

التعلم العميق

المبادئ والمفاهيم والالتايب



ترجمة:
د. علاء طعيمة

تأليف:
ميلاد وزان

بِسْمِ اللَّهِ تَعَالَى

التعلم العميق

المبادئ والمفاهيم والأساليب

تأليف:

ميلاد وزان

ترجمة:

د. علاء طعيمة

تم نشر النسخة الإلكترونية من الكتاب **مجاناً** بواسطة المؤلف والمترجم

يُسمح بأي استخدام لمحتويات هذا الكتاب من خلال الاستشهاد بالمصدر

مقدمة المترجم

يقدم هذا الكتاب دروساً تعليمية عديدة في مجال التعلم العميق ويتميز الكتاب ببساطة لغته وسهولة فهمها من قبل القارئ مع شرح مميز مدعم بالأمثلة والتمارين في كل فصل.

عند انتهائي من قراءة هذا الكتاب، احببت ان اترجم هذا الكتاب وبعد التواصل مع المؤلف الاستاذ ميلاد وزان لم يبد مانعا من ترجمته الى العربية. ولله الحمد ترجمت الكتاب الى العربية وحسب معلوماتي لا يوجد كتاب عربي يتناول التعلم العميق.

لقد اخترت كتاب "يادگیری عمیق: اصول، مفاهيم و رویکردها" للأستاذ ميلاد وزان لما رأيته من جودة هذا الكتاب، وللمنهجية التي اتبعها المؤلف في ترتيبه وبساطة شرحه. لقد حاولت قدر المستطاع ان اخرج بترجمة ذات جودة عالية، ومع هذا يبقى عملاً بشرياً يحتمل النقص، فاذا كان 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 يدخل في مجال التعلم العميق ومساعدة القارئ العربي على تعلم هذا المجال. أسأل الله التوفيق في هذا العمل لأثراء المحتوى العربي الذي يفتقر أشد الافتقار إلى محتوى جيد ورضين في مجال الذكاء الاصطناعي وتعلم الآلة والتعلم العميق. ونرجو لك الاستمتاع مع التعلم العميق ولا تنسونا من صالح الدعاء.

د. علاء طعيمة

كلية علوم الحاسوب وتكنولوجيا المعلومات

جامعة القادسية

العراق

مقدمة المؤلف

يعد بناء نظام ذكي قادر على استخراج تمثيلات عالية المستوى للبيانات أمراً ضرورياً في العديد من القضايا المتعلقة بالذكاء الاصطناعي. تظهر الحجج النظرية والبيولوجية أنه لبناء مثل هذه الأنظمة ، هناك حاجة إلى نماذج معمارية عميقة تتضمن العديد من طبقات المعالجة غير الخطية.

التعلم العميق هو مجموعة فرعية من أساليب التعلم الآلي التي يشار إليها أيضاً باسم التعلم التمثيلي. يعد التعلم التمثيلي أو تعلم الميزات أسلوباً يمنح الجهاز القدرة على اكتشاف العلاقات تلقائياً من البيانات الأولية. أصبحت هذه القدرة المهمة والميزة الرئيسية للتعلم العميق ممكنة من خلال التعلم في طبقات مختلفة في بنية الشبكة.

قبل ظهور التعلم العميق ، اعتمدت أساليب التعلم الآلي التقليدية بشكل كبير على التمثيلات (اختيار الميزات) المستمدة من البيانات. تتطلب هذه الأساليب خبيراً في مجال الموضوع لإجراء استخراج الميزات يدوياً. ومع ذلك ، يعد استخراج الميزات يدوياً عملية صعبة وتستغرق وقتاً طويلاً. كان ظهور التعلم العميق قادراً على استبدال هذه الأساليب التقليدية بسرعة. لأنه يمكنه استخراج الميزات تلقائياً لتناسب أي مشكلة.

في السنوات الأخيرة ، أصبح التعلم العميق المحرك الرئيسي للحلول المبتكرة لمشاكل الذكاء الاصطناعي ، والتي أصبحت ممكنة من خلال زيادة كمية البيانات المتاحة، وزيادة موارد الحوسبة وتحسين التقنيات في التدريب على الشبكة العميقة. قدم التعلم العميق مجموعة واسعة من التغييرات في صناعة التكنولوجيا اليوم ، لذلك سيكون فهم كيفية عمل التعلم العميق مفيداً وضرورياً لمتخصصي البرمجيات في عالم اليوم.

باستخدام أحدث المراجع العلمية وخبرات المؤلف، تم تجميع هذا الكتاب وتجميعه لمجموعة واسعة من الباحثين والطلاب وأصحاب الصناعة والمهتمين بالتعلم العميق حتى يتمكنوا من اكتساب المعرفة الكافية بالمبادئ والمفاهيم الأساسية في هذا المجال. أيضاً، نظراً لأن هذا الكتاب يغطي المواد اللازمة لدورة التعلم العميق في الدراسات العليا، فيمكن أن يكون مرجعاً جيداً لهذه الدورة بالإضافة إلى الدروس الاختيارية لطلاب السنة النهائية الجامعيين في هندسة الكمبيوتر. لذلك، تم بذل كل جهد

لتقديم محتويات الكتاب بطريقة بسيطة وطلاقة ومفهومة، جنباً إلى جنب مع أمثلة لفهم أفضل حتى يمكن فهمها من قبل مجموعة واسعة من القراء.

يؤكد هذا الكتاب على فهم مبادئ ومفاهيم التعلم العميق، مع وجهات نظر حول مناهج التعلم المختلفة. ومع ذلك، هذا لا يعني أنه يمكن وصف جميع جوانب التعلم في مجلد واحد؛ نحن لا ننوي القيام بذلك أيضاً. في الواقع، هدفنا في كتابة وتجميع محتويات هذا الكتاب هو اكتساب المعرفة الكافية بالتعلم العميق ومقارباته المختلفة من خلال التأكيد على الموضوعات الهامة والجديدة وتقديم رؤية شاملة للتعلم العميق.

على الرغم من أن محتويات هذا الكتاب مفهومة، إلا أنها مكتوبة على أساس أن القارئ لديه معرفة كافية بالتعلم الآلي. من المؤكد أن امتلاك أساسيات التعلم الآلي سيضعف من فهم هذا الكتاب. ومع ذلك، خلال عرض المحتويات، تم بذل كل جهد ممكن لتقليل هذه المتطلبات الأساسية للتعلم الآلي.

يتكون هذا الكتاب من ستة فصول، سنشير إلى محتوى هذه الفصول بإيجاز كما في أدناه:

- **الفصل الأول - مقدمة إلى التعلم الآلي والتعلم العميق:** يبدأ هذا الفصل بتعريف التعلم. بعد ذلك، يتم تلخيص ومقارنة مفهوم التعلم الآلي ومقارباته المختلفة مثل: التعلم الخاضع للإشراف، والتعلم غير الخاضع للإشراف، والمعزز، وشبه الإشراف، والإشراف الذاتي، والنشط، والاونلاين، ومتعدد المهام، والانتقالي. فيما يلي، يتم تقديم تعريف للتعلم العميق وكيف يعمل، ويتم شرح أهميته والتحديات والاختلافات مع التعلم الآلي وفي نهاية الفصل، يتم ذكر تطبيقاته في العالم الحقيقي.
- **الفصل الثاني - التعلم العميق الخاضع للإشراف:** في الفصل الثاني، يصف الكتاب الشبكات العصبية الاصطناعية وهيكلها وعملية التعلم والمفاهيم المطلوبة مثل: دالة التنشيط، دالة الخسارة، مناهج تهيئة الاوزان الاولية، التحسين والتحديات في تعلم الشبكات العميقة. في الجزء المتبقي من الفصل، ستتعرف على اثنتين من أكثر شبكات التعلم العميق شيوعاً، وهما الشبكات المتكررة والشبكات الالتفافية.

- **الفصل الثالث – تمثيل التعلم بدون اشراف عميق:** في هذا الفصل، سنصف هيكل المشفر الذاتي وأنواعه. بعد ذلك، سنقارن بين النماذج الإنتاجية والقابلة للفصل، وأخيراً سنقوم بفحص أنواع نماذج التوليد العميق.
 - **الفصل الرابع – التعلم المعزز العميق:** في هذا الفصل، سنرى لماذا لا يمكن حل بعض المشكلات من خلال مناهج التعلم الخاضعة للإشراف وغير الخاضعة للإشراف، والحاجة إلى التعلم المعزز في هذه المشكلات. في استمرار للفصل، سوف نتعامل مع الأساليب الكلاسيكية المختلفة لحل المشكلات من خلال التعلم المعزز، وفي النهاية، سنرى سبب ظهور مجال بحث جديد يسمى التعلم المعزز العميق، وسوف ندرس مناهجه.
 - **الفصل الخامس – التعلم الانتقالي العميق:** في الفصل الخامس من الكتاب، سوف ندرس التعلم الانتقالي، ودوافع استخدامه، وفوائده، واستراتيجيات استخدامه، وطرقه المختلفة.
 - **الفصل السادس – التعلم العميق الهندسي:** الفصل الأخير من الكتاب مخصص لحقل بحث جديد يسمى التعلم العميق الهندسي. في هذا الفصل، ستتعرف على بنية الرسم البياني وشبكات الرسم البياني العصبية وتعلم التمثيل البياني وشبكات ارتباط الرسم البياني. وتجدر الإشارة إلى أنه تم النظر في هذا الفصل بعبارات عامة ولم تتم مناقشته بالتفصيل.
- في النهاية، يُرجى من القراء الأعزاء إخباري بأي انتقادات أو اقتراحات أو إذا رأيت أي مشاكل في الكتاب.

ميلاد وزان

شتاء 1399

vazanmilad@gmail.com

المحتويات

- 15..... الفصل الأول : مقدمة في التعلم الآلي والتعلم العميق
- 16..... المقدمة
- 16..... ما هو التعلم؟
- 17..... تعلم الآلة
- 18..... البرمجة التقليدية مقابل التعلم الآلي
- 19..... التعلم الخاضع للإشراف
- 20..... التعلم غير خاضع للإشراف
- 20..... التعلم المعزز
- 21..... الفرق بين التعلم الخاضع للإشراف وغير الخاضع للإشراف والمعزز
- 21..... التعلم شبه الخاضع للإشراف
- 22..... التعلم الخاضع للإشراف الذاتي
- 23..... التعلم الفعال
- 23..... التعلم الاونلاين
- 24..... التعلم متعدد المهام
- 24..... التعلم الانتقالي
- 25..... الفرق بين التعلم الانتقالي والتعلم متعدد المهام
- 25..... التعلم التمثيلي
- 25..... البيانات التدريبية والتجريبية والتحقق من الصحة
- 26..... التعلم العميق
- 27..... تاريخ التعلم العميق
- 28..... كيف يعمل التعلم العميق؟
- 29..... سبب شعبية التعلم العميق
- 30..... سبب أهمية التعلم العميق
- 31..... التحديات في التعلم العميق
- 32..... مقارنة بين التعلم الآلي والتعلم العميق
- 33..... العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق
- 35..... تطبيقات التعلم العميق

37 خلاصة الفصل الاول
37 أسئلة للمراجعة
39 الفصل الثاني: التعلم العميق الخاضع للإشراف
39 الشبكة العصبية امامية التغذية، المتكررة والالتفافية
40 المقدمة
40 الشبكات العصبية الاصطناعية
43 بيرسيبترون
47 شبكات التغذية العميقة
49 دالة التنشيط
55 دالة الخسارة
55 دوال الخسارة المتعلقة بالتصنيف
56 دوال الخسارة المتعلقة بالانحدار
57 طرق تهيئة القيم الأولية للأوزان
57 تهيئة جميع الأوزان إلى الصفر
57 التهيئة العشوائية
58 التعلم الانتقالي
58 تهيئة القيم الأولية الموحدة لـ غلوروت
58 تهيئة القيم الأولية هي
59 التحسين وتحديث الأوزان
61 الانحدار الاشتقاقي العشوائي (SGD) والصغير
62 آداكراد
63 آدادلتا
63 آرآماسپروب
64 آدام (ADAM)

65.....	خوارزمية الانتشار الخلفي للخطأ
72.....	تحديات التدريب في الشبكات العميقة
72.....	تلاشي وانفجار الانحدار
75.....	طرق لتحديد مشاكل تلاشي وانفجار الانحدار؟
75.....	طرق القضاء على مشاكل تلاشي الانحدار وانفجار الانحدار
76.....	الضبط الزائد
77.....	التوقف المبكر
78.....	الحذف العشوائي
79.....	التسوية بالدفعات
81.....	توافر وجودة البيانات التعليمية
82.....	تحسين المعاملات الفائقة
82.....	الاختلافات بين معاملات النموذج والمعاملات الفائقة في الشبكات العصبية؟
83.....	ضبط المعاملات الفائقة
84.....	الضبط اليدوي للمعاملات الفائقة (التجربة والخطأ)
84.....	البحث الشبكي
85.....	البحث العشوائي
86.....	تحسين بايزي
86.....	الشبكة العصبية المتكررة (RNN)
87.....	هيكل شبكة عصبية متكررة بسيطة
89.....	أنواع بنية الشبكة العصبية المتكررة
91.....	تدريب الشبكة العصبية المتكررة
91.....	الانتشار الخلفي بمرور الوقت
97.....	شبكات الذاكرة قصيرة المدى لدوم لفترة أطول (LSTM)
101.....	وحدات إرجاع البوابة (GRU)
104.....	آلة تورينج العصبية (NTM)

107	القراءة
107	الكتابة
110	الشبكات العصبية الالتفافية CNN
112	بُنْيَة الشبكات العصبية الالتفافية
112	طبقة الالتفاف
115	طبقة الدمج
116	الطبقة المتصلة بالكامل
117	الحشو والخطوات
118	التدريب في CNN
120	أسباب استخدام CNN لتصنيف الصور
121	بُنْيَة CNN
121	LeNet
122	AlexNet
123	ZFNet
123	تحديات CNN
124	خلاصة الفصل الثاني
125	أسئلة للمراجعة
127	الفصل الثالث: التعلم التمثيلي غير الخاضع للإشراف العميق
127	المشفرات الذاتية والنماذج الانتاجية
128	المقدمة
128	التعلم النشط والتعلم التمثيلي بدون إشراف
130	المشفرات الذاتية
131	بُنْيَة المشفرات الذاتية
133	معاملات المشفرات الذاتية
134	كيف يعمل المشفر الذاتي ؟
134	المشفر الذاتي الانكماشى

135	المشفر الذاتي لإزالة الضوضاء
136	المشفر الذاتي غير الكامل
137	المشفر الذاتي المبعثر
138	المشفر الذاتي الالتفافي
139	النماذج المميزة والانتاجية
140	أنواع النماذج الانتاجية
143	النموذج المولد العميق
145	المشفر التلقائي المتغير
155	شبكات الخصومة التوليدية
159	آلة بولتزمان
163	آلة بولتزمان المحدودة
165	شبكات الاعتقاد العميقة
165	نماذج التوليد القائمة على التدفق
168	النماذج ذات التدفق المعادل
170	النماذج ذات التدفق الذاتي
171	خلاصة الفصل الثالث
173	أسئلة للمراجعة
175	الفصل الرابع : التعلم المعزز العميق
177	التعلم المعزز
179	التعلم المعزز مقارنة بالتعلم الآلي
180	قرارات عملية ماركوف
181	الوكيل
182	خوارزميات قائمة على القيمة
185	الخوارزميات المستندة إلى السياسة
186	الاستخراج مقابل الاستكشاف
189	بناءً على النموذج مقابل بدون نموذج

189	التنبؤ مقابل المراجعة.....
192	المناهج الكلاسيكية للتعلم المعزز
192	البرمجة الديناميكية
195	مونت كارلو
196	تعلم الفرق الزمني
200	البحث في السياسة
200	نقد الوكيل
202	الطريقة المشتركة (داينو-كيو)
202	التعلم المعزز العميق
203	شبكة كيو العميقة (DQN)
205	شبكة كية العميقة المزدوجة
206	شبكة كيو العميقة معاً
207	خلاصة الفصل الرابع
208	أسئلة للمراجعة.....
210	الفصل الخامس: التعلم الانتقالي العميق
211	المقدمة.....
211	التعلم الانتقالي
215	متى نستخدم التعلم الانتقالي؟
215	التعلم الانتقالي العميق
216	الدافع لاستخدام التعلم الانتقالي العميق.....
217	فوائد التعلم الانتقالي.....
218	استراتيجيات التعلم الانتقالي العميق
220	مناهج التعلم الانتقالي العميق
220	التعلم الانتقالي العميق القائم على العينة.....

221	التعلم الانتقالي العميق القائم على الخصومة
222	التعلم الانتقالي العميق القائم على التخصيص
222	التعلم الانتقالي العميق القائم على الشبكة
223	خلاصة الفصل الخامس
223	أسئلة للمراجعة
225	الفصل السادس : التعلم العميق الهندسي
225	التعلم التمثيلي بالرسم البياني
226	المقدمة
226	التعلم العميق الهندسي
227	الرسم البياني
229	شبكات الرسم البياني العصبية
230	الشبكات العصبية لنقل الرسائل
232	تعلم تمثيل الرسم البياني
233	شبكة الرسم البياني الالتفافية
235	خلاصة الفصل السادس
236	أسئلة للمراجعة
247	المصادر

الفصل 1

مقدمة في التعلم الآلي والتعلم العميق

الاهداف:

- نظرة عامة على التعلم الآلي.
- ما هو التعلم العميق؟
- ما هو الفرق بين التعلم الآلي والتعلم العميق؟
- العلاقة بين الكفاءة الاصطناعي والتعلم الآلي والتعلم العميق.
- أهمية وتطبيق التعلم العميق.

المقدمة

الهدف الأساسي في مجال الذكاء الاصطناعي هو إعطاء أجهزة الكمبيوتر القدرة على فهم العالم من حولهم والتفاعل معه بطريقة ذكية. على مدى السنوات العديدة الماضية ، برز التعلم العميق كواحد من أكثر الأساليب الواعدة لتحقيق هذا الهدف.

التعلم العميق هو طريقة للتعلم الحسابي للمفاهيم عالية المستوى في البيانات وتمثيلها باستخدام شبكات عصبية هرمية عميقة وهي جزء من أساليب التعلم الآلي. لذلك ، سيكون من المفيد مراجعة مفاهيم التعلم الآلي قبل التعلم العميق. لأن العديد من المفاهيم المستخدمة في الشبكات العصبية مثل التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف والمعزز والعديد من الموضوعات الأخرى تنشأ من التعلم الآلي. لذلك، في هذا القسم سيكون لدينا لمحة موجزة عن هذه المفاهيم لفهم التعلم العميق بشكل أفضل. لكن قبل أن ندخل في ذلك ، دعنا نعود قليلاً وننظر إلى ماهية التعلم.

ما هو التعلم؟

عندما نتحدث عن التعلم البشري ، فإننا نفرق بين التعلم والحفظ والذكاء. بالطبع ، تذكر أرقام الهواتف هو نوع من التعلم ، ولكن عندما نقول التعلم ، فإننا غالباً ما نعني شيئاً آخر. يمكن تعريف التعلم على أنه تحسين الأداء في مهمة معينة باستخدام الخبرة والممارسة. يتم تصنيف السلوك الذكي للإنسان من خلال التعلم في التجارب ، والتعلم هو مصدر المرونة في حياة الفرد.

تخيل استخدام بطاقة تعليمية لتعليم الطفل الفرق بين القطعة والكلب. نعرض بطاقة للطفل ، ويختار الطفل واحدة ، ثم يتم وضع البطاقة في أحد العمودين المناسبين لاختيار الصواب أو الخطأ. من خلال تدريب الطفل ، سيتحسن أدائه وسيكون قادراً على التعرف والتمييز بين القطط والكلاب. من أجل قدرة هذا الإدراك والمعرفة في الإنسان ، ما نحتاجه فقط هو الأمثلة. بمجرد أن يتقن الطفل عينة البطاقات التعليمية ، لن يتمكن فقط من تصنيف الصور على البطاقات التعليمية ، ولكن أيضاً معظم صور الكلاب والقطط. هذه القدرة على التعميم لتطبيق المعرفة المكتسبة على أمثلة لم يرها من قبل هي السمة الرئيسية للتعلم البشري والآلي. بالطبع ، يعد التعلم البشري شيئاً أكثر تقدماً حتى من

خوارزميات التعلم الآلي الأكثر تقدماً. لكن ما هو تعلم الكمبيوتر؟ يصف توم ميشيل (1997) التعلم في برامج الكمبيوتر على النحو التالي:

" أي برنامج كمبيوتر يعمل على تحسين أدائه في عمل ذي خبرة معينة ".
وفي تعريف أكثر دقة فإنه يعبر عن:

" سيكون برنامج الكمبيوتر قادراً على التعلم من خلال النظر في تجربة E للمهمة T وفقاً لمعيار الأداء P ، إذا تحسن أدائه بعد تجربة E للمهمة T."

وفقاً لهذا التعريف ، يبرز سؤالان: كيف يعرف الكمبيوتر ما إذا كان يؤدي أداءً أفضل في مهمة معينة ، وكيف يعرف كيفية القيام بذلك ، وسيتم تحسين هذه المهمة. تُنشئ الإجابات على هذه الأسئلة تصنيفاً للعديد من الأساليب المختلفة للتعلم الآلي ، والتي سنصنفها أدناه تحت عناوين التعلم الخاضع للإشراف وشبه الإشراف وغير الخاضع للإشراف.

تعلم الآلة

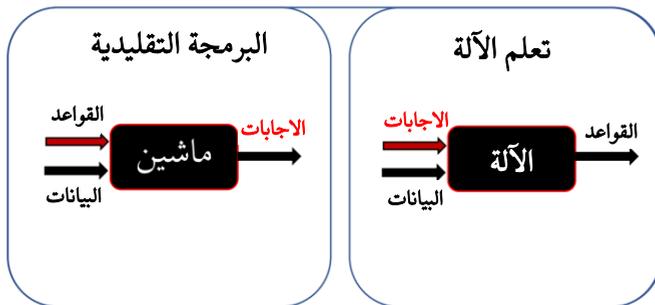
خلال اليوم ، غالباً ما نواجه آلات تقوم ميكانيكياً بالعمل المقرر لها القيام به. ولكن ماذا لو كانت هذه الآلات ، مثلنا مثل البشر ، يمكن أن تتعلم من التجربة ، وإذا كان بإمكان الآلات تغيير سلوكها في بيئة خاضعة للإشراف وأخلاقية لتكون أكثر كفاءة؟ في السنوات الأخيرة ، تطورت الأنظمة التكنولوجية من أنظمة ثابتة سلبية إلى أنظمة مؤتمتة وديناميكية تتحسن بمرور الوقت. هذا النهج يسمى التعلم الآلي.

