم بتدريب واختبار النماذج على مجموعات البيانات المختلفة التي تم تنزيلها. هنا، نقوم بتنفيذ دالتين مفيدتين لتنزيل الملفات واستخراج ملفات zip أو tar. مرة أخرى، نرجئ تنفيذها إلى القسم 20.7.

```
def download(url, folder, sha1_hash=None):
    """Download a file to folder and return the local
filepath."""

def extract(filename, folder):
    """Extract a zip/tar file into folder."""
```

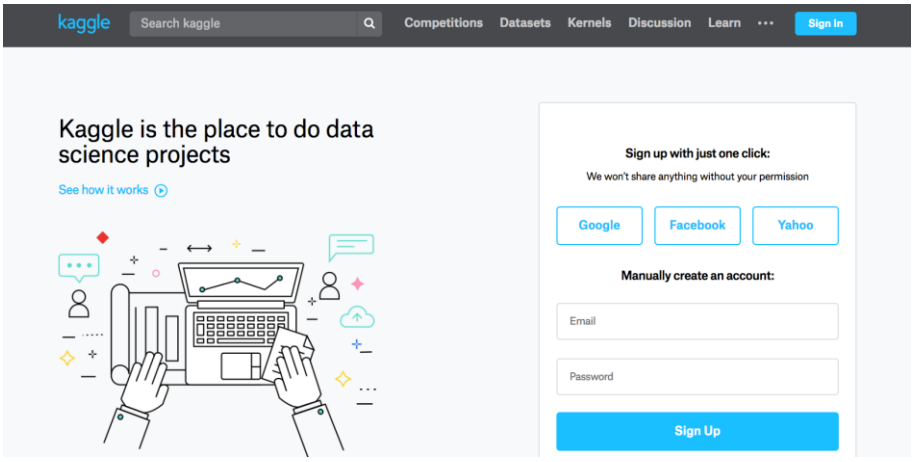

الشكل 5.7.1 موقع Kaggle الإلكتروني.

5.7.2. Kaggle

Kaggle هي منصة شهيرة تستضيف مسابقات التعلم الآلي. تركز كل مسابقة على مجموعة بيانات والعديد منها برعاية أصحاب المصلحة الذين يقدمون جوائز للحلول الفائزة. تساعد المنصة المستخدمين على التفاعل عبر المنتديات والاكواد المشتركة، مما يعزز التعاون والمنافسة.في حين أن مطاردة المتصدرين غالبًا ما تخرج عن نطاق السيطرة، مع تركيز الباحثين على خطوات المعالجة المسبقة بدلاً من طرح الأسئلة الأساسية، هناك أيضًا قيمة هائلةفي موضوعية النظام الأساسي الذي يسهل المقارنات الكمية المباشرة بين الأساليب المتنافسة بالإضافة إلى مشاركة الكود بحيث يمكن للجميع أن يتعلموا ما نجح وما لم ينجح. إذا كنت ترغب في المشاركةفي مسابقة Kaggle، فستحتاج أولاً إلى التسجيل للحصول على حساب (انظر الشكل 5.7.1).

في صفحة مسابقة التنبؤ بسعر المنزل، كما هو موضحفي الشكل 5.7.2، يمكنك العثور على مجموعة البيانات (ضمن علامة التبويب "البيانات")، وإرسال التنبؤات، والاطلاع على الترتيب الخاص بك، عنوان URL موجود هنا:

https://www.kaggle.com/c/house-prices-advanced-regression-techniques

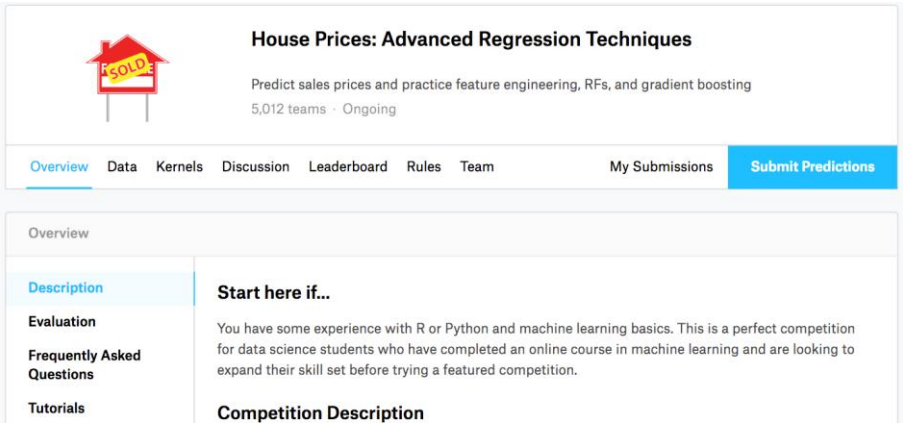

شكل 5.7.2 صفحة مسابقة التنبؤ بسعر المنزل.