التعلم الآلي هو فرع من فروع الذكاء الاصطناعي حيث تتعلم الآلة أداء المهام التي لم يتم التخطيط لها بشكل صريح ، ويتم تحسين أداء الجهاز تلقائياً من خلال الخبرة في أداء هذه المهمة. لقد قطعت محاولة إنشاء آلة تفكر مثل الإنسان شوطاً طويلاً. لقد تحول التعلم الآلي من نظام غامض إلى قوة صناعية واجتماعية رئيسية في صنع القرار الآلي ، من الأعمال التجارية عبر الإنترنت والإعلان إلى التعليم والرعاية الصحية. أصبح التعلم الآلي تقنية عامة قوية للعالم نظراً لقدرته القوية على التعلم من خلال التكيف مع البيانات المصنفة وغير المصنفة.

تبدأ عملية التعلم الآلي باستخدام البيانات الأولية لاستخراج معلومات مفيدة للمساعدة في اتخاذ قرارات أفضل. في تعريف أكثر دقة ، يمكن التعبير عن التعلم الآلي على النحو التالي: يركز التعلم الآلي على تصميم النماذج التي في مجال معين ، تم الحصول على خوارزميات الكمبيوتر بناءً على بيانات التدريب المعطاة لنموذج التعلم تلقائياً من خلال التجربة والاختبار من البيانات ، بحيث في مواجهة البيانات الجديدة في نفس المجال ، يمكن أن تظهر سلوكاً شبيهاً بالبشر. يمكن تنفيذ التعلم الآلي وتنفيذه بأساليب مختلفة. مناهجها الرئيسية الثلاثة هي **التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف والتعلم المعزز**. بالإضافة إلى هذه الأساليب الثلاثة ، هناك مناهج أخرى سنتعرف عليها فيما يلي.

البرمجة التقليدية مقابل التعلم الآلي

عندما يتعلق الأمر باستخدام أجهزة الكمبيوتر لأداء مهام بشرية ، يجب علينا دائماً إعطاء التعليمات للكمبيوتر في شكل برنامج كمبيوتر. لغات البرمجة التقليدية هي عملية يدوية (بمعنى أنه يجب على المبرمج إنشاء البرنامج) وعادة ما يأخذ البيانات ومجموعة من القواعد كمدخلات ، ومن خلال تطبيق هذه القواعد على البيانات ، يحصلون على الإجابات كمخرجات. في التعلم الآلي ، من ناحية أخرى ، يتم تقديم البيانات والإجابات (أو العلامات) كمدخلات ، ويتم استخدام القواعد (النماذج) كمخرجات (الشكل 1-1). نمط التعلم الآلي له قيمة لا مثيل لها. لأنه يسمح للآلة بتعلم قواعد جديدة في مساحة معقدة وكبيرة يصعب على البشر فهمها.



الشكل 1-1: البرمجة التقليدية مقابل التعلم الآلي

التعلم الخاضع للإشراف

فكر في نفسك كطالب في فصل الرياضيات حيث يشرف المعلم على كيفية حل مشكلة أو حل مشكلة بشكل صحيح أو خاطئ. هذا الموقف مشابه لما تتبعه خوارزمية الخاضعة للإشراف. في وضع التعلم ، يراقب النظام التعلم لكل تعليمات إرشادية بناءً على عنصر مزدوج من المدخلات والتسمية ، وهو ناتج المشكلة. تعني مجموعة البيانات الموسومة أن كل عضو في مجموعة التدريب يحصل على إجابة أو حل. الهدف هنا هو تكييف النظام بطريقة تمكن إدخال النظام الجديد من توقع المخرجات الصحيحة بناءً على ما تعلمته حتى الآن من بيانات التدريب. في التعلم الخاضع للإشراف، إذا كانت بيانات مسألة التعلم منفصلة ، فهي مسألة تصنيف، وإذا كانت قيم البيانات مستمرة ، فإنها تسمى الانحدار(التوقع).

التصنيف

يحاول التصنيف إجراء اتصال بين عينات التدريب والفئات المحددة مسبقاً للمشكلة. على سبيل المثال ، افترض أن هناك مجموعة من صور الحيوانات مثل الكلاب والقطط والأرانب والنمور وما إلى ذلك. يسمى وضع كل صورة من هذه الصور الحيوانية في فئتها الخاصة بعملية التصنيف. في هذا المثال ، في هذه الطريقة ، يتم تدريب النظام على عدد كبير من الصور جنباً إلى جنب مع العلامات (التسميات) ، حتى يجد النظام أداءً جيداً في تصنيف الصور.

الانحدار

افترض أن لدينا مجموعة من القيم. على سبيل المثال ، هناك بيانات عن أحوال المياه والطقس بخصائص مختلفة ، وبعضها مفقود. يعتمد تقدير هذه القيم المفقودة على العلاقة بين البيانات عن طريق الانحدار. بمعنى آخر ، يتنبأ بقيمة عددية من خلال النظر في أحد المدخلات.

التعلم غير خاضع للإشراف

يحدث التعلم بدون إشراف بدون مساعدة مشرف أو مراقب ، تماماً كما تتعلم السمكة السباحة بمفردها. في التعلم غير الخاضع للإشراف ، تكون خوارزمية التعلم مخصصة لمدخلات محددة ، بدون مخرجات محددة. الهدف من هذا التعلم هو العثور على هذه المخرجات بمفردها ، والتي يتم إجراؤها بواسطة الخوارزمية نفسها عن طريق تحليل البيانات وتحديد الأنماط المخفية والمحددة الموجودة في بُنية البيانات. التجميع (التكتل) هو مثال على هذا النوع من التعلم ، والذي يهدف إلى اكتشاف مجموعات من العناصر المتشابهة بناءً على التشابه المقاس ، أو لفهم أوجه التشابه في بُنية البيانات.

مزايا التعلم غير الخاضع للإشراف

- يتطلب وضع العلامات على البيانات الكثير من العمل والمال. التعلم غير الخاضع للإشراف يحل هذه المشكلة من خلال التعلم من البيانات غير المسماة.
- إنه مفيد جداً في العثور على أنماط البيانات التي لا يمكن العثور عليها باستخدام الطرق التقليدية.
- يتم تقليل حجم البيانات بسهولة باستخدام هذا النوع من التعلم.

عيوب التعلم غير الخاضع للإشراف

- قد تكون النتيجة أقل دقة من طريقة التعلم الخاضع للإشراف. لأننا لا نملك أي تسميات للبيانات ويجب أن يتعلم النموذج بالمعرفة المكتسبة من البيانات الأولية.
- كلما زادت الميزات (السمات) ، زادت تعقيدها.
- إنها عملية تستغرق وقتاً طويلاً. لأن مرحلة تعلم الخوارزمية قد تستغرق الكثير من الوقت لتحليل وحساب جميع الاحتمالات.

التعلم المعزز

التعلم المعزز يحل المشكلة بطريقة مختلفة. يعتمد التعلم المعزز على التفاعل مع البيئة، وتتعلم الخوارزمية التفاعل مع البيئة وحدها. في هذا النوع من التعلم، تتعلم الخوارزمية من خلال آلية التغذية الراجعة والتجارب السابقة وتحاول حل المشكلات بنفس الطريقة

التي يمثل بها البشري الحياة، وتتعلم كيفية تحسين سلوك الوكيل بناءً على وجود أو عدم وجود المكافآت. هدفها هو العثور على مجموعة من أنماط الإجراءات، عن طريق اختبارها ومقارنتها جميعاً للحصول على أعلى درجة مكافأة. لا يتطلب هذا النوع من التعلم مجموعة بيانات تعليمية. بمعنى آخر، إنه ليس تعلمًا خاضعًا للإشراف ولا تعلمًا غير خاضع للإشراف.

الفرق بين التعلم الخاضع للإشراف وغير الخاضع للإشراف والمعزز

التعلم الخاضع للإشراف هو عندما يستخدم النموذج مجموعة بيانات ذات علامات للمساعدة في حل مشكلة ما. لا يتطلب التعلم غير الخاضع للإشراف بيانات مصنفة، والنموذج نفسه هو الذي يحل المشكلة بمفرده وبدون مراقب خارجي من خلال اكتشاف الأنماط المخفية. على عكس هذين النهجين، لا يتطلب التعلم المعزز مجموعة من البيانات ويتفاعل الجهاز أو الوكيل مع بيئته للحصول على أفضل إجراء لحل المشكلة عن طريق التجربة والخطأ وتلقي المكافآت من البيئة. باختصار، في التعلم الخاضع للإشراف، الهدف هو إنشاء صيغة تعتمد على قيم المدخلات والمخرجات. في التعلم غير الخاضع للإشراف، تم العثور على اتصال بين قيم الإدخال وتجميعها. في التعلم المعزز، يتعلم الوكيل من خلال التفاعل مع البيئة. بناءً على ذلك، يمكن رؤية الفرق بين هذه الأساليب الثلاثة للتعلم الآلي في الجدول 1-1.

التعلم شبه الخاضع للإشراف

التعلم شبه الخاضع للإشراف هو مزيج من التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف، أي أنه يحتوي على بيانات مصنفة وغير مصنفة. في هذه الطريقة، أولاً، يتم استخراج البيانات غير المسماة، والتي تمثل ميزات بيانات الإدخال، ثم تستخدم هذا التمثيل للسماح المكتسبة في التعلم الإشرافي. يتم استخدام هذا الأسلوب بشكل شائع عند توفر القليل من البيانات ذات العلامات وتركز على تقليل أوجه القصور في كل من النهج الخاضع للإشراف وغير الخاضع للإشراف. والغرض الرئيسي منه هو الاستخدام الفعال لجميع البيانات المتاحة، وليس البيانات المصنفة فقط.

المؤشر	التعلم الخاضع للإشراف	التعلم غير الخاضع للإشراف	التعلم المعزز
التعريف	يتعلم من خلال مجموعات البيانات ذات العلامات.	يتم تدريبه بدون توجيه من خلال البيانات غير المسماة.	يتفاعل مع بيئة العمل.
انواع البيانات	البيانات المصنفة	بيانات غير المصنفة	لا يوجد تعريف بيانات
نوع المشكلة	التصنيف والانحدار	قواعد الرابطة والتكتل (التجميع)	معتمد على المكافآت
المراقب	مراقب إضافي	بدون مراقب	بدون مراقب
الهدف	تعيين بيانات الإدخال لمخرجات محددة	اكتشاف النمط	تعلم سلسلة من الإجراءات

التعلم الخاضع للإشراف الذاتي

بالمقارنة مع التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف ، فإن التعلم الخاضع للإشراف الذاتي يشبه إلى حد كبير التعلم غير الخاضع للإشراف ولكنه يتطلب أيضاً بيانات مصنفة. في هذا النوع من التعلم ، يتم تدريب النموذج على العلامات التي يتم الحصول عليها تلقائياً وتمييزها من البيانات نفسها ، دون تعليق توضيحي بشري. في هذا النهج ، يقوم بتدريب نموذج التعلم الخاص به باستخدام جزء واحد من البيانات للتعلم بالجزء الآخر وإنشاء العلامات بدقة. في النهاية ، تحول طريقة التعلم هذه مشكلة التعلم غير الخاضعة للإشراف إلى مشكلة خاضعة للإشراف. يمكن مقارنة التعلم الذاتي مع المناهج الأخرى على النحو التالي:

▪ التعلم الخاضع للإشراف الذاتي مقابل التعلم الخاضع للإشراف.

من السمات الشائعة للتعلم الخاضع للإشراف والإشراف الذاتي أن كلا الطريقتين تسميان نماذج التعلم من مجموعة من البيانات التعليمية. ومع ذلك ، لا يحتاج التعلم الخاضع للإشراف الذاتي إلى إضافة العلامات يدوياً ، حيث يقوم بإنشائها.

▪ التعلم الخاضع للإشراف الذاتي مقابل التعلم شبه الخاضع للإشراف.

يستخدم التعلم شبه الخاضع للإشراف البيانات التعليمية ذات العلامات اليدوية للتعلم الخاضع للإشراف وأساليب التعلم غير الخاضعة للإشراف للبيانات غير المسماة لإنتاج نموذج يستخدم العلامات الموجودة ويخلق نموذجاً يمكنه التنبؤ بما يتجاوز البيانات

المصنفة. في المقابل ، يعتمد التعلم الخاضع للإشراف الذاتي كلياً على البيانات التي تفتقر إلى التسميات التي تم إنشاؤها يدوياً.

▪ التعلم الخاضع للإشراف الذاتي مقابل التعلم غير الخاضع للإشراف.

التعلم الخاضع للإشراف الذاتي يشبه التعلم غير الخاضع للإشراف. لأن كلا الأسلوبين يعملان مع مجموعات البيانات التي لا تحتوي على تسميات يدوية. في بعض المصادر، يعتبر التعلم الخاضع للإشراف الذاتي مجموعة فرعية من التعلم غير الخاضع للإشراف. ومع ذلك ، فإن التعلم غير الخاضع للإشراف يركز على التكتل والتجميع وتقليل الأبعاد. بينما يتم استخدام التعلم الخاضع للإشراف الذاتي لاستخلاص استنتاجات حول قضايا التصنيف والانحدار.

التعلم الفعال

إنه نوع من التعلم شبه الخاضع للإشراف وهو طريقة تمكن النموذج من استخدام مستخدم بشري تفاعلي أثناء عملية التعلم لتسمية البيانات بالمرحلات المرغوبة. يسمح التعلم النشط بأخذ عينات المجال بطريقة تقلل من عدد العينات وتزيد من فعالية النموذج. سيكون هذا النوع من التعلم مفيداً عندما لا يتوفر الكثير من البيانات ويكون جمع البيانات الجديدة وتصنيفها أمراً مكلفاً.

التعلم الاونلاين

يتم إجراء التعلم الآلي التقليدي في وضع عدم الاتصال (الافلاين) ، مما يعني أن لدينا مجموعة من البيانات ونريد تحسين المعادلة. ومع ذلك ، فإن استخدام التعلم عبر الإنترنت (الاونلاين) ضروري إذا كانت لدينا بيانات تدفق. في التعلم الاونلاين ، يحاول المتعلم تقديم أفضل التنبؤات أو القرارات باستخدام عينات من البيانات في كل مرحلة. يتغلب التعلم الاونلاين على مشاكل التعلم الجماعي. لأنه يمكن تحديث النموذج الذي تم إنشاؤه على الفور لكل عينة بيانات جديدة. يعد التعلم الاونلاين مناسباً لتلك المشكلات حيث يتم تقديم الملاحظات بمرور الوقت ومن المتوقع أن يتغير توزيع الاحتمالية للملاحظات بمرور الوقت. لذلك ، من المتوقع أن يتغير النموذج قدر الإمكان

للحد من هذه التغييرات. أصبح التعلم الاونلاين طريقة واحدة للتعلم من تدفق البيانات في العديد من تطبيقات العالم الحقيقي.

التعلم متعدد المهام

التعلم متعدد المهام هو نوع من التعلم الخاضع للإشراف الذي يسعى إلى إنشاء نموذج يمكنه أداء مهام مختلفة في وقت واحد من خلال مشاركة معلومات المجال حول قضية معينة. الدافع الرئيسي للتعلم متعدد المهام هو إنشاء نموذج "عام" يمكنه حل مهام متعددة في نموذج واحد بدلاً من إنشاء عدة نماذج "متخصصة" يتم تدريبها فقط لمهمة محددة. من وجهة نظر بيولوجية ، فإن تعدد المهام مستوحى من الطريقة التي نتعلم بها نحن البشر. لتعلم مهام جديدة ، عادة ما نطبق المعرفة التي اكتسبناها من تعلم المهام ذات الصلة. بالإضافة إلى ذلك ، عادة ما نتعلم أولاً المهام التي تمنحنا المهارات اللازمة لإتقان المهام الأكثر تعقيداً.

التعلم الانتقالي

التعلم الانتقالي هو نوع من التعلم الآلي يتم فيه تدريب النموذج لأول مرة في مهمة معينة، ثم يتم استخدام بعض أو كل النموذج كنقطة بداية لمهمة ذات صلة. بمعنى آخر، نريد استخدام ما تعلمناه من دالة مصدر واحدة لمساعدتنا في تعلم دالة أخرى مستهدفة. الغرض من التعلم الانتقالي هو تحسين عملية تعلم المهام الجديدة باستخدام الخبرة المكتسبة من حل المشكلات السابقة المتشابهة إلى حد ما. يعد التعلم الانتقالي مفيداً بشكل خاص في النماذج التي يتم تدريبها تدريجياً، ويمكن استخدام نموذج موجود كنقطة انطلاق لمزيد من التدريب، مثل شبكات التعلم العميق. يركز التعلم الانتقالي على استخراج البيانات من مجال مشابه لزيادة القدرة على التعلم أو تقليل عدد العينات ذات العلامات المطلوبة في المجال المستهدف. من المهم ملاحظة أن مخرجات نماذج التعلم الانتقالي تتأثر بالعلاقة بين المصدر والمجالات المستهدفة. إذا كان للمجال المصدر والمجال الهدف معرفة أقل شبيوعاً، فسيؤثر هذا النموذج سلباً على التعلم والدقة الهدف، وهو ما يسمى الانتقال السلبي.

الفرق بين التعلم الانتقالي والتعلم متعدد المهام

يختلف التعلم متعدد المهام عن التعلم الانتقالي، ويختلف في كيفية نقل المعرفة. يتم تعلم المهام بالتسلسل في التعلم الانتقالي ونقلها من واحد إلى آخر. في حين أن التعلم متعدد المهام من خلال مشاركة المعلومات بين جميع المهام يؤدي إلى أداء جيد في جميع المهام التي ينظر فيها نموذج واحد في وقت واحد.

التعلم التمثيلي¹

التعلم التمثيلي هو مجموعة فرعية من التعلم الآلي الذي يهدف إلى الحصول على ميزات جيدة ومفيدة للبيانات تلقائياً، دون أن يشارك مصمم الميزات في المشكلة. نظراً لأنه يمكن تفسير هذه الطريقة على أنها تعلم ميزات مفيدة، فإنها تسمى أيضاً تعلم الميزات. ومع ذلك، غالباً ما تُستخدم هذه الأساليب لإيجاد تمثيل جيد في المشكلات الخاضعة للإشراف مثل التصنيف والانحدار؛ ومع ذلك، من الممكن تعلم التمثيل دون إشراف. يُسهل تمثيل التعلم في البيانات الأولية رؤية المعلومات المفيدة عند إنشاء أي نموذج لمسائل التصنيف والتنبؤ والإنتاج.

البيانات التدريبية والتجريبية والتحقق من الصحة

على الرغم من أن خوارزميات التعلم الآلي تعتبر أدوات مذهلة وقوية في التنبؤ والتصنيف، إلا أن السؤال الذي يطرح نفسه حول مدى دقة هذه التنبؤات، وهل هناك طريقة لقياس أداء النموذج؟ نظراً لأن هذه الخوارزميات قد وصفت العينات، يمكن الإجابة على هذا السؤال بتقسيم عينات التدريب إلى عدة أقسام. من خلال تقسيم البيانات، نقوم أولاً بإجراء التدريب على جزء من البيانات، ثم نستخدم البيانات التجريبية لقياس كفاءة النموذج وإمكانية تعميمه. يشير التعميم إلى أداء النموذج في التعامل مع البيانات، وهو ما لم يلاحظه النموذج بعد في عملية التدريب. بالطبع في تصميم نماذج التعلم الآلي نقوم في أغلب الأحيان بتقسيم مجموعة بيانات المشكلة المطلوبة إلى قسم آخر بالإضافة إلى البيانات التدريبية والتجريبية، وطريقة هذا التصنيف على النحو التالي:

¹ Representation learning

- **مجموعة التدريب:** عادة ما تكون أكبر مجموعات البيانات الثلاث هذه وتستخدم للعثور على معاملات النموذج. تحدد مجموعة بيانات التدريب العلاقة الأساسية بين البيانات وعلاماتها بأفضل طريقة ممكنة.
- **مجموعة الاختبار (التجريبية):** قياس أداء النموذج بناءً على قدرة النموذج على التنبؤ بالبيانات التي ليس لها دور في عملية التعلم ، مجموعة الاختبار هي نفس البيانات التي لم يتم رؤيتها في عملية التعلم. هذه المجموعة تقيس أداء النموذج النهائي. إذا كان النموذج يعمل بشكل جيد في مجموعة التدريب ويناسب أيضاً مجموعة الاختبار ، أي أنه يتنبأ بالتسمية الصحيحة لكمية كبيرة من بيانات الإدخال التي تم تجاهلها ، فسيقلل الضبط الزائد overfitting. وتجدر الإشارة إلى أن مجموعة الاختبار تستخدم عادة مرة واحدة فقط لتقييم أداء تعميم النموذج بشكل كامل بمجرد تحديد معاملات النموذج والمعاملات الفائقة بشكل كامل. ومع ذلك ، يتم استخدام مجموعة التحقق لتقريب الأداء التنبئي لنموذج أثناء التدريب.
- **مجموعة التحقق من الصحة:** في تقييم أنواع مختلفة من النماذج والخوارزميات للمشكلة ، يتم استخدام مجموعة التحقق من الصحة. تستخدم هذه البيانات لضبط المعاملات الفائقة ومنع النموذج من الضبط الزائد لتحديد أفضل نموذج.

التعلم العميق

الدماغ هو أروع جزء في جسم الإنسان. يسمح لنا بتخزين الذكريات وتجربة العواطف أو حتى الأحلام. بدونها ، نحن كائن بيولوجي بدائي غير قادر على أبسط التفاعلات. إن الدماغ بطبيعته هو ما يجعلنا كائنات ذكية.

يوزن دماغ الطفل أقل من نصف كيلوغرام. ومع ذلك ، فهو قادر على حل المشكلات التي لا تمتلكها حتى أكبر وأقوى أجهزة الكمبيوتر العملاقة من صنع الإنسان. بعد عدة أشهر من الولادة ، يمكن للطفل التعرف على وجوه والديه ، وتحديد الأشياء المتعارضة ، وحتى تمييز الأصوات. في الطفولة المبكرة ، كان لديهم فهم واضح للقواعد وحفظوا آلاف الكلمات.

على مدى السنوات القليلة الماضية ، كان البشر يحاولون بناء آلات ذكية مثل الروبوتات التي تنظف المنازل ، والسيارات ذاتية القيادة ، والأنظمة التي تكتشف الأمراض تلقائياً. يتطلب بناء مثل هذه الآلات الاصطناعية الذكية حل بعض أكثر المشكلات الحسابية تعقيداً التي واجهناها على الإطلاق ؛ المشاكل التي يمكن للدماغ البشري حلها في أجزاء من الثانية. لمعالجة هذه القضايا ، يجب استخدام نهج مختلف تماماً لبرمجة الكمبيوتر التقليدية ، تم تطويره على مدار العقد الماضي. هذا هو المجال النشط للذكاء الاصطناعي ، والذي يشار إليه بالتعلم العميق.

التعلم العميق هو مجموعة فرعية من التعلم الآلي ويركز على دراسة وتطوير الآلات التي يمكنها التعلم. في تعريف أكثر دقة: التعلم العميق مع معالجة البيانات والمشابه للإنسان، من خلال تعلم مثال تم تعلمه مسبقاً، ومحاولة استخراج ميزات محددة تلقائياً، من خلال عدد طبقات التسلسل، ما هو موجود في هيكلها هو إنشاء نموذج لاتخاذ القرار من أجل حل مشكلة. يسمح وجود هذا العدد من الطبقات المختلفة بالتعلم العميق ليكون قادراً على اكتشاف ميزات محددة للمشكلة في كل طبقة واستخدامها لاتخاذ قرارات أفضل في حل المشكلة.

تاريخ التعلم العميق

التعلم العميق له تاريخ طويل على عكس التوقعات. قد يبدو الأمر مفاجئاً بعض الشيء ، لكن التعلم العميق موجود منذ الأربعينيات من القرن الماضي تحت عناوين مختلفة مثل: السيبرانية¹ والاتصالية² والأكثر شهرة ، الشبكات العصبية.

تم تقديم النموذج الأول للشبكات العصبية بواسطة ماك كلوج³ وبيتز⁴ في عام 1943. كانت الشبكة عبارة عن مصنف ثنائي يمكنه التمييز بين فئتين مختلفتين بناءً على قيم الإدخال. كانت مشكلة هذه الشبكة هي تعديل الأوزان بواسطة عامل بشري. بعد ذلك، في عام 1957 ، اقترح روزنبلات⁵ خوارزمية بيرسيبترون (Perceptron)، والتي يمكن أن تتعلم الأوزان لتصنيف البيانات في هيكلها دون تدخل عامل بشري. بينما تم استخدام

¹ cybernetics

² connectionism

³ McCulloch

⁴ Pitts

⁵ Rosenblatt

طريقة بيرسبترون لعدة سنوات ، في عام 1969 نشر مينسكي¹ وبويرت² مقالاً يوضح أن بيرسبترون لا يمكنها إلا تصنيف المشكلات الخطية ، وأن المشكلات غير الخطية لا يمكن حلها بهذه الطريقة. ادعى مؤلفو هذه المقالة أيضاً في نفس العام أنه لا توجد موارد حسابية مطلوبة لبناء شبكات عصبية كبيرة وعميقة ، وهو ادعاء أدى إلى تدمير المقالات على الشبكات العصبية. لحسن الحظ ، أدى إدخال خوارزميات الانتشار الخلفي بواسطة فيربوس³ (1974) و روملهات⁴ (1986) و لكان⁵ (1998) إلى الإحياء المبكر للشبكات العصبية. في هذا البحث ، كانوا قادرين على تدريب شبكة عصبية متعددة الطبقات.

اليوم ، تعد خوارزميات الانتشار الخلفي أساس الشبكات العصبية ، والتي يمكننا من خلالها تدريب الشبكة ، وكذلك التعلم من أخطائها. لكن في ذلك الوقت ، بسبب ضعف أجهزة الكمبيوتر ونقص مجموعات البيانات الكبيرة ، لم يتمكنوا من تدريب الشبكات العصبية بأكثر من طبقتين مخفيتين. ولكن اليوم ، مع تزايد قوة الأجهزة وعصر البيانات الضخمة ، والتي توفر الكثير من البيانات لتدريب الشبكة ، يمكن تعليم الشبكات التي تحتوي على أكثر من بضع طبقات مخفية. تسمى الشبكات العصبية المكونة من عدة طبقات الشبكات العميقة. عندما نستخدم الشبكات العميقة اليوم ، فإننا نعني التعلم العميق.

كيف يعمل التعلم العميق؟

تتعلم نماذج التعلم العميق من خلال التحليل المستمر للبيانات واكتشاف الهياكل المعقدة في البيانات. تتحقق عملية التعلم من خلال بناء نماذج حسابية تسمى الشبكات العصبية المستوحاة من بنية الدماغ. يتكون هيكل هذه الشبكة من عدة طبقات معالجة. يسعى التعلم العميق إلى استغلال البنية غير المعروفة في توزيع المدخلات من أجل اكتشاف تمثيل جيد من خلال هيكل هرمي للمفاهيم التي تشبه طبقات المعالجة.

في هذا الهيكل ، بالانتقال إلى طبقات المستوى التالي ، يكون قادراً على حل المفاهيم الأكثر تعقيداً للمشكلة. تقوم الطبقات الأولية بمعالجة البيانات الأولية والطبقات اللاحقة

¹ Minsky

² Papert

³ Werbos

⁴ Rumelhart

⁵ Lecun

قادرة على استخدام المعلومات العصبية الموجودة في الطبقات السابقة للحصول على معلومات أكثر تعقيداً من البيانات. على سبيل المثال، في معالجة الصورة، تعالج طبقة الإدخال كل بكسل من الصورة. تقوم الطبقات اللاحقة بمعالجة مجموعة من البكسلات واسترداد المعلومات من البيانات. قد تلاحظ الطبقات الأولية أن بعض البكسلات أعمق من غيرها، بينما قد تلاحظ الطبقات اللاحقة أن مجموعة من البكسلات تُظهر بُنية العين، وطبقة عميقة جداً لإدراك أن الصورة بأكملها تدور حول إنسان.

سبب شعبية التعلم العميق

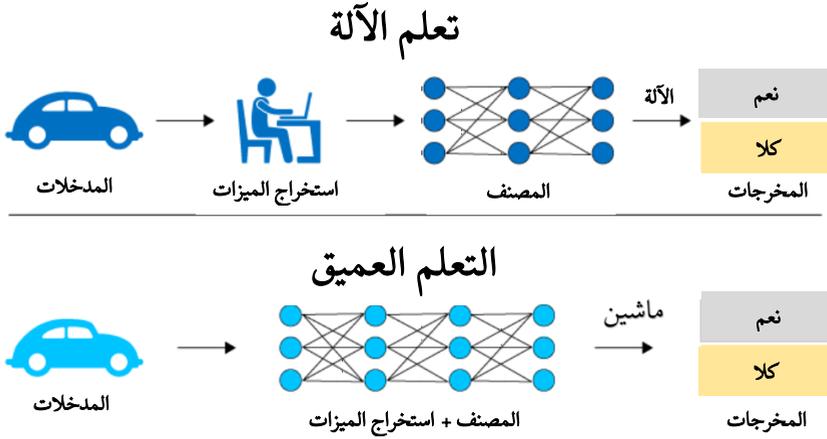
قبل ظهور التعلم العميق لعقود من الزمن، كانت أنظمة التعلم الآلي بحاجة إلى متخصص في مجال الموضوع لاستخراج الميزات يدوياً. اختيار السمات لمجموعة البيانات له تأثير كبير على نجاح نموذج التعلم الآلي، في حين أن استخراج السمات يدوياً سيكون عملية معقدة وتستغرق وقتاً طويلاً.

يتيح لك التعلم العميق تحويل البيانات الأولية إلى متجهات وإدخالها إلى الشبكة دون الحاجة إلى استخراج الميزة يدوياً من هذه البيانات. يؤدي التعلم العميق لاستخراج هذه الميزة بشكل أفضل من الخبير من خلال عدد الطبقات المختلفة في هيكلها، من أجل حل المشكلة بناءً على البيانات التعليمية المتعلقة بالمشكلة. يمكن لهذه الطبقات أن تتعلم بشكل مباشر ومنفردة تمثيلاً تجريبياً للبيانات الخام. يوضح الشكل 1-2 الفرق بين هذه الممارسة في التعلم الآلي والتعلم العميق. هنا، يتم إنشاء تمثيل مجرد ومضغوط للبيانات الخام في طبقات متعددة في الشبكة. بعد ذلك، يتم استخدام هذا العرض المضغوط لبيانات الإدخال لتوليد الإخراج. على سبيل المثال، تصنيف بيانات الإدخال إلى فئات مختلفة. أيضاً أثناء عملية التدريب على الشبكة، تم تحسين هذه الخطوة بواسطة الشبكة العصبية للحصول على أفضل تمثيل تجريدي ممكن لبيانات الإدخال. هذا يعني أن نماذج التعلم العميق تتطلب القليل جداً من الجهد اليدوي لأداء عملية استخراج الميزات وتحسينها. على سبيل المثال، إذا أردنا استخدام نموذج التعلم العميق لتحديد صورة السيارة، فيجب علينا أولاً استخراج ميزات معينة للسيارة (الشكل والحجم والعجلات) ونقلها إلى إدخال الخوارزمية. بهذه الطريقة، تقوم الخوارزمية بالتصنيف. بمعنى، يجب أن يتصرف المبرمج مباشرة لتحقيق نموذج النتيجة المرجوة. ومع ذلك، في التعلم العميق،

يتم تحديد استخراج الميزات داخل النموذج دون تدخل بشري لعمل التنبؤ المطلوب للمشكلة.

تعد خطوة استخراج الميزة جزءاً من عملية تحدث في شبكة اصطناعية عميقة.

الميزة الثانية للتعلم العميق هي أنه يتم تزويده بكمية كبيرة من البيانات. تميل نماذج التعلم العميق إلى زيادة الدقة مع زيادة كمية البيانات التعليمية. في المقابل، لا تتحسن نماذج التعلم الآلي التقليدية بعد نقطة تشبع واحدة.



الشكل 1-2 الفرق بين التعلم الآلي والتعلم العميق في استخراج الميزات.

سبب أهمية التعلم العميق

نحن نعيش في وقت غير مسبوق، حيث لعبت تقنية التعلم العميق دوراً أساسياً في العديد من الاختراقات الجديدة وكان لها دور أساسي في اكتشاف الكواكب خارج المجموعة الشمسية، واكتشاف العقاقير الجديدة، وتشخيص الأمراض والجسيمات دون الذرية. نحن نعيش أيضاً في عصر نواجه فيه تحديات مستمرة. يهدد تغير المناخ إنتاج الغذاء وقد يؤدي في يوم من الأيام إلى نشوب حرب بسبب الموارد المحدودة. يتزايد التحدي المتمثل في التغيير البيئي بسبب تزايد عدد السكان. يتطلب نطاق وحجم هذه التحديات مستوى جديداً من الذكاء أصبح ممكناً من خلال التعلم العميق.

التحديات فى التعلم العميق

التعلم العميق هو رائد الذكاء الاصطناعي وواحد من أكثر التقنيات إثارة فى العقد الماضى. والآن يتم استخدامها على نطاق واسع فى مجالات مختلفة مثل التعرف على الكلام وتشخيص السرطان والسيارات ذاتية القيادة والمجالات التي بدت مغلقة فى السابق. وفقاً لبعض الخبراء، سيستمر هذا الاتجاه بوتيرة أسرع وسيحتل مناطق أخرى.

فى بعض هذه الحالات، سيكون هناك خوف من أن يهدد التعلم العميق أسس الاقتصاد ومجتمع الحياة البشرية، مما يؤدي إلى البطالة أو العبودية. على الرغم من أن التعلم العميق كان فعالاً للغاية فى العديد من الأشياء، إلا أنهم لم يتمكنوا بعد من التغلب على جميع التقنيات. هذا بسبب القيود والتحديات التي واجهتها مقارنة بالعقل البشري. يمكن للمرء أن يتعلم العلاقات المجردة والواسعة بين المفاهيم المختلفة مع القليل من المعلومات واستخدامها فى صنع القرار. من ناحية أخرى، تتطلب خوارزميات التعلم العميق كميات كبيرة من البيانات فى هذه الإمكانيّة:

"يفتقر التعلم العميق اليوم إلى آلية التعلم المجرد من خلال التعريف الصريح واللفظي، ويعمل بشكل أفضل عندما يكون هناك الآلاف أو الملايين أو حتى المليارات من الأمثلة التعليمية".

مشكلة أخرى فى خوارزميات التعلم العميق هي أنها جيدة جداً فقط فى التخطيط بين المدخلات والمخرجات، لكنها ليست جيدة فى فهم سياق البيانات التي تستخدمها. فى الواقع، تشير كلمة "عميق" فى التعلم العميق إلى مرجع هندسة التكنولوجيا وعدد الطبقات المخفية فى هيكلها أكثر من كونها تشير إلى فهم عميق لما يتم القيام به.

التحدي الآخر فى التعلم العميق هو الافتقار إلى الشفافية. بينما يمكن تتبع القرارات التي تتخذها النماذج المستندة إلى القواعد من خلال عبارات if and else ، فإن هذا لن يكون ممكناً فى التعلم العميق. هذا النقص فى الشفافية هو ما يشار إليه فى التعلم العميق باسم "الصندوق الأسود".

تجد خوارزميات التعلم العميق الأنماط والارتباطات من خلال البيانات التي يتم تغذيتها بها وأحياناً تتخذ قرارات مربكة حتى للمهندسين الذين قاموا بإنشائها. لن تكون

هذه مشكلة عندما يقوم التعلم العميق بشيء ذي أهمية ثانوية. ولكن عندما يتعلق الأمر بتقرير مصير المتهم في المحكمة أو العلاج الطبي لمريض ، فقد يكون ذلك أمراً بالغ الأهمية. لأن الأخطاء يمكن أن يكون لها عواقب كثيرة. بحسب ماركوس:

" لا تزال قضية الشفافية دون حل ، ويريد المستخدمون فهم كيف اتخذ نظام معين قراراً محددًا عند استخدام التعلم العميق للعمل في مجالات التشخيص الطبي والأعمال المالية."

كما يقترح أنه يجب دمج التعلم العميق مع تقنيات أخرى مثل البرمجة البسيطة المستندة إلى القواعد وطرق أخرى للذكاء الاصطناعي مثل التعلم المعزز. يرى خبراء آخرون ، مثل باسكال كوفمان ، أن علم الأعصاب هو مفتاح الذكاء الاصطناعي الحقيقي الذي يمكنه حل مشاكل مثل البشر.

ومع ذلك، يُظهر التعلم العميق الآن أداءً جيداً وكفاءة لمشاكل التصنيف إذا كانت هناك مجموعة كافية من بيانات التدريب.

مقارنة بين التعلم الآلي والتعلم العميق

من أهم الاختلافات التي تقارن التعلم العميق بالتعلم الآلي هو أداء النظام بناءً على زيادة عدد الأمثلة التدريبية. لن يحقق التعلم العميق نتائج جيدة في حالة عدم وجود أمثلة تدريب كافية. في المقابل، يمكن أن يُظهر التعلم الآلي نتائج جيدة حتى مع وجود عدد صغير من الأمثلة. يتطلب استخدام التعلم العميق أيضاً أجهزة متقدمة، بينما يمكن استخدام التعلم الآلي مع كل من الأجهزة وأجهزة الكمبيوتر منخفضة الطاقة.

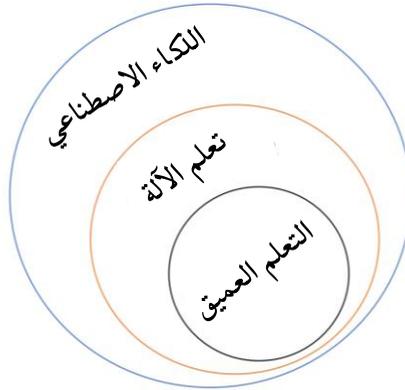
يتمثل الاختلاف المهم والرئيسي الذي يظهر قوة التعلم العميق مقابل التعلم الآلي في الاستخراج التلقائي للميزات في هذه الخوارزميات. باختصار، يمكن رؤية المقارنة بين التعلم الآلي والتعلم العميق في الجدول 1-2.

الجدول 1-2 مقارنة بين التعلم الآلى وأساليب التعلم العميق

المعايير	التعلم الآلى	يادگیری عميق
هندسة الميزات	تحتاج إلى فهم الميزات في البيانات	لا حاجة لاستخراج الميزات يدوياً
الاعتماد على البيانات	أداء ممتاز على البيانات المنخفضة والمتوسطة	أداء رائع في البيانات الضخمة
الاعتماد على الأجهزة	يعمل على الاجهزة الضعيفة أيضاً	يحتاج الى اجهزة قوية
وقت التنفيذ	من بضع دقائق إلى بضع ساعات	في بعض الأحيان تصل إلى بضعة أسابيع

العلاقة بين الذكاء الاصطناعي والتعلم الآلى والتعلم العميق

على الرغم من أن مصطلحات الذكاء الاصطناعي والتعلم الآلى والتعلم العميق تستخدم غالباً بشكل متبادل ومتشابك، إلا أنها لا تشير جميعها إلى نفس الشيء. يوضح الشكل 1-3 كيفية ارتباطها ببعضها البعض، وكما يمكن رؤيته، فإن التعلم العميق هو مجموعة فرعية من التعلم الآلى وكذلك الذكاء الاصطناعي.



الشكل 1-3 العلاقة بين الذكاء الاصطناعي والتعلم الآلى والتعلم العميق

لفهم الاختلافات والفصل بين هذه المجموعات الثلاث عن بعضها البعض، يمكن وصفها على النحو التالي:

الذكاء الاصطناعي: كما يوحي الاسم، فإن الذكاء الاصطناعي هو مزيج من الذكاء البشري في الآلة، بطريقة تحاكي السلوك الشبيه بالإنسان وتحل المشكلات بشكل إبداعي. بتعبير أدق، يحاول الذكاء الاصطناعي إيجاد طريقة لتنفيذ نسخة من الدماغ البشري، أي كما يفكر الإنسان ويعمل. على سبيل المثال، هذه الأنظمة قادرة على تحديد واكتشاف الأشياء أو نقلها أو أداء مهام أخرى. حتى الآن، لم يتم تطوير أي نظام يمكنه تحقيق المستوى الكامل للذكاء البشري، والسبب هو عدم وجود فهم كامل للدماغ البشري. ومع ذلك، فإن بناء مثل هذا النظام أصبح أقرب إلى الواقع يوماً بعد يوم.

التعلم الآلي: التعلم الآلي، وهو مجموعة فرعية من الذكاء الاصطناعي، يمكن الكمبيوتر ليكون قادراً على التعلم من خلال التجربة دون تخطيط صريح. يجد هذا التعلم علاقة بين مدخلات ومخرجات المشكلة لاستخدامها بواسطة البيانات المعطاة لكل مشكلة لاستخدامها في مواجهة مشكلة مماثلة. تعلم الآلة كيفية اتخاذ قرار بشأن مشكلة ما، وهي طريقة لتحقيق الذكاء الاصطناعي.

التعلم العميق: التعلم العميق هو مجموعة فرعية من التعلم الآلي ويستخدم بُنية الشبكات العصبية لتقليد عملية صنع القرار لحل مشكلة مشابهة للدماغ البشري، ويقوم بنفس الشيء مثل التعلم الآلي، ولكن بقدرات مختلفة. بمقارنة التعلم الآلي مع التعلم العميق، يمكن القول إنه بينما يستخرج التعلم العميق الميزات تلقائياً من بُنية البيانات، يجب أن يتم ذلك يدوياً عن طريق التعلم الآلي. وإذا قام بتنبؤات خاطئة في تقرير حل المشكلة، فإن الخبير أو المبرمج يجب أن يحل المشكلة بشكل صريح. لذلك يمكن اعتبار التعلم العميق نسخة متطورة ومتقدمة من التعلم الآلي.

كما رأينا، يعمل التعلم الآلي والتعلم العميق على تحقيق الذكاء الاصطناعي. نأمل أن تتمكن من تحقيق مستوى كامل من الذكاء الاصطناعي في المستقبل القريب. لذا فإن التعلم الآلي والتعلم العميق هما أداتان لتحقيق الذكاء الاصطناعي. بمعنى آخر، فإن أي خوارزمية للتعلم الآلي تتضمن التعلم العميق هي ذكاء اصطناعي، ولكن ليست كل خوارزمية ذكاء اصطناعي هي التعلم الآلي. الأنظمة الخبيرة، على سبيل المثال، هي ذكاء اصطناعي، لكنها لا تعتبر تعلم آلي.

تطبيقات التعلم العميق

تتضمن الأشياء التي تستخدم التعلم العميق اليوم مجموعة متنوعة من برامج تحليل البيانات الضخمة. تشمل المجالات المحددة التي تستفيد من التعلم العميق ما يلي:

- **معالجة اللغة الطبيعية:** يعد فهم التعقيدات المرتبطة باللغة والبنية والمعنى والاختلافات الدقيقة في النغمة والعبارة والتلميحات من أصعب المهام للتعلم البشري. يساعد التعليم المستمر منذ الولادة والتواجد في بيئات اجتماعية مختلفة الشخص على الحصول على الاستجابة الصحيحة وشكل التعبير الشخصي لسيناريوهات مختلفة. يسعى استخدام التعلم العميق في معالجة اللغة الطبيعية إلى تحقيق نفس المستوى البشري من خلال التعلم الآلى ، مع مراعاة الاختلافات اللغوية والاستجابات المناسبة. تستخدم معالجة اللغة الطبيعية التعلم العميق في العديد من مهامها مثل: تحليل المشاعر ، ونمذجة اللغة ، وتصنيف النص ، واسترجاع المعلومات ، وتضمين الكلمات ، وفهم اللغة المنطوقة ، والترجمة الآلية ، وأنظمة الأسئلة والأجوبة ، إلخ.
- **الروبوتات:** ترجع التطورات الحديثة في مجال الروبوتات إلى التطورات في الذكاء الاصطناعي والتعلم العميق. يمكن الذكاء الاصطناعي الروبوتات من إدراك بيئتها والتفاعل معها. تعني هذه التطورات أنه يمكننا توقع استخدام الروبوتات بشكل متزايد كمساعدين بشريين في المستقبل القريب.
- **المساعدين الافتراضيين:** أحد أكثر التطبيقات استخدامًا هو التعلم العميق للمساعدين الافتراضيين. يوفر كل تفاعل مع هؤلاء المساعدين فرصة لهم لمعرفة المزيد عن صوتك ولهجتك. ونتيجة لذلك ، فإنه يجلب لك تجربة تفاعلية بشرية ثانوية. يستخدم المساعدون الافتراضيون التعلم العميق لمعرفة المزيد حول مواضيعهم ، من إعدادات العشاء إلى الأماكن الشعبية أو الموسيقى المفضلة. سوف يتعلمون فهم أوامرك من خلال تقييم لغة الإنسان الطبيعية. ميزة أخرى للمساعدين الافتراضيين هي ترجمة كلامك إلى نص ، وكتابة ملاحظات لك وحجز مواعيدك. المساعدون الافتراضيين جاهزون فعليًا لخدمتك. لأنه يمكنهم فعل كل شيء من الرد على مكالماتك المحددة إلى التنسيق بينك وبين أعضاء فريقك.