5.7.3. الوصول إلى مجموعة البيانات وقراءتها Accessing and Reading the Dataset

لاحظ أن بيانات المسابقة مقسمة إلى مجموعات تدريب training واختبار test. يتضمن كل سجل قيمة ممتلكات المنزل والسمات مثل نوع الشارع street type وسنة البناء year of

construction ونوع السقف roof type وحالة الطابق السفلي basement condition وما إلى ذلك. تتكون الميزات من أنواع بيانات مختلفة. على سبيل المثال، يتم تمثيل سنة البناء بعدد صحيح، ونوع السقف بالتخصيصات الفئوية المنفصلة، والميزات الأخرى بأرقام الفاصلة العائمة. وهنا حيث يعقد الواقع الأشياء: بالنسبة لبعض الأمثلة، بعض البيانات مفقودة تمامًا مع وضع علامة على القيمة المفقودة ببساطة على أنها "na". سعر كل منزل مشمولفي مجموعة التدريب فقط (إنها منافسة بعد كل شيء). سنرغبفي تقسيم مجموعة التدريب لإنشاء مجموعة التحقق من الصحة validation set، لكننا فقط نقوم بتقييم نماذجنا على مجموعة الاختبار الرسمية بعد تحميل التنبؤات إلى Kaggle. تحتوي علامة التبويب "البيانات"في علامة تبويب المنافسةفي الشكل 5.7.2 على روابط لتنزيل البيانات.

```
%matplotlib inline
import numpy as np
import pandas as pd
import tensorflow as tf
from d2l import tensorflow as d2l
```

للبدء، سنقرأ البيانات ونعالجها باستخدام pandas، والتي قدمناهافي القسم 2.2. للسهولة، يمكننا تنزيل مجموعة بيانات الإسكان Kaggle وتخزينها مؤقتًا. إذا كان الملف المطابق لمجموعة البيانات هذه موجودًا بالفعلفي دليل ذاكرة التخزين المؤقت وكان SHA-1 يتطابق مع sha1_hash، فسيستخدم الكود الخاص بنا الملف المخزن مؤقتًا لتجنب انسداد الإنترنت بالتنزيلات الزائدة عن الحاجة.

```
class KaggleHouse(d2l.DataModule):
    def __init__(self, batch_size, train=None,
val=None):
        super().__init__()
        self.save_hyperparameters()
        if self.train is None:
            self.raw_train = pd.read_csv(d2l.download(
                d2l.DATA_URL +
'kaggle_house_pred_train.csv', self.root,

sha1_hash='585e9cc93e70b39160e7921475f9bcd7d31219ce'))
            self.raw_val = pd.read_csv(d2l.download(
                d2l.DATA_URL +
'kaggle_house_pred_test.csv', self.root,

sha1_hash='fa19780a7b011d9b009e8bff8e99922a8ee2eb90'))
```

تتضمن مجموعة بيانات التدريب 1460 مثالاً و80 ميزة و1 تسمية، بينما تحتوي بيانات التحقق من الصحة على 1459 مثالاً و80 ميزة.

```
data = KaggleHouse(batch_size=64)
print(data.raw_train.shape)
print(data.raw_val.shape)
```

```
Downloading ../data/kaggle_house_pred_train.csv from
http://d2l-data.s3-
accelerate.amazonaws.com/kaggle_house_pred_train.csv...
Downloading ../data/kaggle_house_pred_test.csv from
http://d2l-data.s3-
accelerate.amazonaws.com/kaggle_house_pred_test.csv...
(1460, 81)
(1459, 80)
```

5.7.4. المعالجة المسبقة للبيانات Data Preprocessing

دعنا نلقي نظرة على الميزات الأربع الأولى والأخيرة بالإضافة إلى التصنيف (سعر البيع SalePrice) من الأمثلة الأربعة الأولى.

```
print(data.raw_train.iloc[:4, [0, 1, 2, 3, -3, -2, -1]])
```