- **الأمته الصناعية:** التعلم العميق لتعزيز سلامة العمال في بيئات مثل المصانع والمستودعات يوفر خدمات للكشف تلقائياً عن اقتراب العمال أو الأشياء من الجهاز.
- **كشاورزي:** التعلم العميق يمكن أن يحدث ثورة في الزراعة. يتيح التعلم العميق للمزارعين اليوم استخدام المعدات اللازمة للتمييز بين المحاصيل والأعشاب الضارة. تمنح هذه الميزة الآلات القدرة على رش مبيدات الأعشاب بشكل انتقائي على الحشائش وترك النباتات الأخرى سليمة. أيضاً، يمكن للآلات الزراعية التي تستخدم رؤية الكمبيوتر ذات القدرة على التعلم العميق تحسين نباتات معينة عن طريق الرش الانتقائي لمبيدات الأعشاب والأسمدة ومبيدات الفطريات ومبيدات الحشرات. بالإضافة إلى الحد من استخدام مبيدات الأعشاب وتحسين الإنتاج الزراعي، يمكن توسيع التعلم العميق ليشمل العمليات الزراعية الأخرى مثل استخدام الأسمدة والري والحصاد.
- **تحديد الأنواع البحرية:** يعد البحث عن تحديد الأنواع البحرية جزءاً مهماً من تدابير حماية بيئة المحيطات. مع التقدم الكبير في التعلم العميق، ازداد الاهتمام بهذا الموضوع.
- **البحث الطبي:** بدأ باحثو السرطان في استخدام التعلم العميق لتحديد طريقة للكشف التلقائي عن الخلايا السرطانية.
- **التصوير الطبي:** في الآونة الأخيرة، تم استخدام تقنيات التعلم العميق على نطاق واسع لتحليل الصور الطبية وأظهر نتائج مشجعة، خاصة بالنسبة لمجموعات البيانات الكبيرة.
- **أنظمة التوصية:** يستخدم التعلم العميق في أنظمة التوصية لاستخراج ميزات مفيدة للتوصيات.
- **التعرف على الإيماءات والحركة:** يعد اكتشاف الحركة أحد المجالات الجديدة في التعلم الآلي ويرتبط بالتعرف على حركات الوجه البشرية. الإشارات المنبعثة من أجهزة الاستشعار قادرة على اكتشاف العواطف أو حتى الكائن وخصائصه مع الطاقة والتأخير الزمني وتغيير التردد.

- **تشخيص تأخر النمو عند الأطفال:** يمكن لاضطرابات النطق والتوحد واضطرابات النمو أن تضعف نوعية حياة الطفل الجيدة. يمكن أن يكون للتشخيص والعلاج المبكر تأثير مفاجئ على صحة الطفل الجسدية والعقلية والعاطفية. لذلك، فإن أحد أكثر التطبيقات المحددة للتعلم العميق هو فترة الاكتشاف المبكر والتعافي من هذه المشاكل المتعلقة بالأطفال.

يتمثل أحد الاختلافات الرئيسية بين التعلم الآلي والتعلم العميق في أن التعلم الآلي غالبًا ما يستخدم فقط لمهام محددة. في المقابل، يساعد التعلم العميق في حل أخطر مشاكل الجنس البشري.

خلاصة الفصل الاول

- ◆ يمكن اعتبار التعلم بمثابة تحسين للأداء في مهمة معينة باستخدام الخبرة والممارسة.
- ◆ أي برنامج كمبيوتر يعمل على تحسين أدائه في وظيفة معينة ذات خبرة قد تعلم.
- ◆ يمكن تنفيذ التعلم الآلي من خلال ثلاثة مناهج مختلفة: التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف والتعلم المعزز.
- ◆ يركز التعلم الآلي على تصميم النماذج التي ، في مجال معين ، تحصل تلقائيًا على خوارزميات الكمبيوتر بناءً على بيانات التدريب المعطاة لنموذج التعلم من خلال التجربة وتجريب البيانات لمواجهة بيانات جديدة في نفس المجال يمكن أن يتصرف المجال بشكل مشابه للبشر.
- ◆ يمكن أن يقوم التعلم العميق باستخراج الميزات تلقائيًا بدلاً من التعلم الآلي.



أسئلة للمراجعة

1. لماذا لا يزال التعلم الآلي مستخدمًا على الرغم من التعلم العميق؟

2. كيف وبأي طريقة يستخلص التعلم العميق الميزات؟
3. ما هو الفرق المهم بين التعلم العميق والتعلم الآلي؟
4. اشرح تحديات التعلم العميق؟
5. ما هي العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق؟

الفصل 2

**التعلم العميق الخاضع للإشراف:
الشبكة العصبية امامية التغذية، المتكررة والالتفافية**

الأهداف:

- عملية التعلم في الشبكات العصبية.
- التعرف على الشبكات امامية التغذية والمتكررة والالتفافية
- تحديات التدريب في الشبكات العميقة.

المقدمة

تستخدم العديد من خوارزميات التعلم الآلي الحالية هياكل "ضحلة". وتشمل هذه الشبكات العصبية مع طبقة مخفية واحدة ، والانحدار الأساسي ، وآلات متجهات الدعم ، والمزيد. تظهر النتائج النظرية أن التمثيلات التي تعلمتها هذه الأنظمة هي بالضرورة بسيطة وغير قادرة على استخراج مجموعة متنوعة من الهياكل المعقدة من المدخلات.

تظهر الحجج النظرية والبيولوجية أنه من أجل بناء نظام ذكي لديه القدرة على استخراج تمثيلات عالية المستوى وقوية من هذه البيانات ، هناك حاجة إلى نماذج معمارية عميقة تتضمن العديد من طبقات المعالجة غير الخطية. يمكن القول إن أفضل الأمثلة وأكثرها استخداماً لهذه الشبكات هي الشبكات العصبية متعددة الطبقات نظراً لتوافقها مع أنواع البيانات.

الشبكات العصبية الاصطناعية

الغرض من اكتشاف الإنسان للعلوم الجديدة هو زيادة القدرات البشرية. اخترعنا النار لطهي الطعام. لذلك ، قللنا من اعتمادنا على القدرة الأولية على معالجة الطعام في المعدة. أدى هذا إلى زيادة في تناول السعرات الحرارية وربما نمو الحضارة ، وهو أمر لم يكن بمقدور أي شخص آخر القيام به. اخترعنا عجلات ومركبات أخرى بحيث لا تقتصر سرعة السفر على القدمين.

قصة الاختراع البشري ونمو التكنولوجيا هي سرد لنوع فريد من نوعه في الطبيعة يتخطى باستمرار قدراته ويوسع آفاقه إلى ما لا نهاية وينتقل إلى المستقبل. ترتبط معظم هذه التطورات ببنية الدماغ البشري. إن الجهاز العصبي للإنسان وقدراته الشاسعة والمعقدة. لدى البشر جهاز عصبي معقد للغاية قادر على التفكير والاستدلال والشعور والخيال والفلسفة. تحدث عملية التعلم أيضاً في الجهاز العصبي داخل دماغ الإنسان. إذا تمكنا من فهم كيفية عمل الدماغ ، فقد نتمكن من تنفيذ القدرة على تنفيذ نسخة منه في الآلات.

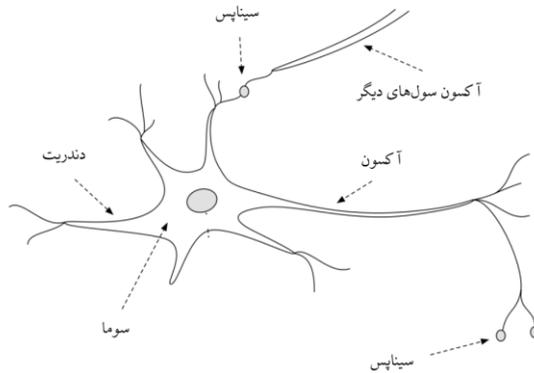
على الرغم من أن الدماغ هو أحد أكثر المكونات تعقيداً وقوة في بنية الكائنات الحية ، إلا أن بُنيته الأساسية بسيطة نسبياً ومفهومة. الشبكات العصبية الاصطناعية هي نسخ من

هذا الهيكل. الشبكات العصبية الاصطناعية هي نماذج حسابية تحاكي آلية التعلم لبنية الدماغ البشري مثل الشبكة العصبية الطبيعية.

تتكون بنية الدماغ البشري ، وهي الشبكة العصبية الطبيعية ، من عدد كبير من الوحدات البسيطة تسمى الخلايا العصبية. تحتوي الخلايا العصبية على ثلاثة أنواع من المكونات: **التشعبات ، والسوما ، والمحاور**. يمكن رؤية منظر لها في الشكل 2-1.

تستخدم الخلايا العصبية المحاور والتشعبات للتواصل مع بعضها البعض. تسمى مناطق الربط بين المحاور والتشعبات نقاط الاشتباك العصبي. غالباً ما تتغير هذه النقاط استجابةً للمحفزات الخارجية ، وهذه التغييرات هي التي تؤدي إلى التعلم في الكائنات الحية. يولد كل خلية عصبية إشارة داخل نفسها عن طريق إنشاء عمليات كيميائية ، ويتم إرسال الإشارات المرسله من كل خلية عصبية بواسطة المحور العصبي إلى التشعبات العصبية الأخرى. بناءً على هذه الإشارات ، يقوم الدماغ بعمل محدد. الشبكات العصبية الاصطناعية هي محاكاة لبنية الدماغ البشري وتستند إلى هذه الفرضيات:

1. تتم معالجة المعلومات في هياكل بسيطة بأعداد كبيرة تسمى الخلايا العصبية.
2. تنتقل الإشارات من خلال الاتصالات بين الخلايا العصبية في الشبكة.
3. كل اتصال له وزنه الخاص ، والذي يتم ضرب هذه الأوزان في الشبكة العصبية بواسطة إشارة الإرسال.
4. يستخدم كل خلية عصبية دالة تنشيط لتطبيقها على مدخلاتها ، وهي مجموع الأوزان لإشارات الإدخال ، لتوليد إشارة الخرج.



الشكل 2-1 منظر لشبكة عصبية طبيعية

وفقاً لهذه الفرضيات ، فإن نمط الاتصال بين الخلايا العصبية المختلفة لتلك الشبكة يسمى بنية الشبكة وطريقة تحديد الأوزان على الاتصالات تسمى الخوارزمية التعليمية.

تشكل الشبكة العصبية طبقة من خلال ضم عدة خلايا عصبية معاً. في الشبكة العصبية الاصطناعية ، يحسب حساب الدالة عن طريق نشر القيم المحسوبة من الخلايا العصبية المدخلة إلى الخلايا العصبية الناتجة واستخدام الأوزان كمعاملات وسيطة. يحدث التعلم عن طريق تغيير الأوزان المرتبطة بالخلايا العصبية. وفقاً للمحفزات الخارجية اللازمة لتعلم بنية الدماغ ، توجد بيانات تعليمية في الشبكات العصبية الاصطناعية لهذا المحفز الخارجي ، وهي أمثلة على أزواج المدخلات-المخرجات.

فمثلاً؛ قد تحتوي بيانات التدريب على تمثيلات بكسل للصور كأدخال للمشكلة والعلامات مثل الكلاب والقطط والأرانب كإخراج. يتم تغذية هذا الزوج من بيانات التدريب إلى بنية الشبكة العصبية باستخدام تمثيلات الإدخال لعمل تنبؤات حول علامات الإخراج. توفر بيانات التدريب تغذية راجعة حول الأوزان المتاحة على الشبكة اعتماداً على المخرجات المتوقعة (مثل القطة) لمدخل معين. يتم تنظيم الأوزان بين الخلايا العصبية استجابةً للأخطاء المتوقعة في الشبكة العصبية. الغرض من تغيير الأوزان هو تعديل الأداء الحسابي ، بحيث تكون التنبؤات أكثر دقة في التكرارات اللاحقة. لذلك، يتم تعديل الأوزان رياضياً والتحقق من صحتها لتقليل الخطأ الحسابي.

من خلال ضبط الأوزان بشكل تسلسلي بين الخلايا العصبية بناءً على مدخلات ومخرجات بيانات التدريب ، يتم تحسين الأداء المحسوب بواسطة الشبكات العصبية بمرور الوقت لعمل تنبؤات أكثر دقة. لذلك ، إذا تم تدريب الشبكة العصبية بالعديد من الصور المختلفة ، فستتمكن في النهاية من التعرف على صورة القط بشكل صحيح في الصورة التي لم ترها من قبل.

يتشكل سلوك الشبكة العصبية من خلال بنية تلك الشبكة. يتم تعريف هذه البنية على أساس ما يلي:

- عدد الخلايا العصبية.
- عدد الطبقات.
- كيفية الاتصال بين الطبقات.

يُطلق على البنية الأكثر شهرة للشبكة العصبية اسم الشبكة العصبية متعددة الطبقات ، والتي تسمى أيضاً بيرسيبترون متعدد الطبقات ، والذي يتكون من ثلاث طبقات: طبقة الإدخال ، والطبقة المخفية ، وطبقة الإخراج. تتلقى طبقة الإدخال المعلومات ، تقوم طبقة مخفية واحدة أو أكثر بتنفيذ عملية المعالجة ، وتعرض الطبقة الناتجة من النتائج. مع زيادة عدد الطبقات المخفية ، تنتقل إلى شبكة أعمق لديها القدرة على حل مشاكل أكثر تعقيداً من نظيراتها الضحلة. في ما يلي ، سوف نقدم الشبكات العصبية أحادية الطبقة ومتعددة الطبقات.

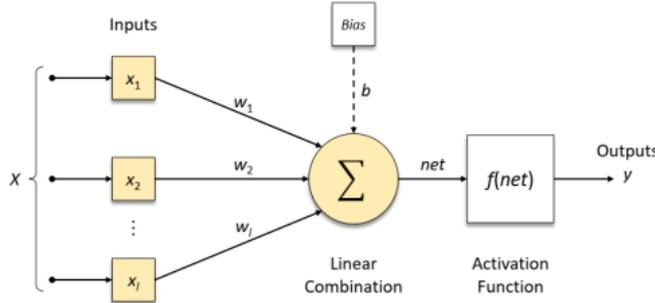
بيرسيبترون

اخترعت بيرسيبترون بواسطة فرانك روزنبلات في عام 1957 في مختبر كورنيل للطيران، بيرسيبترون هو أبسط شكل للشبكة العصبية الاصطناعية وهو عبارة عن مصنف ثنائي. إن بنية هذه الشبكة العصبية ليست سوى طبقة إدخال واحدة بمخرج واحد فقط، ومن ثم يطلق عليها أيضاً اسم الشبكة العصبية أحادية الطبقة. يظهر مثال على ذلك في الشكل 2-2. كما يمكن رؤيته، هناك عدد كبير من المدخلات في هذه الشبكة، والتي يتنبأ مجموعها، بعد الحساب، بالإخراج باستخدام دالة التنشيط. مع قائمة المدخلات $x = \{x_1, x_2, \dots, x_n\}$. سيكون لكل إدخال متجه وزن $w = \{w_1, w_2, \dots, w_n\}$. يتم حساب مجموع الأوزان بالمعادلة 2-1:

$$net = \sum_{i=0}^n w_i * x_i + b \quad \text{معادله 2 - 1}$$

ثم تحصل دالة التنشيط على الناتج y بناءً على العتبة θ :

$$y = f(net) = \begin{cases} 1, & \text{if } net \geq \theta \\ 0, & \text{if } net < \theta \end{cases}$$



الشكل 2-2 مخطط بيرسيبترون

خوارزمية التعلم بيرسيبترون

مع الافتراضات المناسبة، يمكن إثبات أن التعلم في بيرسيبترون سوف يتقارب مع الأوزان الصحيحة من خلال تكرار الخوارزمية الخاصة به. أي أن التعلم الشبكي سيؤدي إلى تقدير الأوزان التي تمكن الشبكة من إنشاء القيم الصحيحة في المخرجات بناءً على مدخلات المشكلة. في خوارزمية بيرسيبترون، لكل متجه إدخال أثناء التدريب، فإنه يولد شبكة الإخراج ويقارنها بالقيمة الصحيحة لتحديد ما إذا كان قد حدث خطأ. في هذه الشبكة، إذا لم يحدث خطأ، فلن تتغير الأوزان وسيستمر التدريب حتى تصبح الشبكة خالية من الأخطاء.

لنفترض أننا قمنا بتغذية متجه إدخال إلى الشبكة وأن إحدى الخلايا العصبية تقدم إجابة خاطئة؛ أي أن مقدار المدخلات ليس هو نفسه الهدف. هناك وزن m لهذه الشبكة، فكل خلية عصبية متصلة بعقدة الإدخال تحدد وزناً. إذا أطلقنا على k الخلية العصبية التي أنتجت ناتجاً خاطئاً، فإن الأوزان هي w_{ik} ، حيث يمكننا أن يكون من 1 إلى m . بناءً على هذا نعرف الأوزان التي تتغير. الآن دعونا نلقي نظرة على كيفية تغير الأوزان. السؤال الأول هو ما إذا كان كل وزن كبير جداً أم صغيراً جداً. حساب $y_k - t_k$ هو الفرق بين الإخراج (y_k) الذي تقوم به الخلية العصبية والقيمة المستهدفة (t_k) التي يجب أن تقوم بها الخلية العصبية. إذا أصبحت هذه القيمة سالبة، فإننا نجعلها أكبر، وعلى العكس، إذا كانت موجبة، فيمكن التحكم فيها عن طريق تقليل الخطأ. تعتمد كيفية تغيير الأوزان على المعادلة التالية:

$$\Delta w_{ik} = -(y_k - t_k) \times x_i$$

قبل أن ينتهي قانون التعلم ، ومع ذلك ، يجب أن نقرر مدى تغير الأوزان. يتم ذلك بضرب القيمة العالية بواسطة معامل يسمى **معدل التعلم** ، والتي يتم تمثيله عادةً بالرمز η . تحدد قيمة معدل التعلم سرعة التعلم للشبكة وهي مهمة للغاية. بناءً على ذلك ، نكتب المعادلة الأخيرة لتحسين الوزن على النحو التالي:

$$w_{ij} \leftarrow w_{ij} - \eta(y_i - t_i) \cdot x_i$$

بناءً على ذلك ، يمكن رؤية خوارزمية تعلم بيرسيبترون على النحو التالي.

خوارزمية التعلم بيرسيبترون

- **تهيئة القيم الأولية**

قم بتعيين قيم صغيرة لجميع الأوزان w_{ij} .

- **التدريب**

لتكرار T حتى تكون جميع النواتج صحيحة:

- حساب دالة التنشيط لكل خلية عصبية z باستخدام وظيفة التنشيط g :

$$y_j = g\left(\sum_{i=0}^m w_{ij}x_i\right) = \begin{cases} 1, IF \sum_{i=0}^m w_{ij}x_i > 0 \\ 0, IF \sum_{i=0}^m w_{ij}x_i \leq 0 \end{cases}$$

- يتم ضبط كل من الأوزان بشكل فردي على النحو التالي:

$$w_{ij} \leftarrow w_{ij} - \eta(y_i - t_i) \cdot x_i$$

- **الاستدعاء**

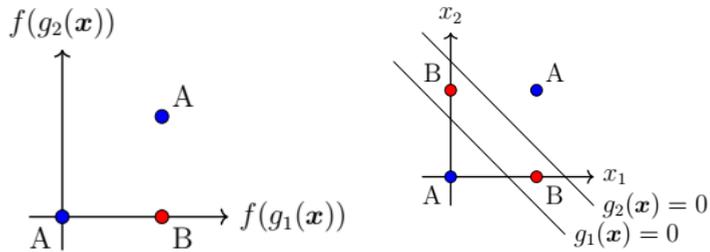
- حساب دالة التنشيط لكل خلية عصبية z:

$$y_j = g \left(\sum_{i=0}^n w_{ij} x_i \right) = \begin{cases} 1, & \text{اگر } w_{ij} x_i > 0 \\ 0, & \text{اگر } w_{ij} x_i \leq 0 \end{cases}$$

مسئلة XOR وعدم قدرة بيرسيبترون على حلها

تقوم خوارزمية التعلم بيرسيبترون بضبط الأوزان بحيث يتم تصنيف جميع عينات الإدخال بشكل صحيح. لن تكون خوارزمية التعلم هذه محدودة إذا لم تكن المدخلات قابلة للفصل خطياً عن بعضها البعض. لن تكون هذه الشبكة العصبية أحادية الطبقة قابلة للاستخدام في مشاكل العالم الحقيقي لأن الأنماط بين الفئات ليست بالضرورة قابلة للفصل خطياً. لذلك نذهب إلى مجموعة من الشبكات التي لديها قوة أكبر في حل مشاكل العالم الحقيقي.

يعد استخدام الطبقة المخفية في بنية الشبكات بمثابة هروب من القيود الموجودة في الشبكات أحادية الطبقة. لفهم هذه المسئلة بشكل أفضل، ضع في اعتبارك الشكل (أ) 2-3؛ حيث $[0,0]$ و $[1,1]$ تنتمي إلى الفئة A و $[0,1]$ و $[1,0]$ تنتمي إلى الفئة B. من السهل ملاحظة أنه لا توجد خطوط مستقيمة يمكنها فصل الفئتين تماماً. لذلك، فإن المصنف الخطي مثل بيرسيبترون لديه أداء ضعيف للغاية في هذه الحالة.



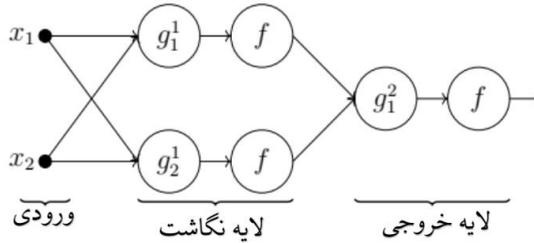
(أ) مسئلة تصنيف XOR (ب) مسئلة XOR في تعيينها

الشكل 3-2 مسئلة XOR في الفضاء الرئيسي والمنقول.

ومع ذلك ، ماذا يحدث إذا تم استخدام أحد البيرسيترون بدلاً من ذلك؟ من الشكل (أ)، يمكن أن نفهم بسهولة أن المسافة بين g_1 و g_2 مخصصة للفئة B ويجب تخصيص المساحة أدناه g_1 أو أعلى g_2 للفئة A. الآن ضع في اعتبارك هذا التعيين:

$$x \rightarrow \begin{bmatrix} f(g_1(x)) \\ f(g_2(x)) \end{bmatrix}, \quad f(x) = \begin{cases} 1, & \text{if } net \geq \theta \\ 0, & \text{if } net < \theta \end{cases}$$

الآن $g_i(x)$ كما هو وارد في المعادلة 2-1. يمكن رؤية نتيجة هذا التعيين في الشكل (ب) 2-3. كما نرى بوضوح ، يمكن فصل الفئات الآن خطياً في مساحة جديدة. يقدم الشكل 2-4 نظرة عامة على البيرسيترون ثنائي الأبعاد. سيكون الناتج 0 أو 1 ، اعتماداً على الفئة x التي تنتمي إليها.



شكل 2-4 پرسپترون دو لایه

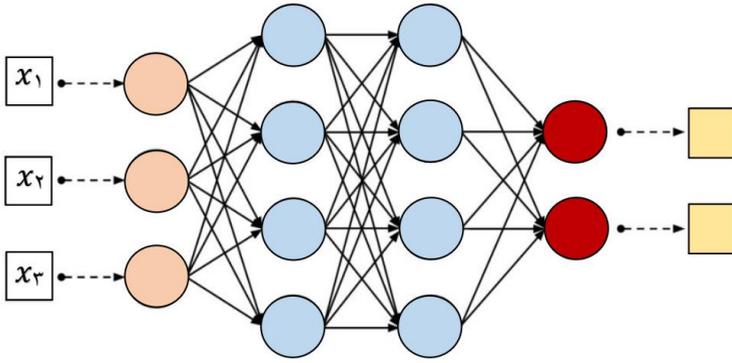
شبكات التغذية العميقة

كما هو مذكور، كان أحد القيود الرئيسية للشبكات أحادية الطبقة أنه لا يمكن تصنيفها إلا بحيث يمكن فصل البيانات خطياً، وإلا فلن يتم حل مشكلة هذه الشبكات. لحل هذا القيد، يمكن استخدام طبقة مخفية بين طبقات الإدخال والإخراج. ومن الأمثلة على هذه الشبكات، والتي تعد أيضاً أساس التعلم العميق، الشبكات العصبية بيرسيبترون متعددة الطبقات، والتي يشار إليها أيضاً باسم شبكات التغذية العميقة.

تعد هذه الشبكات واحدة من أكثر الشبكات استخداماً في التعلم العميق نظراً لتوافقها مع مجموعة متنوعة من المشكلات. لأنه لا يوجد حد لإدخاله سواء كانت البيانات صورة أو نص أو فيديو. سبب تسمية التغذية الامامية هو عدم وجود اتصال تغذية مرتدة ، يمكن من خلاله إرجاع مخرجات النموذج إلى النموذج نفسه. تستخدم الخلايا العصبية في كل

طبقة دالة تنشيط مشتركة ، وبالنسبة لطبقة الإدخال ، يكون الإدخال هو المتجه الخام للبيانات.

في هذه الشبكات، بالانتقال إلى أي طبقة أخرى، يتم حساب مجموع الاوزان للخلايا العصبية للطبقة السابقة وبعد تطبيق دالة التنشيط غير الخطي، يتم نقلها إلى طبقة أخرى للوصول أخيراً إلى طبقة الإخراج. يوضح الشكل 2-5 مخططاً لشبكة عصبية امامية التغذية عميقة متصلة بالكامل.



طبقة المخرجات الطبقة المخفية 2 الطبقة المخفية 1 طبقة المدخلات المقادير المدخلة

الشكل 2-5 بنية شبكة عصبية امامية التغذية عميقة متصلة بالكامل

بناءً على مفهوم الطبقة، ستكون بنية الشبكات العصبية امامية التغذية العميقة على النحو التالي:

- طبقة إدخال واحدة فقط.
- طبقة مخفية واحدة أو أكثر، متصلة بالكامل.
- طبقة إخراج واحدة فقط.

نتقل الآن إلى كيفية عمل كل طبقة من هذه الطبقات وتطبيقها:

طبقة الإدخال: هذه الطبقة هي أول طبقة مرئية وتحدد كيفية تلقي بيانات الإدخال (المتجهات) إلى الشبكة. في هذه الطبقة، يمثل عدد الخلايا العصبية عادةً عدد الميزات في الشبكة. ترتبط هذه الطبقة تمامًا بالطبقات المخفية في الشبكات العصبية امامية التغذية. في معماريات الشبكات الأخرى، من الممكن أن يكون هذا الاتصال غير متصل بشكل كامل.

الطبقة المخفية: هناك طبقة مخفية واحدة أو أكثر في شبكات العصبية امامية التغذية. قيم الأوزان في اتصالات الطبقة البينية هي كيفية تشفير الشبكات العصبية لاستخراج المعلومات المستفادة من البيانات الأولية. تشير كلمة "مخفية" إلى أن هذه الطبقة غير مرئية للنظام الخارجي. تسمح هذه الطبقة بنمذجة الدوال غير الخطية. سيكون وجود طبقة مخفية كافياً لمعظم المشكلات؛ كلما زاد عدد الطبقات، زاد الوقت الذي يستغرقه إنتاج هذه الشبكة، وبدلاً من ذلك يمكن أن تحل مشاكل أكثر تعقيداً. سيعتمد العدد الأمثل للطبقات والخلايا العصبية في كل طبقة إلى حد كبير على المشكلة. يعد اختيار العدد الصحيح من الخلايا العصبية في كل طبقة مخفية أمراً بالغ الأهمية، لأنها تلعب دوراً رئيسياً في نجاح عملية حل المشكلات. يجب تحديد هذه الأرقام بشكل تجريبي. سيؤدي اختيار عدد صغير من الخلايا العصبية إلى الضبط الناقص. من ناحية أخرى، سيؤدي العدد الكبير من الخلايا العصبية المستخدمة في الطبقة المخفية إلى زيادة غير ضرورية في وقت التدريب وإمكانية الضبط الزائد.

طبقة الإخراج: هذه الطبقة هي آخر طبقة كانت مرئية ويمكن توقع أو حل المشكلة في هذه الطبقة. يمكن أن يعتمد هذا الإخراج على التصميم الذي لدينا للمشكلة، يمكن أن يكون هذا الناتج مجموعة من الاحتمالات المتعلقة بمشكلة التصنيف، أو ناتج مُقيّم متعلق بمشكلة الانحدار. يتم تحديد هذا الإخراج بواسطة دالة التنشيط. يتناسب عدد الخلايا العصبية في هذه الطبقة مع المشكلة. على سبيل المثال، إذا كانت المشكلة هي التصنيف الثنائي، فستحتوي طبقة الإخراج على خليتين عصبيتين.

دالة التنشيط

تلعب دالة التنشيط دوراً مهماً ورئيسياً في بُنية نموذج الشبكة العصبية. تُستخدم هذه الدالة لنشر ناتج كل طبقة إلى أخرى في نهاية العملية الحسابية في كل خلية عصبية. ببساطة، فإن دالة التنشيط هي المسؤولة عن تحديد الخلايا العصبية التي يجب تنشيطها أو التي يجب تعطيلها. بشكل عام، يتم استخدام دوال التنشيط غير الخطية بشكل أكثر شيوعاً في الشبكات العصبية.

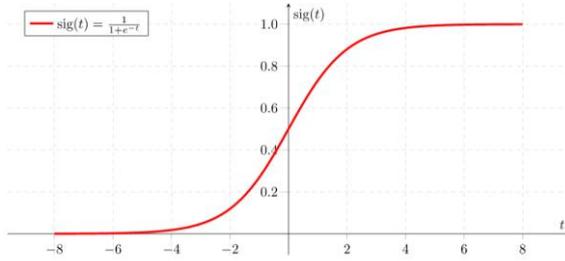
لا يمكن أن تكون دالة التنشيط المستخدمة في شبكات التغذية، على عكس بعض الشبكات الأخرى، ذات أي دالة، ولكن يجب أن يكون لها خصائص معينة. يجب أن تكون هذه الدالة مستمرة ومشتقة وتنازلية بشكل منتظم، ويجب أن يكون المشتق الأول

لهذه الدالة قابلاً للحساب بسهولة. فيما يلي، سنراجع بعض الأمثلة لدوال التنشيط المستخدمة على نطاق واسع في التعلم العميق.

دالة سيجمويد (sigmoid): تعد دالة سيجمويد، والمعروفة أيضاً باسم الدالة المنطقية، واحدة من أكثر دوال التنشيط غير الخطية فائدة في الشبكات العصبية الاصطناعية. تُستخدم هذه الدالة لحساب احتمال مشاكل التصنيف الثنائي في طبقة المخرجات. تولد هذه الدالة قيم خرج احتمالية بين صفر وواحد لكل فئة، ويمكن تحديدها بواسطة المعادلة 2-2:

$$\sigma(x) = \text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad \text{معادله 2-2}$$

يوضح الشكل 2-6 مخططاً لهذه الدالة.



الشكل 2-6 دالة سيجمويد

المزايا:

- إنه غير خطي ، لذا يمكن استخدامه في الطبقات المخفية.
- إنه قابل للاشتقاق في كل مكان.
- نطاق الإخراج الخاص به هو صفر وواحد ، لذلك يمكن استخدامه لمشاكل التصنيف.

العيوب:

- الانحدار للمدخلات البعيدة من المبدأ يقترب من الصفر ، لذا فإن التعلم القائم على الانحدار يكون بطيئاً جداً بالنسبة للخلايا العصبية المشبعة (الخلايا العصبية التي وصلت إلى الحد الأقصى أو الحد الأدنى لقيمتها) باستخدام سيجمويد.

- عند استخدامها كدالة تنشيط الطبقة الأخيرة لمشاكل التصنيف ، فإن مجموع كل الفئات ليس بالضرورة هو نفسه.
- ليست مركزية الصفر (دالة مركزية الصفر هي دالة يكون ناتجها أحياناً أكبر من الصفر وأقل من الصفر). تكون قيمة هذه الدالة دائماً بين صفر وواحد. لذلك لا يمكن أن يكون المتوسط صفراً وسيظل دائماً قيمة أكبر من الصفر.
- يجب أن يتم حسابه بشكل أسي ، وبالتالي فإن معدل التقارب بطيء.
- هناك مشكلة مع تلاشي الانحدار. بالنسبة لقيم x الصغيرة جداً أو الكبيرة جداً ، لا يوجد تغيير تقريباً في التوقعات.

دالة تانتش الزائدية (Tanh): ميزة هذه الدالة هي أنها يمكن أن تتعامل مع الأرقام السالبة بسهولة أكبر. ناتج هذه الدالة هو قيمة بين 1 و -1 ، ويمكن عرضه في صورة المعادلة 2-3:

$$\sigma(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{المعادلة 2 - 3}$$

المزايا:

- تسوية ناتج الخلايا العصبية إلى نطاق من -1 إلى 1.
- على عكس سيكمويد ، فهي دالة ذات محور صفري¹ لتسهيل تحسين دالة الخسارة.

العيوب:

- هناك مشكلة مع تلاشي الانحدار.
- يكلف الكثير من حيث الحوسبة.
- لديه مشكلة تشبع.

دالة الوحدة الخطية المصححة (ReLU²): تعد دالة الوحدة الخطية المصححة، المستخدمة في الطبقة المخفية، واحدة من أكثر الدوال المستخدمة على نطاق واسع في التعلم العميق اليوم. يمكن تمثيل هذه الدالة في المعادلة 2-4:

¹ zero-centered function

² Rectified Linear Unit

$$ReLU(x) = \max(0, x)$$

المعادلة 2-4

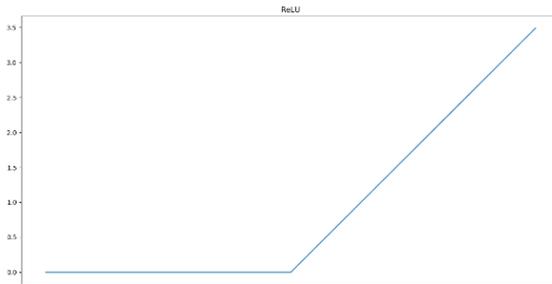
يضبط قيم الإدخال السالبة إلى الصفر لتحويل الإدخال إلى قيمة أكبر من أو تساوي الصفر. بمعنى آخر، لها قيمة صفرية للمدخلات السلبية وقيمة عالية للمدخلات الإيجابية. يمكن رؤية نظرة عامة على هذه الدالة في الشكل 2-7.

المزايا:

- إنه فعال للغاية من الناحية الحسابية ويسمح للشبكة بالتقارب بسرعة كبيرة. ليس لديها حسابات أسية مقارنة بسيكمويد وتانتش.
- يمنع مشكلة تلاشي الانحدار.

العيوب:

- لديه مشكلة موت¹ ReLU. عندما تقترب المدخلات من الصفر أو تكون صفرًا ، يصبح الانحدار دالة للصفر. لذلك ، لا يمكن استخدام خوارزمية الانتشار الخلفي للتعلم. مشكلة موت ReLU ليست دائمة. إذا تمت إضافة بيانات تدريب جديدة ، فقد يتم إعادة تنشيط هذه الخلايا العصبية.
- لا يمنع مشكلة انفجار الانحدار.



الشكل 2-7 دالة تنشيط ReLU

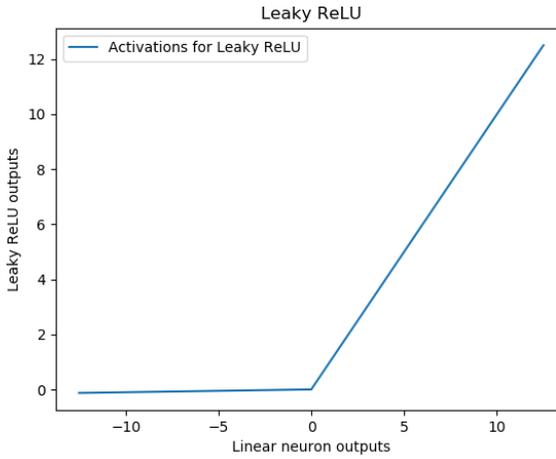
دالة (Leaky ReLU): هذه الدالة مشابهة جداً لدالة التنشيط ReLU. يتمثل الاختلاف في إدخال معامل α تسمح بتنشيط التدرجات الصغيرة إذا لم يتم تنشيطها. لذلك، فإن

¹ Dying ReLU

دالة التنشيط هذه تقضي على مشكلة موت الخلايا العصبية أثناء عملية التدريب. يمكن تمثيل هذه الدالة في المعادلة 2-5:

$$\text{LeakyReLU}(x) = \begin{cases} x & \text{اگر : صفر } \geq x \\ \alpha x & \text{اگر : صفر } < x \end{cases} \quad \text{المعادلة 2-5}$$

يمكن رؤية نظرة عامة على هذه الدالة في الشكل 2-8.



الشكل 2-8 دالة التنشيط Leaky ReLU

المزايا:

- يعمل على إصلاح مشكلة موت ReLU. لأنه يسمح بتدرج صغير عند حساب المشتق.
- إنه أسرع من الناحية الحسابية.

العيوب:

- لا يمنع مشكلة انفجار الانحدار.
- لا يمكن للشبكة العصبية معرفة قيمة المعامل α .

دالة سوفت ماكس (Softmax): هذه الدالة ، التي يتم استخدامها في طبقة الإخراج ، هي امتداد لوظيفة سيكمويد ، وتستخدم لمشاكل التصنيف. هذه الدالة تجعل من الممكن

عمل توقع احتمالي لمشكلة تصنيف لأكثر من فئتين ، ويتم تعريفها على أنها المعادلة 2-6:

$$S(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}} \quad \text{المعادلة 2 - 6}$$

- في مشاكل التصنيف الثنائي، يتم استخدام دالة سيكمويد في طبقة الإخراج.
- في مشاكل التصنيف متعدد العلامات، يتم استخدام دالة سيكمويد في طبقة الإخراج.
- في مشاكل التصنيف متعدد الفئات، يتم استخدام دالة Softmax في طبقة الإخراج.
- يمكن استخدام ReLU على جميع الطبقات المخفية.

مقارنة بين دوال التنشيط

يقارن الجدول 2-1 دوال التنشيط بناءً على معايير سعة الخرج، والمحور الصفري أم لا، ومشكلة التشبع، والحساب، ومشكلة تلاشي الانحدار.

الجدول 2-1 مقارنة بين دوال التنشيط

الدالة	المجال	المحور الصفري	التشبع	نلاشي الانحدار	الحساب
sigmoid	[0,1]	كلا	للقيم الموجبة والسالبة	بله	بطيء وأسي
Tanh	[-1,1]	نعم	للقيم الموجبة والسالبة	بله	بطيء وأسي
ReLU	[0,+∞]	كلا	للقيم السالبة	أفضل من tanh و Sigmoid	سريع
LeakyReLU	[-∞,+∞]	نعم	لا يمتلك	كلا	سريع

دالة الخسارة

تحدد دالة الخسارة، والمعروفة أيضاً باسم دالة التكلفة، مدى قرب الشبكة العصبية المدربة من معيارنا المثالي وهي جانب مهم من التدريب بعد بيانات التدريب الجيدة والهندسة المعمارية المناسبة، وهي موجودة في الشبكات العصبية. يلعب اختيار دالة الخسارة المناسبة دوراً مهماً في سرعة تقارب الشبكة.

في الخوارزميات الخاضعة للإشراف، نعتزم تقليل الخطأ لكل عينة تدريبية أثناء عملية التعلم. يتم ذلك عن طريق خوارزميات التحسين. تقيس دالة الخسارة هذا المقدار من خطأ النموذج لقياس قدرة النموذج. تشير هذه القيمة المقاسة إلى مدى قرب الشبكة العصبية من المعيار المثالي. بالنظر إلى هذه القيمة، يمكن للشبكة تقليل مقدار الخطأ هذا عن طريق التحديث المتكرر لأوزانها.

بشكل عام، يتمثل المفهوم الرئيسي لدالة الخسارة في قياس مقدار الخطأ بين القيم المستهدفة المقدرة والقيمة الفعلية للمشكلة. بافتراض أن y هي القيمة الفعلية للمشكلة و \tilde{y} هو الناتج، من أجل الحصول على أفضل نموذج، يجب تصغير ناتج دالة التكلفة، وهو $L(y, \tilde{y}) = y - \tilde{y}$. يعتمد اختيار دالة الخسارة على نوع المشكلة وبالنسبة للمشكلات المختلفة، سيكون تصنيف وانحدار دالة الخسارة هذه مختلفين. في مشكلة التصنيف، نعتزم توقع توزيع احتمالي لمجموعة الفئات. الآن، في مشاكل الانحدار، سنجد قيمة معينة.

دوال الخسارة المتعلقة بالتصنيف

في هذا القسم، سوف نغطي دوال الخسارة المتعلقة بالتصنيف.

خسارة الانتروبيا المتقاطعة¹

الانتروبيا المتقاطعة هي طريقة رياضية تستخدم في مشاكل منفصلة مثل التصنيف. تحسب هذه الدالة المسافة بين احتمالين ويتم تعريفها على النحو التالي:

¹ Cross-entropy Loss

$$\text{Cross Entropy}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i)$$

يتم استخدام الانتروبيا المتقاطعة في التصنيفات الثنائية ، والتي يتم تعريفها على النحو التالي:

$$\text{Binary Cross Entropy}(y, \hat{y}) = -\frac{1}{n} \sum_{i=1}^n (y_i \log(\hat{y}_i) + (1 - y_i)(1 - \log(\hat{y}_i)))$$

تباعد كولباك - ليبلير¹

تشبه هذه الدالة الانتروبيا المتقاطعة المستخدمة في مشاكل التصنيف وهي مقياس للفرق بين توزيع الاحتمالات وتوزيع الاحتمال الأساسي. يتم تعريف معادلتها على النحو التالي:

$$KL(y, \hat{y}) = \sum_{i=1}^n y_i \log\left(\frac{y_i}{\hat{y}_i}\right)$$

دوال الخسارة المتعلقة بالانحدار

في هذا القسم ، سنغطي دوال الخسارة المتعلقة بالانحدار.

الخطأ التربيعي المتوسط² (MSE)

هي إحدى دالات الخسارة الأكثر شهرة في الانحدار ، وتحسب متوسط الخطأ التربيعي المتوسط بين القيم الفعلية والمتوقعة بالمعادلة التالية:

$$MSE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

¹ Kullback-Leibler divergence

² Mean squared error loss

متوسط الخطأ المطلق (MAE)

تستخدم هذه الدالة لمشاكل الانحدار. تحسب هذه الدالة متوسط فرق القيمة المطلقة بين القيم الفعلية والمتوقعة بالمعادلة التالية:

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

طرق تهيئة القيم الأولية للأوزان

تتمثل الخطوة الأولى في بناء شبكة عصبية للحصول على أفضل النتائج في تهيئة المعاملات. إذا تم ذلك بشكل صحيح، فسيتم تحقيق التحسين في أقصر وقت. وإلا فسيكون التقارب مستحيلًا باستخدام الانحدار الاشتقاقي. أحد هذه المعاملات للتهيئة هو إعطاء القيم الأولية للأوزان. يجب أن تحتوي الأوزان المستخدمة أثناء التدريب الشبكي على القيم الأولية لبدء التدريب. هذا التهيئة للأوزان لها تأثير كبير على سرعة التقارب ودقة الشبكة. تؤدي القيم العشوائية إلى التقارب أو إبطاء عملية التعلم. لذلك، سيكون اختيار طريقة مناسبة للتدريب في الشبكات العميقة عملية مهمة. هناك طرق مختلفة للقيام بذلك، والتي سوف ندرسها فيما يلي.