	Id	MSSubClass	MSZoning	LotFrontage	SaleType	SaleCondition	SalePrice
0	1	60	RL	65.0	WD	Normal	208500
1	2	20	RL	80.0	WD	Normal	181500
2	3	60	RL	68.0	WD	Normal	223500
3	4	70	RL	60.0	WD	Abnorml	140000

يمكننا أن نرى أنهفي كل مثال، الميزة الأولى هي المعرف ID. هذا يساعد النموذج على تحديد كل مثال تدريب.في حين أن هذا مناسب، إلا أنه لا يحمل أي معلومات لأغراض التنبؤ. ومن ثم، سنقوم بإزالته من مجموعة البيانات قبل إدخال البياناتفي النموذج. إلى جانب ذلك، بالنظر إلى مجموعة متنوعة من أنواع البيانات، سنحتاج إلى معالجة البيانات مسبقًا قبل أن نبدأفي النمذجة modeling.

لنبدأ بالسمات العددية numerical features. أولاً، نطبق الاستدلال heuristic، مع استبدال جميع القيم المفقودة missing values بمتوسط الميزة المقابلة. بعد ذلك، لوضع جميع الميزات على مقياس مشترك، نقوم بتوحيد البيانات عن طريق إعادة قياس الميزات إلى صفر متوسط zero mean وتباين الوحدة unit variance:

$$x \leftarrow \frac{x - \mu}{\sigma},$$

حيث μ وσ تشير إلى المتوسط والانحراف المعياري، على التوالي. للتحقق من أن هذا يحول بالفعل ميزتنا (المتغير) بحيث لا يحتوي متوسط صفر وتباين وحدة، لاحظ ذلك $E[\frac{x-\mu}{\sigma}] = \frac{\mu-\mu}{\sigma} = 0$ وذلك $E[(x-\mu)^2] = (\sigma^2 + \mu^2) - 2\mu^2 + \mu^2 = \sigma^2$. بشكل حدسي، نقوم بتوحيد البيانات لسببين. أولاً، ثبت أنه مناسب للتحسين. ثانيًا، نظرًا لأننا لا نعرف مسبقًا أي الميزات ستكون ذات صلة، لا نريد معاقبة المعاملات المخصصة لميزة واحدة أكثر من أي ميزة أخرى.

بعد ذلك نتعامل مع القيم المتقطعة discrete values. يتضمن ذلك ميزات مثل "MSZoning". نقوم باستبدالها بترميز واحد ساخن one-hot encoding بنفس الطريقة التي قمنا بها سابقًا بتحويل التسميات متعددة الفئات إلى متجهات (انظر القسم 4.1.1). على سبيل المثال، تفترض "MSZoning" القيمتين "RL" و "RM". بإسقاط ميزة "MSZoning"، يتم إنشاء ميزتين جديدتين للمؤشر "MSZoning_RL" و "MSZoning_RM" بقيم إما 0 أو 1. وفقًا للترميز الواحد الساخن، إذا كانت القيمة الأصلية لـ "MSZoning" هي "RL"، القيمة MSZoning_RL" تساوي 1 و"MSZoning_RM" تساوي 0. حزمة pandas تقوم بذلك تلقائيًا لنا.

```
@d2l.add_to_class(KaggleHouse)
def preprocess(self):
    # Remove the ID and label columns
    label = 'SalePrice'
    features = pd.concat(
        (self.raw_train.drop(columns=['Id', label]),
         self.raw_val.drop(columns=['Id'])))
    # Standardize numerical columns
    numeric_features = features.dtypes[features.dtypes
!= 'object'].index
    features[numeric_features] =
features[numeric_features].apply(
        lambda x: (x - x.mean()) / (x.std()))
    # Replace NAN numerical features by 0
    features[numeric_features] =
features[numeric_features].fillna(0)
    # Replace discrete features by one-hot encoding.
    features = pd.get_dummies(features, dummy_na=True)
    # Save preprocessed features
    self.train =
features[:self.raw_train.shape[0]].copy()
    self.train[label] = self.raw_train[label]
```

```
    self.val = features[self.raw_train.shape[0]:].copy()
```

يمكنك أن ترى أن هذا التحويل يزيد عدد الميزات من 79 إلى 331 (باستثناء أعمدة المعرف ID والتسمية label).

```
data.preprocess()
data.train.shape
```

```
(1460, 332)
```