تهيئة جميع الأوزان إلى الصفر

إنها طريقة بسيطة وتعمل أولاً بإعطاء قيم صفرية لجميع الأوزان ثم تحديث الأوزان أثناء عملية التدريب. تبدو هذه الفكرة مفيدة، لكن هناك مشكلة في هذه الطريقة. إذا تم ضبط جميع الأوزان على صفر، فسيكون مشتقها جميعاً هو نفسه بالنسبة لدالة الخسارة. لذلك، فإن جميع الأوزان لها نفس القيمة بعد عمليات التكرار المتتالية.

التهيئة العشوائية

في هذه الطريقة، يبدأ تهيئة القيم الأولية للأوزان بقيم عشوائية بحيث يكون لكل وزن قيمة مختلفة. سترتبط هذه الطريقة أيضاً بمشكلتين من تلاشي وانفجار الانحدار. إذا كانت الأوزان صغيرة، فسيصبح التدرج أصغر وأصغر بمرور الوقت ويختفي في النهاية.

¹ Mean absolute error loss

سيؤدي ذلك إلى التقارب أو، في أسوأ الأحوال، إلى فقدان عملية التعلم. على عكس مشكلة تلاشي التدرجات في هذه الطريقة، سيكون من الممكن أن تنفجر التدرجات. إذا كانت قيم الأوزان كبيرة جداً، سيزداد تدرجها وسيؤدي إلى تحسين كبير في أوزان الشبكة.

التعلم الانتقالي

هناك طريقة أخرى وهي استخدام كمية الأوزان المدربة من النماذج الأخرى إلى النموذج المستهدف. في هذه الطريقة، في بداية عملية التدريب، لا يتم التهيئة الأولية للأوزان، ولكن يتم تدريب أوزان النموذج الآخر.

تهيئة القيم الأولية الموحدة لـ Glorot

تهيئة القيم الأولية الموحدة لـ Glorot، والمعروفة أيضاً باسم تهيئة القيم الأولية خافير²، يتم تباعد أوزان الطبقة L بشكل موحد بناءً على التوزيع بمتوسط صفر وانحراف معياري محدد في الشبكة:

$$\left[-\sqrt{\frac{6}{(n_{l-1} + n_l)}}, \sqrt{\frac{6}{(n_{l-1} + n_l)}} \right]$$

في هذه المعادلة n_l و n_{l-1} هي عدد الخلايا العصبية في الطبقات L و L-1.

تهيئة القيم الأولية هي³

في هذه الطريقة، يتم تهيئة الأوزان من خلال النظر في حجم الخلايا العصبية للطبقة السابقة من أجل تحقيق المستوى الأمثل العالمي بشكل أسرع وتقليل دالة الخسارة. في هذه الطريقة، يتم تهيئة الأوزان في الطبقة L ذات القيم العشوائية على أساس متوسط الصفر والانحراف المعياري $\sqrt{\frac{2}{n_{l-1}}}$ حيث n_{l-1} هو عدد الخلايا العصبية في الطبقة L-1.

¹ Glorot Uniform Initialization

² Xavier Initialization

³ He Normal Initialization

التحسين وتحديث الأوزان

التحسين عبارة عن خوارزميات تحاول تقليل دالة الخسارة عن طريق تحسين الأوزان في الشبكة ، أي أن هدفنا الرئيسي هو تدريب الشبكات على المشكلة التي نحاول حلها. ضبط أوزان الشبكة بحيث تكون الشبكة قادرة على التعلم . يلعب اختيار خوارزمية التحسين الصحيحة دورًا مهمًا في سرعة تقارب الشبكة. هناك عدة طرق للتحسين.

الانحدار الاشتقاقي هي واحدة من أكثر هذه الخوارزميات شيوعًا وشيوعًا في الشبكات العصبية. مثال آخر على هذه الخوارزميات هو طريقة نيوتن. تشارك هذه الطريقة في تحسين التحسين باستخدام مشتق من الدرجة الثانية من خلال إيجاد جذور الدالة. تزيد طريقة نيوتن بشكل كبير من التعقيد الحسابي مقارنة بأساليب المشتقات من الدرجة الأولى. لهذا السبب ، فإن استخدام أساليب التدرج الاشتقاقي أكثر شيوعًا في عملية تدريب الشبكة العصبية. يحسب الوضع البسيط لهذه الطريقة تدرج الخطأ لجميع عينات التدريب على النحو التالي:

خوارزمية الانحدار الاشتقاقي

افتراض أن : دالة الخسارة: $L(w)$, معدل التعلم: η , متجه الوزن: w

1- تهيئة القيم الأولية للأوزان.

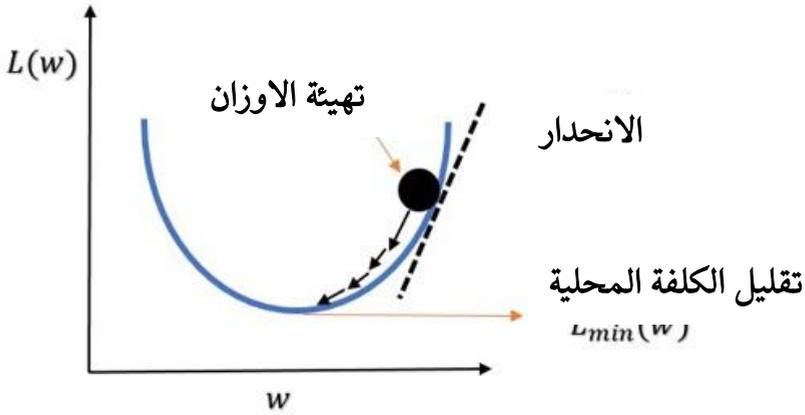
2- طبق هذا حتى تتقارب الحلقة:

احسب الانحدار الاشتقاقي ، $\frac{\partial L(w)}{\partial w}$

حدث الأوزان ، $w \leftarrow w - \eta \frac{\partial L(w)}{\partial w}$

3- أعد الأوزان.

وفقًا للشكل 2-9 ، يمكن اعتبار هذه الخوارزمية على أنها متسلق (عامل وزن) ، ينوي الانتقال من الجبل (دالة التكلفة) إلى الوادي (التكلفة الدنيا) وفي كل خطوة مع منحدر حاد (التدرج) من طول الخطوات (معدل التعلم) تنزل.



الشكل 2-9 خوارزمية الانحدار الاشتقاقي

تعد خوارزمية الانحدار الاشتقاقي طريقة تحسين قائمة على التكرار وتحاول تقليل دالة الخسارة عن طريق تغيير الأوزان الداخلية للشبكة وتحديثها تدريجياً. يتم تحديد حجم الخطوة في كل تكرار للخوارزمية من خلال معدل التعلم. يتم تنفيذ عملية التكرار حتى لا يكون هناك تغيير في دالة الخسارة (تسمى التقارب).

من الناحية العملية ، عندما يكون عدد عينات التدريب كبيراً ، فإن استخدام خوارزمية التدرج الاشتقاقي سيستغرق وقتاً طويلاً. لأنه يجب أن يتم ذلك في كل تكرار للخوارزمية لجميع الحالات. لذلك ، سيكون استخدام خوارزمية الانحدار الاشتقاقي العشوائي أكثر فائدة لأنه في كل تكرار للخوارزمية ، يقوم فقط بتحديث مجموعة من العينات. هناك ثلاث طرق عامة لاستخدام الانحدار الاشتقاقي: الانحدار الاشتقاقي لعينة واحدة ، الانحدار الاشتقاقي الكامل ، والانحدار الاشتقاقي الصغير. في ما يلي ، سوف ندرس أنواعاً مختلفة من خوارزميات تحسين الانحدار الاشتقاقي المستخدمة في الشبكات العميقة.

الانحدار الاشتقاقي العشوائي (SGD)¹ والصغير²

لنفترض أن هناك ملايين الحالات في مجموعة بيانات التدريب. في مثل هذه الحالة، باستخدام طريقة الانحدار الاشتقاقي، يجب حساب الانحدار الاشتقاقي لكل هذه الملايين من الحالات في كل تكرار، والذي سيتضمن الكثير من المعالجة والحساب. يتم حل هذه المشكلة عن طريق خوارزمية الانحدار الاشتقاقي العشوائي. الانحدار الاشتقاقي العشوائي هو طريقة للتقريب العشوائي للانحدار الاشتقاقي، على عكس الانحدار الاشتقاقي، لا تُستخدم جميع عينات التدريب لتحسين دالة الهدف، ولكن عن طريق إدخال كل عينة بشكل عشوائي. يتم تحديدها لتحسين الإجراءات في كل فترة ويتم الحصول على أوزان جديدة. معادلتها على النحو التالي:

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta, x^i, y^i)$$

في هذه المعادلة، θ هي معاملات النموذج، J هي دالة الخسارة، x^i هي مدخلات عينة التدريب، و y^i هي التسمية الخاصة بها. في هذه الطريقة، نظراً للاستجابة مع كل إدخال عينة، يمكن أن يؤدي إلى عدم استقرار نتائج الشبكة. هناك أيضاً مشكلة التعشرفي الحد الأدنى المحلي بهذه الطريقة.

في طريقة الانحدار الاشتقاقي الكامل، تقوم الشبكة بتحديث الأوزان عن طريق حساب الخطأ لجميع عينات التدريب. لذلك، ليس لديها مشكلة دنيا محلية. في المقابل، سوف يستغرق وقت تدريب أطول. في الفراغ بين الطريقتين، يتم استخدام تدرج الانحدار الاشتقاقي الصغير. في هذه الطريقة، يوجد مصطلح يسمى الدفعة³، والذي يشير إلى عدد العينات المستخدمة في كل فترة تكرار لحساب الانحدار الاشتقاقي. يقسم الانحدار الاشتقاقي الصغير مجموعة التدريب بأكملها إلى أقسام فرعية من الرقم n ، وبناءً على هذه التقسيمات الفرعية، فإنه يحسن المعاملات. معادلتها على النحو التالي:

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta, x^{i:i+n}, y^{i:i+n})$$

¹ Stochastic gradient descent

² Mini batch gradient descent

³ Batch

يتراوح الحجم المعتاد للدفعات الصغيرة من 50 إلى 256 ويجب اختياره بشكل معقول:

- توفر أحجام الدفعات الكبيرة تدرجات أكثر دقة ولكنها تتطلب مساحة أكبر.
- يتطلب حجم الدفعة الصغيرة معدل تعلم صغيراً للحفاظ على الاستقرار بسبب التباين الكبير في تقدير التدرج. اختيار معدل التعلم الصغير بدوره يقلل من عملية التعلم.

يعد استخدام الانحدار الاشتقاقي الصغير أكثر مقاومة للضوضاء وله تباين أقل بسبب استخدام مزيج من طريقتين الانحدار الاشتقاقي الكامل والانحدار الاشتقاقي العشوائي، مما يؤدي إلى تقارب أكثر استقراراً. لذلك، عادة ما تستخدم طريقة التحسين هذه في التعلم العميق. ومع ذلك، فإن هذه الأساليب لها عيب مهم: اختيار معدل التعلم. إن اختيار معدل التعلم الصحيح ليس بالأمر السهل دائماً. بصرف النظر عن هذا، فإن اختيار نفس معدل التعلم في جميع المراحل التعليمية لجميع المعاملات لن يكون هو الأمثل. لذلك، تم اقتراح خوارزميات مختلفة لحل هذه المشكلة من أجل تكييف معدل التعلم في مراحل مختلفة من الخوارزمية لإنشاء تقارب شبكة أسرع. يعد Adam مثلاً عملياً جداً للخوارزميات ذات معدل التعلم التكيفي.

أداغراد¹

أداغراد هي خوارزمية التحسين القائمة على الانحدار. في طريقة الانحدار الاشتقاقي العشوائي، قمنا بتحسين كل معامل w_i باستخدام معدل تعلم مشترك. غالباً ما يتسبب هذا الإجراء في حدوث مشكلات. أداغراد هي إحدى الخوارزميات التي تستخدم معدل التعلم التكيفي. في هذه الخوارزمية، يتم تعديل معدل التعلم لكل معامل من معاملات النموذج على النحو التالي عن طريق تغيير مقياسها كنسبة عكسية إلى الجذر التربيعي لمجموع كل قيمها التربيعية السابقة:

$$w_{t+1,i} = w_{t,i} - \frac{\eta}{\sqrt{G_t}} \odot \nabla_{t,i}$$

¹ Adagrad

في هذه المعادلة $\nabla_{t,i}$ من تدرج دالة التكلفة ، تحتوي G_t على مجموع مربعات التدرجات الاشتقاقية السابقة.

أهم ميزة لاستخدام آداغراد هي أن معدل التعلم يتم ضبطه تلقائيًا ولا يحتاج إلى تعديل يدويًا. ومع ذلك ، فإن مجموع القواسم المتاحة يؤدي تدريجيًا إلى انهيار معدل التعلم. يمكن أن يؤدي معدل التعلم المتناقص هذا إلى إبطاء التعلم أو حتى إيقافه تمامًا. تم اقتراح الخوارزميات التالية لإزالة هذا العيب.

آدادلتا¹

آدادلتا هو امتداد لخوارزمية آداغراد التي تحل مشكلة تقليل معدل التعلم. بدلاً من مجموع مربعات جميع التدرجات الاشتقاقية السابقة، تحدد الخوارزمية عدد التدرجات الاشتقاقية السابقة إلى x ثم تخزن متوسط هذه التدرجات السابقة للإنتاجية. متوسط قيمة ∇_t^2 في الوقت t يعتمد فقط على المتوسطات السابقة والتدرجات الحالية. يتم تحسين المعامل على النحو التالي:

$$w_{t+1} = w_t - \frac{\eta}{\sqrt{(\nabla_t^2) \text{ميانكين}}} \odot \nabla_t$$

نظرًا لأن المقام هو الجذر المتوسط التربيعي للتدرج² ، فيمكن إعادة كتابته على النحو التالي:

$$w_{t+1} = w_t - \frac{\eta}{(\nabla_t) \text{جذر متوسط مربع}} \odot \nabla_t$$

آراماس بروب³

آراماس بروب ، مثل آدادلتا ، يحل مشكلة تقليل معدل التعلم عن طريق تغيير خوارزمية آداغراد. تستخدم هذه النسخة المعدلة من خوارزمية آداغراد وسيط اختزال أسّي لحذف

¹ Adadelta

² root mean square

³ RMSprop

السجلات من الماضي البعيد. آرماس بروب هو في الواقع نفس المتجه الأول الذي تم الحصول عليه لخوارزمية آدالتا:

$$(\nabla_t^2) \text{ميانكين} = 0.9(\nabla_{t-1}^2) + 0.1\nabla_t^2$$

$$w_{t+1} = w_t - \frac{\eta}{\sqrt{(\nabla_t^2) \text{ميانكين}}} \odot \nabla_t$$

لقد ثبت بشكل تجريبي أن آرماس بروب هي خوارزمية فعالة ومؤثرة في الشبكات العصبية العميقة.

آدام¹ (ADAM)

تقدير الزخم التكييفي ، أو باختصار آدم ، طريقة أخرى لحساب معدل التعلم التكييفي لكل معامل. تستفيد هذه الخوارزمية من خوارزميات آداغراد و آرماس بروب وتخزن متوسط الانهيار الأسّي للتدرجات السابقة في v_t . بالإضافة إلى ذلك ، يخزن آدم متوسط الزخم الثاني للانحدار في m_t . m_t و v_t هما قيم المتوسط والتباين اللامركزي ، على التوالي:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$$

يتحكم آدم في وسائل الحركة الأسية للتدرج الاشتقاقي والتدرج المربع من خلال المعادلات التالية:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

وهي معاملات فائقة بقيم $\beta_2, \beta_1 \in [0, 1]$. معادلة التحسين النهائية على النحو التالي:

¹ Adaptive Moment Estimation

$$w_{t+1} = w_t - \frac{\eta}{\sqrt{\hat{v}_t}} \odot \hat{m}_t$$

تعمل خوارزمية آدم بشكل أفضل من الطرق التكييفية الأخرى وتتقارب بسرعة كبيرة. كما أنه يتغلب على المشكلات الأخرى التي تغلبت عليها خوارزميات التحسين مثل انهيار معدل التعلم، والتباين العالي في التحسين والتقارب البطيء.

خوارزمية الانتشار الخلفي للخطأ

كما هو مذكور في الفصل الأول، في السنوات الأولى لظهور الشبكات العصبية، ظل تدريب الشبكة متعدد الطبقات غير معروف. كان هذا بسبب إصرار مينسكي وبوبرت على عدم القدرة على تدريب الشبكات متعددة الطبقات. نتيجة لذلك، انقرضت مقالات الشبكة العصبية بحلول الثمانينيات. لحسن الحظ، أدى النجاح الأول الذي حققه روميلهارت وزملاؤه في هذا الصدد في شكل خوارزمية الانتشار الخلفي إلى تجدد اهتمام الباحثين بالشبكات العصبية. ومع ذلك، تم العثور على العديد من التحديات الحسابية، والتقارب، والضبط الزائد في هذه الشبكات، بحيث يمكن أن يتعرض البحث في الشبكات العصبية لانتكاسة.

أدت التطورات الأخيرة إلى تنشيط الشبكات العصبية لجعلها أكثر شهرة مرة أخرى. لم تقتصر هذه التحسينات على الخوارزميات؛ فقد لعبت زيادة الوصول إلى البيانات وقوة الحوسبة للأجهزة دوراً رئيسياً. ومع ذلك، في استمرار هذا القسم، سنراجع خوارزمية الانتشار الخلفي مع الانحدار الاشتقاقي.

يعتمد التعلم في الشبكات العصبية على عينات تدريبية تم إدخالها في الخوارزمية والتغييرات في الأوزان. الخوارزمية المستخدمة لمعرفة الأوزان تسمى **خوارزمية الانتشار الخلفي للخطأ**. تستخدم هذه الخوارزمية قاعدة حساب التفاضل والتكامل وتحسب تدرج الخطأ في مسارات مختلفة من عقدة واحدة إلى المخرجات. تندرج هذه الخوارزمية في فئة طرق التعلم الخاضعة للإشراف وتتكون من مرحلتين رئيسيتين تسمى المرحلة الأمامية والمرحلة العكسية. المرحلة الأمامية مطلوبة لحساب قيم المخرجات والمشتقات المحلية في العقد المختلفة، والمرحلة العكسية مطلوبة لتجميع ناتج هذه القيم المحلية في جميع المسارات من العقدة إلى المخرجات.

المرحلة الأمامية: في هذه المرحلة، يتم تغذية المدخلات إلى الشبكة العصبية كعينات تدريب. باستخدام مجموعة الأوزان الحالية، يمكن مقارنة المخرجات النهائية المتوقعة مع عينة التدريب.

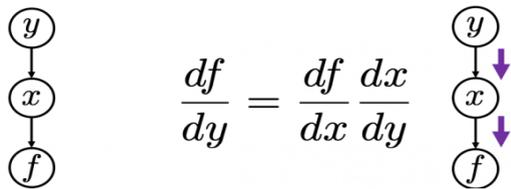
المرحلة الخلفية: الغرض الرئيسي من المرحلة الخلفية هو تحسين الأوزان. نظراً لأن هذه الخطوة تبدأ في عقدة الإخراج، فإن هذه الخطوة تسمى الخطوة الخلفية.

باختصار، تعمل هذه الخوارزمية بطريقة أنه في المرحلة الأولى، والتي تسمى المرحلة الأمامية، يتم تهيئة الأوزان الأولية بأرقام عشوائية صغيرة، ثم يتم تنفيذ مجموع الأوزان لكل طبقة بواسطة دالة التنشيط. ونقلها إلى طبقة أخرى لعمل توقع أخيراً في طبقة الإخراج. تتم مقارنة معدل الخطأ لهذا الناتج المتوقع بالمخرجات المستهدفة، ومن المرجح أن يكون الخطأ في الجولة الأولى مرتفعاً.

المرحلة الثانية، تسمى المرحلة الخلفية، تعتمد على مقدار الخطأ الذي تم الحصول عليه من المرحلة الأمامية، ويتم تحديث الأوزان لتقليل معدل الخطأ المتوقع بالقيمة المستهدفة. قم بإجراء هذه العملية في عدة جولات لتقليل معدل الخطأ هذا لجميع عينات التدريب مع القيم المتوقعة. في ما يلي، سنصف أولاً قانون السلسلة ثم نستخدم مثالاً خطوة بخطوة لوصف هذه الخوارزمية.

قانون السلسلة

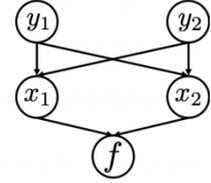
يمكن أن يؤدي استخدام النماذج الرسومية إلى فهم أفضل لقانون السلسلة. في الأساس، تُستخدم النماذج الرسومية لوصف علاقات المتغيرات والدوال في النماذج الاحتمالية. لنفترض أن لدينا دالة $f = f(x) = f(x(y))$ وأن علاقات الدوال كنموذج رسومي هي كما يلي:

$$f = f(x) = f(x(y)) \quad \frac{df}{dy} = \frac{df}{dx} \frac{dx}{dy}$$


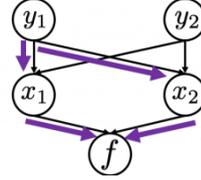
المتغيرات هي نوع من الدوال ، لذلك عليك أن تتخيل أن كل عقدة في النماذج الرسومية تمثل دالة. توضح الأسهم الموجودة على يمين الصورة أعلاه كيفية نشر المعلومات في المشتق.

الآن إذا كانت لدينا دالة f لها تباينان x_1 و x_2 وكلاهما لهما تباينان هما y_1 و y_2 . عندما نأخذ مشتقاً جزئياً لـ f من y_1 و y_2 ، تصبح المعادلة أكثر صعوبة قليلاً. لنفترض الآن أننا نريد حساب $\frac{\partial f}{\partial y_1}$. يتم تمرير التباين y_1 إلى f عبر x_1 و x_2 في هذه الحالة ، سيكون للمشتق الجزئي تعبيرين على النحو التالي.

$$f = f(x_1, x_2) = f(x_1(y_1, y_2), x_2(y_1, y_2))$$

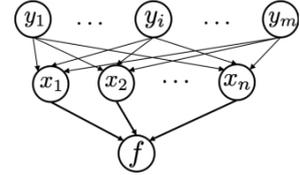


$$\frac{\partial f}{\partial y_1} = \frac{\partial f}{\partial x_1} \frac{\partial x_1}{\partial y_1} + \frac{\partial f}{\partial x_2} \frac{\partial x_2}{\partial y_1}$$

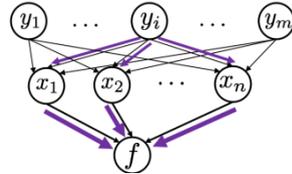


في قانون السلسلة ، يجب حساب جميع المسارات التي ينتشر التباين من خلالها. إذا قمنا بتعميم قانون السلسلة على أنه النموذج الرسومي التالي ، فسيتم حساب المشتق الجزئي f فيما يتعلق بـ y_i على النحو التالي. يساعد هذا الفهم لقانون السلسلة في فهم أي نوع من أنواع الانتشار الخلفي.

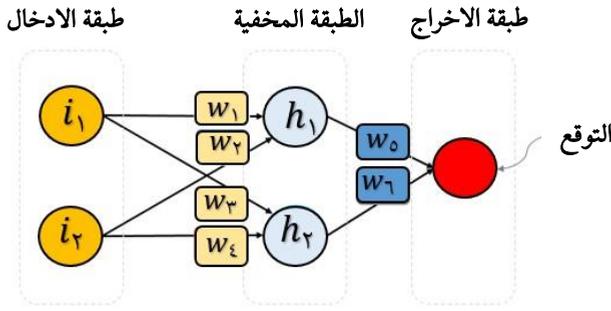
$$\begin{aligned} f(x) &= f(x_1(y_1, \dots, y_m), \dots, x_n(y_1, \dots, y_m)) \\ &= f(x_1(\dots, y_i, \dots), \dots, x_n(\dots, y_i, \dots)) \\ &= f(x_1(y_i), x_2(y_i), \dots, x_n(y_i)) \end{aligned}$$



$$\begin{aligned} \frac{\partial f}{\partial y_i} &= \frac{\partial f}{\partial x_1} \frac{\partial x_1}{\partial y_i} + \frac{\partial f}{\partial x_2} \frac{\partial x_2}{\partial y_i} + \dots + \frac{\partial f}{\partial x_n} \frac{\partial x_n}{\partial y_i} \\ &= \sum_{j=1}^n \frac{\partial f}{\partial x_j} \frac{\partial x_j}{\partial y_i} \end{aligned}$$



الآن ، لنفترض أن لدينا شبكة عصبية بها 3 طبقات ، والتي يمكن عرضها في الشكل 2-10 ، وقيمتي الإدخال 2 و 3 وإخراجها الفعلي هو 1.



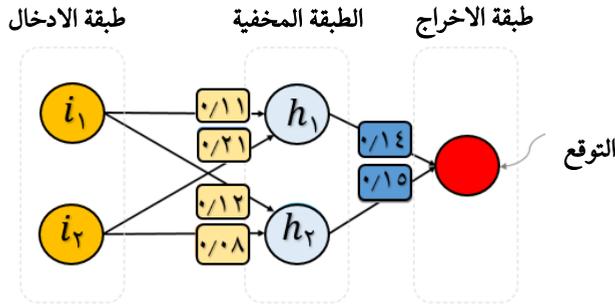
الشكل 2-10 بنية الشبكة العصبية مع طبقة الإخراج

في المرحلة الأولى ، يتم تهيئة القيم الأولية بقيم عشوائية للأوزان على النحو التالي:

$$w_1 = 0.11 , w_2 = 0.21 , w_3 = 0.12 , w_4 = 0.08$$

$$w_5 = 0.14 , w_6 = 0.15$$

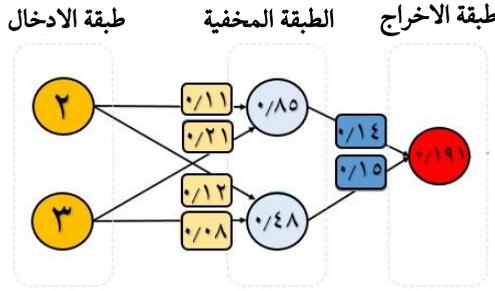
تم تحديدها كميًا. تظهر هذه القيمة في بنية الشبكة في الشكل 2-11.



الشكل 2-11 تهيئة أوزان الشبكة

بعد تهيئة وتغذية مدخلات الشبكة ، يتم ضرب المدخلات بالأوزان ونقلها إلى طبقة أخرى. ثم يتم حساب مجموع الأوزان ويتم إنشاء قيمة متوقعة في المخرجات. يمكن رؤية هذه الخطوة في الشكل 2-12 وطريقة الحساب في هذه الخطوة على النحو التالي:

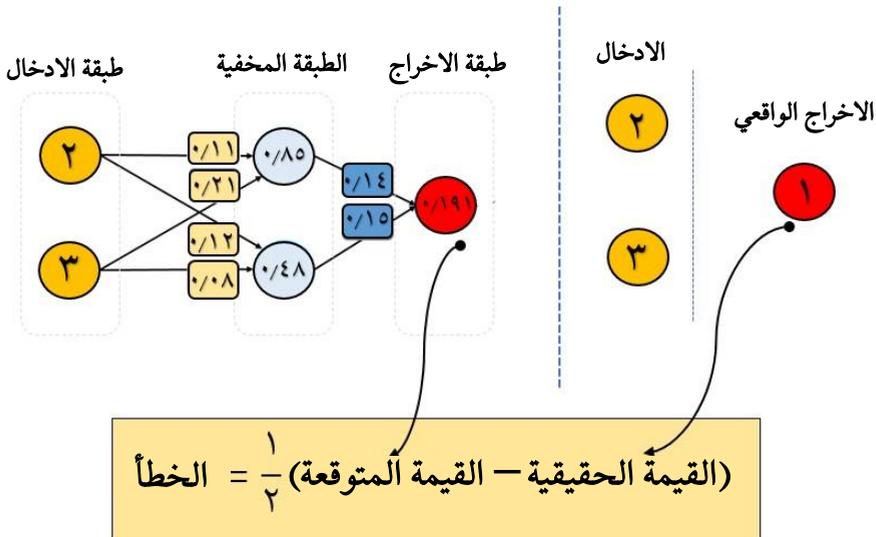
$$[2 \ 3] \cdot \begin{bmatrix} 0.11 & 0.12 \\ 0.21 & 0.08 \end{bmatrix} = [0.85 \ 0.48] \cdot \begin{bmatrix} 0.14 \\ 0.15 \end{bmatrix} = [0.191]$$



الشكل 2-12 المرحلة الامامية

حان الوقت الآن للنظر في كيفية قيام الشبكة بحساب الفرق بين المخرجات المتوقعة والمخرجات الفعلية في تقييم أداء الشبكة. كما ذكر في هذه المرحلة ، من المرجح أن تكون هذه القيمة مختلفة جداً عن القيمة الفعلية. يمكن رؤية اختلاف الخطأ هذا في الشكل 2-13. تم حساب هذا الخطأ في هذه الخطوة بعد الحصول على الحساب أدناه:

$$\text{خطأ} = \frac{1}{2} (0.191 - 1)^2 = 0.327$$



الشكل 2-13 حساب الخطأ

هدفنا الرئيسي في تدريب الشبكات هو تقليل مقدار الخطأ بين قيم المخرجات الفعلية والمتوقعة. نظرًا لأن قيمة المخرجات الفعلية للمشكلة هي قيمة ثابتة ، فإن تقليل الخطأ

هو فقط تغيير القيمة المتوقعة ، لكن السؤال هو كيف يتم تغيير هذه القيمة؟ كما يتضح ، تحدد الأوزان القيمة المتوقعة ، لذلك يجب تغييرها لتقليل معدل الخطأ. يتم إجراء هذا المزامنة وتغيير الأوزان في المرحلة الخلفية في خوارزمية الانتشار الخلفي للخطأ بواسطة الانحدار الاشتقاقي. كيفية حسابه في تحسين الوزن على افتراض أن \dot{w}_x هو الوزن الجديد ، و w_x هو الوزن القديم و η هو معدل التعلم ، يمكن حسابه على النحو التالي:

$$\dot{w}_x = w_x - \eta \left(\frac{\partial \text{خطأ}}{\partial w_x} \right)$$

على سبيل المثال ، كيفية ضبط الوزن لـ w_6 كما يلي:

$$\dot{w}_6 = w_6 - \eta \left(\frac{\partial \text{خطأ}}{\partial w_6} \right)$$

$$\frac{\partial \text{خطأ}}{\partial w_6} = \frac{\partial \text{خطأ}}{\partial \text{پیش بینی}} * \frac{\partial \text{پیش بینی}}{\partial w_6}$$

$$\frac{\partial \text{خطأ}}{\partial w_6} = \frac{1}{2} \left(\text{واقعی} - \text{پیش بینی} \right)^2 * \frac{\partial (i_1 w_1 + i_2 w_2) w_5 + (i_1 w_3 + i_2 w_4) w_6}{\partial w_6}$$

$$\frac{\partial \text{خطأ}}{\partial w_6} = 2 * \frac{1}{2} \left(\text{واقعی} - \text{پیش بینی} \right) \frac{\partial (\text{واقعی} - \text{پیش بینی})}{\partial \text{پیش بینی}} * (i_1 w_3 + i_2 w_4)$$

$$\frac{\partial \text{خطأ}}{\partial w_6} = (\text{واقعی} - \text{پیش بینی}) * (h_2)$$

$$\frac{\partial \text{خطأ}}{\partial w_6} = \Delta h_2$$

وفقاً لذلك ، يتم تحديث w_6 على النحو التالي:

$$\dot{w}_6 = w_6 - \eta \Delta h_2$$

بعد التحديث لجميع الأوزان ، يتم تلخيصها على النحو التالي:

$$\dot{w}_6 = w_6 - \eta(\Delta \cdot h_2)$$

$$\dot{w}_5 = w_5 - \eta(\Delta \cdot h_1)$$

$$\dot{w}_4 = w_4 - \eta(\Delta w_6 \cdot i_2)$$

$$\dot{w}_3 = w_3 - \eta(\Delta w_6 \cdot i_1)$$

$$\dot{w}_2 = w_2 - \eta(\Delta w_5 \cdot i_2)$$

$$\dot{w}_1 = w_1 - \eta(\Delta w_5 \cdot i_1)$$

بعد إعادة كتابتها ووضعها في المصفوفة ، يمكن رؤيتها على النحو التالي:

$$\begin{bmatrix} w_5 \\ w_6 \end{bmatrix} = \begin{bmatrix} w_5 \\ w_6 \end{bmatrix} - \eta \Delta \begin{bmatrix} h_1 \\ h_2 \end{bmatrix} = \begin{bmatrix} w_5 \\ w_6 \end{bmatrix} - \begin{bmatrix} \eta(\Delta \cdot h_1) \\ \eta(\Delta \cdot h_2) \end{bmatrix}$$

$$\begin{bmatrix} w_1 & w_3 \\ w_2 & w_4 \end{bmatrix} = \begin{bmatrix} w_1 & w_3 \\ w_2 & w_4 \end{bmatrix} - \eta \Delta \begin{bmatrix} i_1 \\ i_2 \end{bmatrix} \cdot \begin{bmatrix} w_5 & w_6 \end{bmatrix}$$

$$\begin{bmatrix} w_1 & w_3 \\ w_2 & w_4 \end{bmatrix} = \begin{bmatrix} w_1 & w_3 \\ w_2 & w_4 \end{bmatrix} - \begin{bmatrix} \eta i_1 \Delta w_5 & \eta i_1 \Delta w_6 \\ \eta i_2 \Delta w_5 & \eta i_2 \Delta w_6 \end{bmatrix}$$

الآن يمكننا استخدام هذه المعادلات لتحسين الأوزان الجديدة لمثالنا ، بافتراض أن قيمة معدل التعلم هي 0.05 . يتم حساب قيم الأوزان الجديدة على النحو التالي:

$$\Delta = 0.191 - 1 = -0.809$$

$$\begin{bmatrix} w_5 \\ w_6 \end{bmatrix} = \begin{bmatrix} 0.14 \\ 0.15 \end{bmatrix} - 0.05(-0.809) \begin{bmatrix} 0.85 \\ 0.48 \end{bmatrix} = \begin{bmatrix} 0.17 \\ 0.17 \end{bmatrix}$$

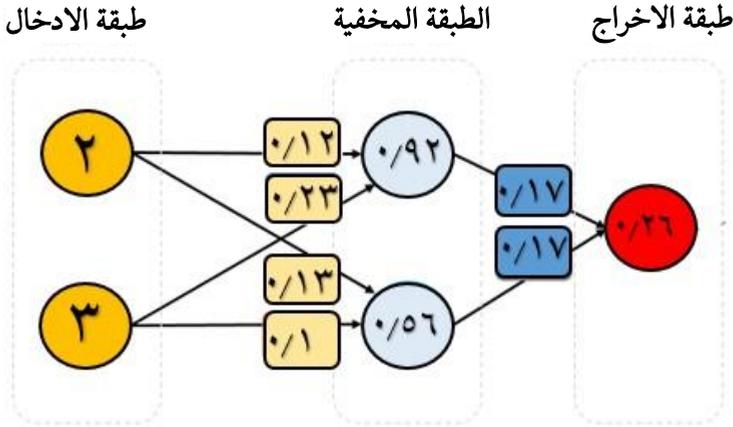
$$\begin{bmatrix} w_1 & w_3 \\ w_2 & w_4 \end{bmatrix} = \begin{bmatrix} 0.11 & 0.12 \\ 0.21 & 0.08 \end{bmatrix} - 0.05(-0.809) \begin{bmatrix} 2 \\ 3 \end{bmatrix} \cdot \begin{bmatrix} 0.14 & 0.15 \end{bmatrix}$$

$$\begin{bmatrix} w_1 & w_3 \\ w_2 & w_4 \end{bmatrix} = \begin{bmatrix} 0.11 & 0.12 \\ 0.21 & 0.08 \end{bmatrix} - \begin{bmatrix} -0.011 & -0.012 \\ 0.017 & -0.018 \end{bmatrix} = \begin{bmatrix} 0.12 & 0.13 \\ 0.23 & 0.10 \end{bmatrix}$$

الآن ، بعد تعديل الأوزان ، نكرر المرحلة الأمامية مرة أخرى ، ويمكن رؤية هذه الخطوة في الشكل 2-14 .

كيفية حساب قيم الإخراج الجديدة على النحو التالي.

$$\begin{bmatrix} 2 & 3 \end{bmatrix} \cdot \begin{bmatrix} 0.12 & 0.13 \\ 0.23 & 0.10 \end{bmatrix} = \begin{bmatrix} 0.92 & 0.56 \end{bmatrix} \cdot \begin{bmatrix} 0.17 \\ 0.17 \end{bmatrix} = \begin{bmatrix} 0.26 \end{bmatrix}$$



الشكل 2-14 تكرار المرحلة الأمامية مرة أخرى

كما يتضح ، تغيرت قيمة المخرجات في التكرار الثاني للخوارزمية من 0.191 إلى 0.26 ، وهو أقرب إلى الناتج الفعلي. بتكرار الخوارزمية عدة مرات ، يمكن أن يكون معدل الخطأ قريباً من الصفر أو مساوياً له.

تحديات التدريب في الشبكات العميقة

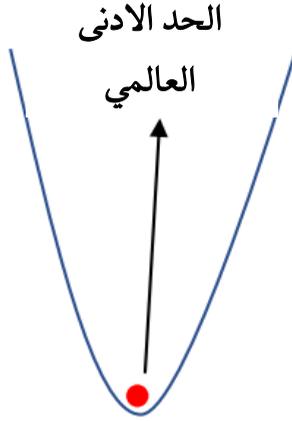
يعد التدريب في الشبكات العميقة عملية صعبة للغاية ، لذلك سيكون لها مشاكل وعقبات معقدة. في هذا القسم ، سنتناول التحديات الرئيسية التي نواجهها في تدريب الشبكات العميقة.

تلاشي وانفجار الانحدار

تتضمن عملية التدريب في الشبكات العميقة إيجاد مجموعة من الأوزان في الشبكة، وهذه الأوزان تمثل التعلم في الشبكة للمشكلة.

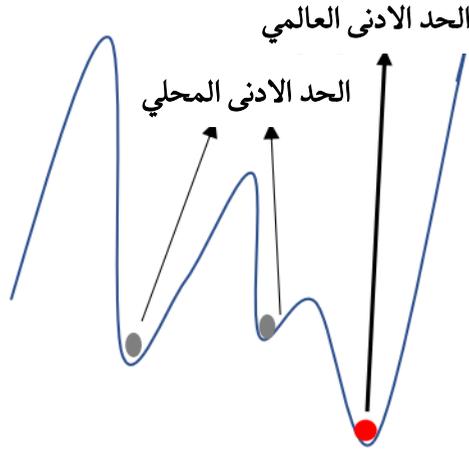
بعد التدريب في الشبكات العصبية عملية متكررة، أي خطوة بخطوة مع تحديثات صغيرة في الأوزان، وبتكرار هذه العملية، يتحسن أداء النموذج في حل المشكلات. تخلق هذه العملية مشكلة تحسين، حيث تحاول الشبكة تقليل دالة الخسارة استناداً إلى الأوزان. مشكلة التحسين هذه تخلق تحديات للشبكة. السؤال هو، ما الذي يمثل تحدياً بشأن التحسين؟

كما رأينا، فإن الخوارزمية الأكثر شيوعاً للتحسين في الشبكات العميقة هي التدرج الاشتقاقي. يتم استخدام هذا المحسن في خوارزمية الانتشار الخلفي لتحسين الأوزان في كل تكرار لتقليل قيمة الخطأ لدالة الخسارة. يبحث المُحسِّن عن الأوزان في الوقت المناسب ويسعى إلى الحد الأدنى العالمي. في مشاكل التحسين البسيطة، يمكن تشبيهها بوعاء كبير كما في الشكل 2-15، حيث يمكن العثور على قاع الوعاء بسهولة باستخدام خوارزمية العمل. تُعرف هذه المشكلات في الرياضيات باسم التحسين المحدب.



الشكل 2-15 التحسين المحدب

ومع ذلك، في أوزان الشبكة العصبية، لن تكون المشكلة كوعاء بل منظر تلال ووديان، كما في الشكل 2-16. تُعرف هذه الأنواع من المشكلات في الرياضيات باسم التحسين غير المحدب.



الشكل 2-16 التحسين غير المحدب

في الواقع، يمكن القول إن إيجاد مجموعة الأوزان المثلى في الشبكات العصبية لا وجود له في زمن كثير الحدود. تُعرف هذه الأنواع من المشكلات NP-completeness في علوم الكمبيوتر.

ننتقل الآن إلى المشكلات التي نواجهها عند التدريب في الشبكات العصبية العميقة باستخدام الانحدار الاشتقاقي وخوارزمية الانتشار الخلفي. تسمح إضافة المزيد من الطبقات المخفية إلى الشبكات العصبية للشبكة بمعرفة دوال أكثر تعقيداً، وهذا هو الفرق الكبير بين الشبكات العصبية والشبكات العميقة. ولكن عند استخدام خوارزمية الانتشار الخلفي، يتم حساب التدرج بشكل أصغر وأصغر في المرحلة العكسية. هذا بسبب وجود تدرجات متناقصة في كل تكرار للمشتقات الجزئية بالمرور من الطبقة النهائية إلى الطبقة الأولية باستخدام قانون السلسلة. في شبكة بها n طبقات مخفية، يتم ضرب مشتقات هذه الطبقة n ببعضها البعض. الآن إذا كانت هذه المشتقات صغيرة، فإن الانتقال إلى الطبقات الأولية سينخفض بشكل كبير (أوفي أسوأ الحالات ستكون صفراً وسيتوقف تعلم الشبكة) سيؤدي هذا إلى تلاشي الانحدار الاشتقاقي. نظراً لأن هذه التدرجات الصغيرة لا يتم تحديثها في خوارزمية التحديث، وغالباً ما تكون هذه الطبقات الأولية فعالة في التعرف على البيانات، فإنها تؤدي إلى دقة الشبكة غير الكافية. على العكس من ذلك، إذا كانت قيم المشتقات هذه كبيرة، فسوف تتدفق من خلال النمو الأسي من خلال النقل إلى الطبقات، ولن تكون الأوزان قادرة على التحسين، مما يؤدي إلى إنشاء شبكة غير مستقرة.

طرق لتحديد مشاكل تلاشي وانفجار الانحدار؟

نحن الآن نواجه مشكلة كيفية تشخيص أن شبكتنا لديها مشاكل مع تلاشي الانحدار وانفجار الانحدار! هناك عدة طرق لتحديد هذه المشاكل ، والتي لخصناها أدناه.

اكتشاف انفجار الانحدار

- نظراً لعدم استقرار النموذج ، لوحظت العديد من التغييرات في تحسين الوزن. الأوزان تزيد أضعافاً مضاعفة أثناء التدريب.
- أثناء عملية التدريب ، ستحصل دالة التكلفة على مقدار NaN.
- لا يتعلم النموذج الكثير من المعلومات أثناء عملية التدريب ، لذلك لديه دالة تكلفة ضعيفة.

اكتشاف تلاشي الانحدار

- يعد تحسين النموذج بطيئاً جداً أثناء عملية التدريب ، وقد تتوقف عملية التدريب قريباً جداً ، مما يعني أنه لا يوجد تدريب آخر سيحسن النموذج.
- تخضع الأوزان القريبة من طبقة الإخراج لتغييرات أكثر من الطبقات القريبة من طبقة الإدخال.
- أوزان النموذج تنخفض أضعافاً مضاعفة.
- يجب أن يكون وزن النموذج صفرًا أثناء التدريب.