5.7.5. قياس الخطأ Error Measure

للبدء، سنقوم بتدريب نموذج خطي بخسارة مربعة squared loss. ليس من المستغرب أن نموذجنا الخطي لن يؤدي إلى إرسال فائز بالمنافسة ولكنه يوفر فحصًا للعقل لمعرفة ما إذا كانت هناك معلومات مفيدةفي البيانات. إذا لم نتمكن من القيام بما هو أفضل من التخمين العشوائي هنا، فقد تكون هناك فرصة جيدة لوجود خطأفي معالجة البيانات. وإذا نجحت الأشياء، فسيكون النموذج الخطي بمثابة خط أساس يمنحنا بعض الحدس حول مدى قرب النموذج البسيط من أفضل النماذج المبلغ عنها، مما يمنحنا إحساسًا بمدى المكاسب التي يجب أن نتوقعها من النماذج الأكثر رواجًا.

مع أسعار المساكن، كما هو الحال مع أسعار الأسهم، نهتم بالكميات النسبية أكثر من الكميات المطلقة. وبالتالي فإننا نميل إلى الاهتمام أكثر بالخطأ النسبي $\frac{y-\hat{y}}{y}$ من الخطأ المطلق $y - \hat{y}$. على سبيل المثال، إذا تم إيقاف توقعنا بمقدار 100,000دولار أمريكي عند تقدير سعر منزلفي ريف أوهايو، حيث تبلغ قيمة المنزل النموذجي 125,000دولار أمريكي، فمن المحتمل أننا نقوم بعمل رهيب. من ناحية أخرى، إذا أخطأنا بهذا المبلغفي لوس ألتوس هيلز، كاليفورنيا، فقد يمثل هذا تنبؤًا دقيقًا بشكل مذهل (هناك، يتجاوز متوسط سعر المنزل 4 ملايين دولار أمريكي).

تتمثل إحدى طرق معالجة هذه المشكلةفي قياس التناقضفي لوغاريتم تقديرات الأسعار.في الواقع، يعد هذا أيضًا مقياس الخطأ الرسمي الذي تستخدمه المسابقة لتقييم جودة الطلبات المقدمة. بعد كل شيء، قيمة صغيرة δ لـ $|\log y - \log \hat{y}| \leq \delta$ تترجم إلى $e^{-\delta} \leq \frac{\hat{y}}{y} \leq e^{\delta}$. يؤدي هذا إلى الخطأ الجذر التربيعي root-mean-squared-error التالي بين لوغاريتم السعر المتوقع predicted price ولوغاريتم سعر التسمية label price:

$$\sqrt{\frac{1}{n}\sum_{i=1}^{n} (\log y_i - \log \hat{y}_i)^2}.$$

```
@d2l.add_to_class(KaggleHouse)
def get_dataloader(self, train):
```

```
    label = 'SalePrice'
    data = self.train if train else self.val
    if label not in data: return
    get_tensor = lambda x: tf.constant(x.values,
dtype=tf.float32)
    # Logarithm of prices
    tensors = (get_tensor(data.drop(columns=[label])),
# X

tf.reshape(tf.math.log(get_tensor(data[label])), (-1,
1)))  # Y
    return self.get_tensorloader(tensors, train)
```

K-Fold Cross Validation .5.7.6

قد تتذكر أننا قدمنا التحقق المتبادلفي القسم 3.6.3، حيث ناقشنا كيفية التعامل مع اختيار النموذج. سنستخدم هذا بشكل جيد لتحديد تصميم النموذج وضبط المعلمات الفائقة. نحتاج أولاً إلى دالة تُرجع i^{th} طي البياناتفي إجراء تحقق متقاطع. يتم المضي قدمًا عن طريق تقطيع i^{th}المقطع كبيانات تحقق وإعادة الباقي كبيانات تدريب. لاحظ أن هذه ليست الطريقة الأكثر فاعلية للتعامل مع البيانات وسنفعل بالتأكيد شيئًا أكثر ذكاءً إذا كانت مجموعة البيانات الخاصة بنا أكبر بكثير. لكن هذا التعقيد الإضافي قد يؤدي إلى تشويش الكود الخاصة بنا دون داع لذلك يمكننا حذفها بأمان هنا بسبب بساطة مشكلتنا.

```
def k_fold_data(data, k):
    rets = []
    fold_size = data.train.shape[0] // k
    for j in range(k):
        idx = range(j * fold_size, (j+1) * fold_size)
        rets.append(KaggleHouse(data.batch_size,
data.train.drop(index=idx),
                                data.train.loc[idx]))
    return rets
```

يتم إرجاع متوسط خطأ التحقق من الصحة عندما نتدرب Kمراتفي التحقق المتبادل K-Fold.

```
def k_fold(trainer, data, k, lr):
    val_loss, models = [], []
    for i, data_fold in enumerate(k_fold_data(data, k)):
        model = d2l.LinearRegression(lr)
        model.board.yscale='log'
        if i != 0: model.board.display = False
        trainer.fit(model, data_fold)
```

```
        val_loss.append(float(model.board.data['val_loss'][-
1].y))
        models.append(model)
    print(f'average validation log mse =
{sum(val_loss)/len(val_loss)}')
    return models
```

5.7.7. اختيار النموذج Model Selection

في هذا المثال، نختار مجموعة غير مضبوطة من المعلمات الفائقة ونتركها للقارئ لتحسين النموذج. قد يستغرق العثور على خيار جيد وقتًا، اعتمادًا على عدد المتغيرات التي يحسنها المرء. مع وجود مجموعة بيانات كبيرة بما يكفي، والأنواع العادية من المعلمات الفائقة، يميل التحقق المتبادل K-Fold إلى أن يكون مرنًا بشكل معقول ضد الاختبارات المتعددة. ومع ذلك، إذا جربنا عددًا كبيرًا بشكل غير معقول من الخيارات، فقد نحالفنا الحظ ونجد أن أداء التحقق من الصحة لم يعد يمثل الخطأ الحقيقي.

```
trainer = d2l.Trainer(max_epochs=10)
models = k_fold(trainer, data, k=5, lr=0.01)
average validation log mse = 0.1782047653198242
```

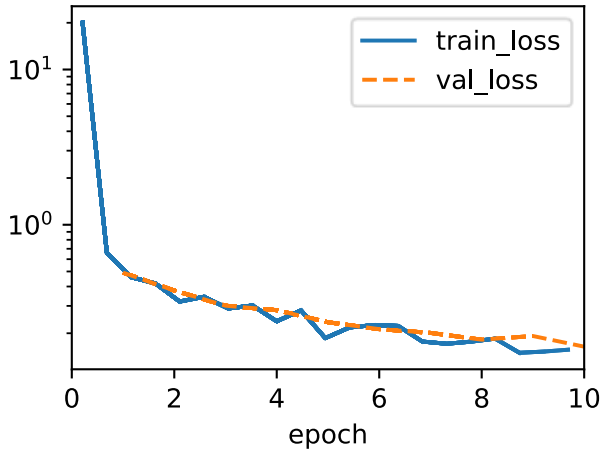

لاحظ أنهفي بعض الأحيان يمكن أن يكون عدد أخطاء التدريب لمجموعة من المعلمات الفائقة منخفضًا جدًا، حتى مع ارتفاع عدد الأخطاءفي التحقق المتبادل K-Fold بشكل كبير. هذا يشير إلى أننا نفرطفي التجهيز overfitting. خلال التدريب، سترغبفي مراقبة كلا الرقمين. قد يشير التجاوز الأقل إلى أن بياناتنا يمكن أن تدعم نموذجًا أكثر قوة. قد يوحي فرط التجهيز الهائل بأنه يمكننا الاستفادة من خلال دمج تقنيات التنظيم regularization.

5.7.8. تقديم التنبؤات على كاجل Submitting Predictions on Kaggle

الآن بعد أن عرفنا ما يجب أن يكون عليه الاختيار الجيد للمعلمات الفائقة، يمكننا حساب متوسط التنبؤاتفي الاختبار الذي تم تعيينه بواسطة جميع النماذج. سيؤدي حفظ التنبؤاتفي ملف csv إلى تبسيط تحميل النتائج إلى Kaggle. سيُنشئ الكود التالي ملفًا يسمى `submission.csv`.

```
preds = [model(tf.constant(data.val.values,
dtype=tf.float32))
         for model in models]
# Taking exponentiation of predictions in the logarithm
scale
ensemble_preds = tf.reduce_mean(tf.exp(tf.concat(preds,
1)), 1)
submission = pd.DataFrame({'Id':data.raw_val.Id,

'SalePrice':ensemble_preds.numpy()})
submission.to_csv('submission.csv', index=False)
```

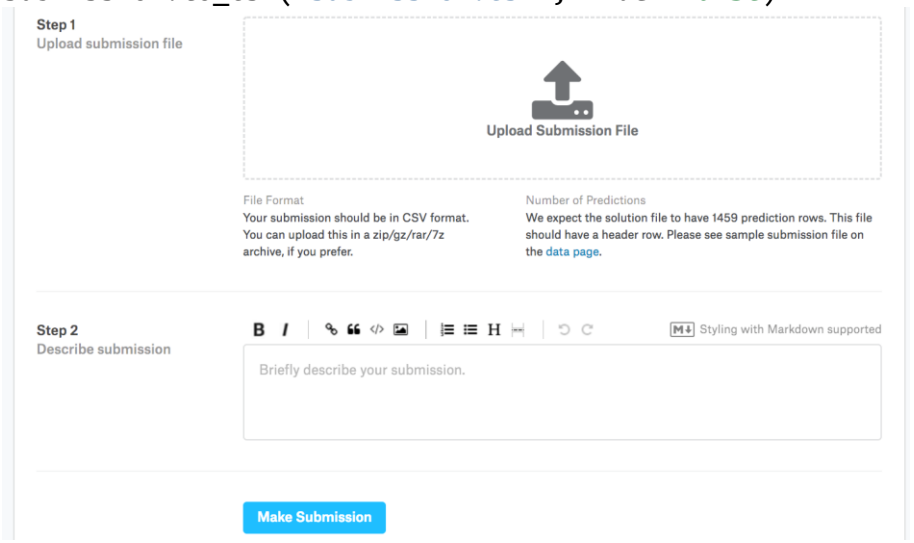

الشكل 5.7.3 تقديم البيانات إلىKaggle

بعد ذلك، كما هو موضحفي الشكل 5.7.3، يمكننا تقديم تنبؤاتنا على Kaggle ومعرفة كيفية مقارنتها بأسعار المنازل الفعلية (التسميات labels)في مجموعة الاختبار. الخطوات بسيطة للغاية:

- قم بتسجيل الدخول إلى موقع Kaggle الإلكتروني وقم بزيارة صفحة مسابقة التنبؤ بأسعار المنازل.

- انقر فوق الزر "إرسال التوقعات Submit Predictions " أو "التقديم المتأخر" (حتى كتابة هذه السطور، يوجد الزر على اليمين).
- انقر فوق الزر "تحميل ملف التقديم Upload Submission File "في المربع المتقطع أسفل الصفحة وحدد ملف التنبؤ الذي ترغبفي تحميله.
- انقر فوق الزر "تقديم Make Submission "في أسفل الصفحة لعرض النتائج الخاصة بك.

5.7.9. الملخص

- غالبًا ما تحتوي البيانات الحقيقية على مزيج من أنواع البيانات المختلفة وتحتاج إلى معالجة مسبقة.
- إعادة قياس Rescaling البيانات ذات القيمة الحقيقية إلى متوسط الصفر وتباين الوحدة يعد افتراضيًا جيداً. لذلك يتم استبدال القيم المفقودة بمتوسطها.
- يتيح لنا تحويل الميزات الفئوية categorical features إلى ميزات مؤشر أن نتعامل معها على أنها متجهات واحدة ساخنة.
- يمكننا استخدام التحقق المتبادل K-Fold لتحديد النموذج وضبط المعلمات الفائقة.
- اللوغاريتمات مفيدة للأخطاء النسبية.

5.7.10. التمارين

1. أرسل توقعاتك لهذا القسم إلى Kaggle. ما مدى جودة توقعاتك؟
2. هل من الجيد دائمًا استبدال القيم المفقودة بمتوسطها؟ تلميح: هل يمكنك بناء موقف لا تكون فيه القيم مفقودة بشكل عشوائي؟
3. قم بتحسين النتيجة على Kaggle عن طريق ضبط المعلمات الفائقة من خلال التحقق المتبادل K-Fold.
4. قم بتحسين النتيجة من خلال تحسين النموذج (على سبيل المثال، الطبقات وتناقص الوزن وdropout).
5. ماذا يحدث إذا لم نقم بتوحيد standardize السمات العددية المستمرة مثل ما فعلناه في هذا القسم؟

Dive into Deep Learning

Basics and Preliminaries

ASTON ZHANG, ZACHARY C. LIPTON, MU LI,
AND ALEXANDER J.SMOLA

Translated Into Arabic by
Dr. Alaa Taima