طرق القضاء على مشاكل تلاشي الانحدار وانفجار الانحدار

هناك عدة طرق للتعامل مع تلاشي الانحدار وانفجار الانحدار، وبعضها مذكور أدناه.

1. استخدام دوال التنشيط الأخرى (المعدل الخطي).
2. اختيار طريقة تهيئة أوزان أولية أخرى.

3. **قطع التدرج**¹: هذه الطريقة ، المناسبة لانفجار التدرج ، تحد من حجم التدرج بعتبة. هذا يتسبب في قطع التدرجات التي لها عتبة أعلى من المعيار المحدد لتتوافق مع القاعدة.

الضبط الزائد²

الجوانب الرائعة للشبكات المتصلة بالكامل هي الحفظ. بمعنى ، إذا تم منحهم الوقت الكافي ، فيسكونون قادرين على حفظ جميع بيانات التدريب. لذلك ، فإن تقارب الشبكة ليس معياراً لتقييم أداء الشبكة. لأنه إذا كان هناك الكثير من التقارب ، فستحفظ الشبكة بجميع البيانات ولن تكون قابلة للتعميم بعد الآن.

في الشبكات العميقة ، يكون الاتجاه التنازلي إلى الصفر شائعاً في دالة التكلفة ، وهذا ليس دليلاً على القدرة على تعميم الشبكة ، ولا يشير إلى قوة التعلم للشبكة. هذا لأنه من الممكن أن تحتوي الشبكة على ميزات وحالات محفوظة لمجموعة البيانات التي يتم تغذيتها بها ، والتي لم تعد مستخدمة في مجموعة البيانات. في مجموعة البيانات الكبيرة ، هناك احتمالية لوجود ارتباطات غريبة يمكن للشبكات المتصلة بالكامل أن تكتشفها وتستخدمها ، لذلك لكي تنجح الشبكة في الأداء بشكل أفضل ، يجب تجنب هذه السلوكيات.

يتمثل التحدي الرئيسي في التعلم الآلي في أن النموذج يجب أن يعمل بشكل جيد في التعامل مع البيانات الجديدة ، وليس فقط البيانات التي تعلمها ، بمعنى آخر ، أن يكون قادراً على التعميم. من ناحية أخرى ، تقوم شبكات التعلم العميق بنمذجة الدوال المعقدة بناءً على بيانات الإدخال نظراً للعدد الكبير من معاملات التعلم ، وإذا كان عدد هذه البيانات صغيراً ، فإن النموذج يعمل جيداً فقط على هذه البيانات ولن يكون قابلاً للتطوير. بعبارة أخرى ، علينا أن نكرر تدريب الشبكة العصبية لفترة كافية حتى نتمكن من التعيين بين المدخلات والمخرجات. لكن لا ينبغي أن يكون التدريب طويلاً بحيث

¹ gradient clipping

² Overfitting

تمتص الشبكة الضوضاء الإحصائية ويتوافق فقط مع بيانات التدريب ويقلل من امتداد الشبكة.

هناك طريقتان لحل هذه المشكلة ، أولاً ، جمع المزيد من البيانات وإدخالها إلى النموذج ، بينما في معظم الحالات هذه الطريقة غير ممكنة وهذه الطريقة أيضاً عملية مكلفة. الطريقة الثانية ، تسمى **التنظيم (التنعيم)**¹ ، هي نهج عملي لتقليل الضبط الزائد. يؤدي التنظيم إلى تغيير طفيف في خوارزمية التعلم ، بحيث يمكن تعميم النموذج لأداء أفضل في مواجهة البيانات التي لم تشاهد من قبل. فيما يلي سنصف طرق التنظيم.

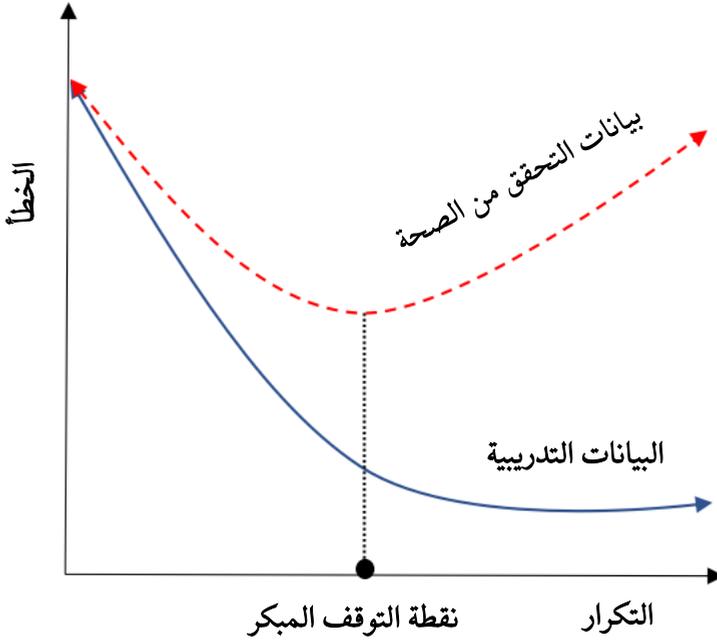
التوقف المبكر²

يعد التوقف مبكراً أحد أبسط الطرق وأكثرها شيوعاً للتعامل مع الضبط الزائد. يمكن رؤية الفكرة الرئيسية لهذه الطريقة في الشكل 2-17. باستخدام هذه الطريقة ، يمكن تحديد العدد المناسب من التكرارات لعملية تدريب الشبكة. لاستخدام هذه الطريقة ، تُستخدم بيانات التحقق من الصحة لحساب أداء دالة الخسارة في نهاية كل تكرار ، وتستمر عملية التكرار حتى النقطة (التكرار) حيث يتحسن أداء بيانات التحقق من الشبكة.

التوقف المبكر هو طريقة تنظيم مناسبة وغير متداخلة لأنها لا تتطلب تقريباً أي تغيير في عملية التدريب. هذا يعني أن استخدام هذه الطريقة لا يؤثر على ديناميكيات التعلم للشبكة. يمكن استخدام هذه الطريقة بمفردها أو بالاشتراك مع طرق تنظيم أخرى.

¹ Regularization

² Early Stopping



الشكل 2-17 التوقف المبكر

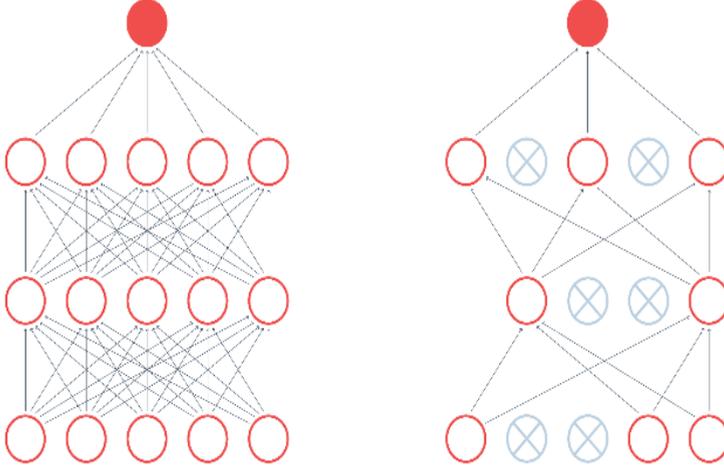
الحذف العشوائي¹

افترض أنك تقابل الكثير من الناس كل يوم. عندما تتحدث إليهم شخصياً ، تتذكر وجوههم. في بعض الأحيان عليك التواصل عبر الهاتف. لكنك هذه المرة لا تتعرف على نفس الأشخاص ، لأنك رأيتهم فقط ولا تتذكر سوى وجوههم. تخيل الآن أنه يمكنك التحدث إلى شخص عبر الهاتف فقط. في هذه الحالة ، عليك أن تتعلم حفظها بناءً على صوتهم. لذلك ، من خلال حذف الميزات المرئية ، عليك التركيز على ميزات الصوت. وهذا ما يفعله الحذف العشوائي على الشبكات العصبية ، إلى أن تتعلم الشبكة العصبية المزيد من الميزات المفيدة.

يعد الحذف العشوائي طريقة فعالة ومنخفضة التكلفة لتنظيم الشبكات العصبية. الفكرة البسيطة لهذه الطريقة هي أنه خلال كل عملية تدريب ، يتم الاحتفاظ بكل خلية عصبية في الشبكة مع احتمال p وإزالتها (غير نشطة) مع احتمال $1 - p$. عادة ما يعتبر

¹ Dropout

هذا الاحتمال 0.5 ، مع $P = 1$ لن تتم إزالة الخلايا العصبية من الشبكة. يوضح الشكل 18-2 مخططاً لشبكة قبل وبعد الحذف العشوائي.



الشكل 18-2 الحذف العشوائي. الشكل الأيمن للشبكة بعد الحذف العشوائي

في الشبكات العميقة ، تعتمد الخلايا العصبية الشبكية بسرعة على الخلايا العصبية التي تتلقى المعلومات المطبقة وتتلقى المعلومات منها. يرتبط هذا الاعتماد بخلايا عصبية غير مستقرة في الشبكة ، لأن الشبكة تعتمد على الميزات التي تتعلمها هذه الخلايا العصبية ، في حين أن هذه الخاصية لا تمثل جميع البيانات. باستخدام طريقة الحذف العشوائي ، لأنه سيكون من الممكن أن تكون الخلايا العصبية المحذوفة هي نفسها الخلايا العصبية القوية المذكورة ، فإنها ستزيل هذا الاعتماد. هذا يجبر الخلايا العصبية على التعلم بشكل مستقل ، مما يؤدي بدوره إلى أداء أفضل لتدريب الشبكة.

التسوية بالدفعات¹

إحدى المشاكل في تدريب الشبكة العصبية ، بالإضافة إلى تلاشي التدرج وانفجار التدرج ، هي مشكلة تغيير المتغيرات الداخلية للشبكة. تنشأ هذه المشكلة لأن المعاملات تتغير باستمرار أثناء عملية التدريب ، والتي بدورها تغير قيم دوال التنشيط. يؤدي تغيير

¹ Batch Normalization

قيم الإدخال من الطبقات الأولية إلى الطبقات التالية إلى تقارب أبطأ أثناء عملية التدريب، لأن بيانات التدريب للطبقات اللاحقة غير مستقرة.

بمعنى آخر ، الشبكات العميقة عبارة عن مزيج من عدة طبقات ذات دوال مختلفة ، ولا تتعلم كل طبقة التمثيل العام من بداية التدريب فحسب ، بل يتعين عليها أيضاً تغيير توزيعات الإدخال باستمرار وفقاً للطبقات السابقة. بينما يقوم المُحسِّن بتحسين المعاملات على افتراض أنها لا تتغير في الطبقات الأخرى ومزامنة جميع الطبقات في نفس الوقت ، فإن هذه العملية ستؤدي إلى نتائج غير مرغوب فيها عند الجمع بين الدوال المختلفة. تم اقتراح التسوية بالدفعات للتغلب على هذه المشكلة لتقليل عدم الاستقرار وتحسين الشبكة. في هذه الطريقة ، تقوم بتوحيد بيانات الإدخال للطبقة بحيث يكون لها متوسط صفر وانحراف معياري واحد. يعمل هذا على تبسيط عملية التعلم في النموذج ، حيث ستكون المعاملات في الطبقات السابقة غير فعالة في معظم الحالات. بدون هذه التسوية ، ستؤدي كل ترقية إلى إجراء تغيير جذري على النموذج. باختصار ، يمكننا تقليل التغييرات الداخلية لطبقات الشبكة عن طريق تسوية الدفعات بين الطبقات المخفية وإنشاء خاصية تباين مشتركة. تتلخص مزايا استخدام تسوية الدفعات في الشبكة على النحو التالي:

1. تساعد على نمذجة النموذج. أظهرت التجارب أن استخدام هذه الطريقة يقلل الحاجة إلى طرق تنظيمية أخرى إلى حد ما ، مثل الحذف التصادفي.
2. القدرة على استخدام معدلات تعلم عالية. في الشبكات التي لا تستخدم التسوية بالدفعات ، يتسبب معدل التعلم الكبير في تقلبات تؤدي إلى زيادة خطأ دالة الخسارة بدلاً من تقليلها. يعمل التسوية بالدفعات على حل هذه المشكلة إلى حد ما ، وبالتالي يسمح بمعدلات تعلم أكبر ، وبالتالي زيادة سرعات تعلم الشبكة.
3. باستخدام التسوية بالدفعات ، يمكن الحصول على تدرج أفضل من خلال الشبكة ، مما يجعل من الممكن استخدام المزيد من الطبقات المخفية.
4. تساعد في تقليل الاعتماد على تهيئة المعاملات.
5. يقلل من احتمالية الضبط الزائد. لأنها أقل تأثراً بالوضوء أثناء الاختبار (البيانات موحدة).
6. يتلاشى التدرج بدرجة أقل. خاصة لدوال التنشيط ذات الفضاء المشبع (السيكمويد ، إلخ).

توافر وجودة البيانات التعليمية

تعلم خوارزميات التعلم العميق التعلم من خلال الأمثلة التعليمية التي هي بيانات المشكلة المعنية. من أجل ضمان أن هذه الشبكة توفر أداءً جيداً ونتائج جيدة، من الضروري معرفة العديد من المعاملات. كلما زادت تعقيد الشبكة، زاد عدد المعاملات، مما يعني تجديداً أقوى. يتطلب تعلم هذا العدد من المعاملات الكثير من البيانات ويعتمد نجاح الشبكة على كمية البيانات. على سبيل المثال، يتطلب بناء نموذج للتعرف على الكلام بيانات من لهجات مختلفة. يتطلب بناء مثل هذا النظام حتى للغة واحدة بيانات كبيرة جداً لتغذية النموذج.

ومع ذلك، فإن التنظيم أو التنعيم هو أحد أكثر الطرق شيوعاً لمنع الضبط الزائد. ولكن يمكن أيضاً التغلب على هذه المشكلة عن طريق زيادة كمية البيانات. البيانات هي أهم عنصر في أي نموذج للتعلم الآلي. باختصار، الشبكات العصبية تتعلم من التجارب التي تواجهها. عادةً ما يكون ضبط المعاملات الفائقة أفضل خطوة لتصحيح خطأ التعميم. إذا كانت لا تزال هناك فجوة بين التدريب وخطأ التعميم، فغالباً ما تكون زيادة البيانات مفيدة. نقطة أخرى هي جودة البيانات التعليمية. لأن لديهم تأثير كبير على تدريب النموذج. يمكن للشبكات العصبية أن تقلل جزئياً من الضوضاء في مجموعة البيانات أثناء عملية التدريب. ومع ذلك، يمكن أن تسبب البيانات غير الصحيحة العديد من المشاكل. في بعض الأحيان، يرجع الأداء الضعيف للنموذج في التطبيقات الحقيقية إلى تسمية غير صحيحة (بيانات ذات جودة رديئة) أو نفس كمية البيانات. في النموذج المدرب، إذا بدا أن هناك سلوكاً غريباً في جميع مراحل التدريب، فقد يكون ذلك علامة على عدم تطابق البيانات.

يستفيد التعلم العميق من مجموعات البيانات الضخمة مقارنة بخوارزميات التعلم الآلي الأخرى. ترتبط العديد من التحسينات النوعية للتعلم المتعمق ارتباطاً مباشراً بزيادة حجم مجموعة البيانات التعليمية. يمكن أن تعمل مجموعات البيانات الضخمة كطريقة لوضع القواعد لمنع الضبط الزائد في النموذج.

تحسين المعاملات الفائقة

يختلف جداً تعلم شبكة عميقة عن تعلم شبكة عميقة يمكن استخدامها. من أجل تعليم نموذج مناسب للتعلم العميق ، يجب اجتياز العديد من الخطوات. كيفية تعيين المعاملات الفائقة هو واحد منهم. تسمى عملية تعيين معاملات النموذج ، والتي يجب أن يتم تحديد قيمتها قبل تعلم الشبكة ، **تحسين المعاملات الفائقة** ، وتحاول تحقيق أقصى استفادة من النظام.

المعاملات مثل عدد الخلايا العصبية في كل طبقة مخفية ، وعدد الطبقات المخفية ، وحجم الدفعة ومعدل التعلم هي معاملات فائقة. يعتبر أداء الشبكة العميق شديد الحساسية لهذه المعاملات. سيؤدي التعديل غير المناسب للمعاملات الفائقة إلى فشل عملية التعلم على الشبكة تماماً.

الاختلافات بين معاملات النموذج والمعاملات الفائقة في الشبكات العصبية؟

هناك نوعان من المعاملات المتضمنة في تدريب الشبكات العصبية وهما مختلفان عن بعضهما البعض، وفيما يلي، سوف نلقي نظرة سريعة على الاختلافات بينهما.

- **معاملات النموذج:** هذه المعاملات هي متغيرات يتم تقديرها من مجموعة البيانات أثناء عملية التدريب ولا يتم تحديد قيمها يدوياً. بمعنى آخر، هذه المعاملات هي متغيرات داخلية في الشبكة. يستخدم النموذج هذه المعاملات للتنبؤ.
- **المعاملات الفائقة:** المعاملات الفائقة هي متغيرات خارجية في تكوين الشبكة. بمعنى آخر، يتم تحديد قيمة هذه المتغيرات قبل بدء التعلم. هذه المعاملات لها تأثير كبير على سرعة الشبكة وأدائها.

لفهم الفرق بين المعاملات والمعاملات الفائقة بشكل أفضل، سيكون إعطاء مثال لفصلها عن بعضها أكثر وضوحاً. افترض أنك تريد تعلم القيادة. للقيام بذلك تحتاج إلى مدرب ليعلمك في عدة جلسات. سيواصل المدرب التدريب والتمارين بمساعدة الدروس والتمارين حتى تتأكد من قدرتك على القيادة بمفردك. بعد التدريب، بمجرد أن تصبح

قادرًا على القيادة، لن تحتاج إلى مدرب. في هذا السيناريو، يلعب المدرب دور المعاملات الفائقة، وأنت تلعب دور المعاملات.

كما لوحظ سابقًا، المعاملات هي المتغيرات التي يتم تقديرها أثناء عملية التدريب، ويتم استخدامها للتنبؤ في نهاية التدريب. في المقابل، لا تعتمد المعاملات الفائقة على مجموعة البيانات وليست جزءًا من النموذج النهائي، وتستخدم لتقدير معاملات النموذج. استخدم هذه القاعدة البسيطة عندما تواجه مشكلة في الفصل بينهما: إذا كان عليك تعيين قيمة قبل التدريب، فستكون معامل فائق. يمكن تلخيص المقارنة بين معاملات النموذج والمعاملات الفائقة في الجدول 2-2.

الجدول 2-2 مقارنة بين معاملات النموذج والمعاملات الفائقة

معاملات النموذج	المعاملات الفائقة
يتم تقدير قيمهم أثناء عملية التدريب.	يتم تعيين القيم قبل التدريب.
هي جزء من النموذج.	هي المتغيرات الخارجية.
تعتمد على البيانات.	لا تعتمد على البيانات.

ضبط المعاملات الفائقة

ضبط أو تحسين المعاملات الفائقة في محاولة للعثور على أفضل القيم لكل معامل فائق بحيث يوفر النموذج التنبؤ الأفضل والأكثر دقة. عند إعداد المعاملات الفائقة، استخدم دائمًا معيارًا لتجربة قيم تحسين مختلفة. فيما يلي قائمة بالمعاملات الفائقة الشائعة في الشبكات العميقة:

- عدد الطبقات المخفية.
- معدل التعلم.
- دالة التنشيط.
- حجم الدفعة.
- الفترة.
- الحذف العشوائي.
- القيم الأولية للاوزان.
- خوارزمية التحسين.

كما هو مذكور في الفصل الاول ، يتم استخدام بيانات التحقق لتعيين المعاملات الفائقة. في استمرار لهذا القسم ، سنقدم لمحة موجزة عن الطرق المختلفة لتحسين المعاملات الفائقة.

الضبط اليدوي للمعاملات الفائقة (التجربة والخطأ)

أسهل طريقة لتعيين المعاملات الفائقة هي تعيين قيم مختلفة والتحقق من النتائج. من خلال الضبط اليدوي لاختيار المعامل الحالي في كل خطوة ، يمكن التحقق من الفرق بين النتيجة السابقة ومقارنتها. قد تبدو فكرة بسيطة ، لكنها ستحقق نتائج جيدة. يحتاج الممارس في التعلم العميق إلى اكتساب خبرة في مجال الشبكات ، والتي تنقل الخبرات القيمة عن طريق اختبار نتائج مختلفة ويمكن أن تكون مفيدة للغاية. في هذه الطريقة ، من الأفضل العمل بانتظام وتسجيل جميع نتائجه والتحكم في عملية التحسين والأداء ، لتحليل أي من المعاملات لها التأثير الأكبر على أداء النموذج.

المزايا:

- يمكنك معرفة جوهر سلوك المعامل الفائق واستخدام معرفتك في مشاريع أخرى.

العيوب:

- يتطلب عمل يدوي.
- قد تكون راضيًا عن نفس النتيجة التي حصلت عليها دون إجراء الكثير من الاختبارات.

البحث الشبكي¹

يعد التجريب المتكرر والجمع بين القيم المختلفة للمعاملات الفائقة يدويًا مهمة شاقة وتستغرق وقتًا طويلاً وتتطلب قدرًا كبيرًا من الخبرة في فهم النموذج. يحاول البحث

¹ Grid Search

الشبكي ببساطة تعيين المعاملات الفائقة ضمن نطاق معين من القيم. تختبر هذه الطريقة تلقائياً القيم المختلفة لكل معامل فائق تلقائياً باستخدام قيم متعددة للمتغيرات.

المزايا:

- يغطي كل المجموعات الممكنة.

العيوب:

- وقت تنفيذ جميع المعاملات الفائقة طويل ، لذلك سيكون هناك حد لعدد المعاملات.

البحث العشوائي¹

هناك طريقة بسيطة لاستبدال البحث الشبكي عن طريق أخذ عينات عشوائية من مساحة المعامل الفائقة. بمعنى آخر ، بدلاً من التجارب المنتظمة على مجموعة القيم الكاملة في مساحة المشكلة ، من الأفضل تحديد واختبار القيم العشوائية من مساحة العينة بأكملها. من الناحية التجريبية والنظرية ، في عام 2012 ، أظهر بيرجستارا وبينجيو في مقال بعنوان "البحث العشوائي من أجل التحسين" أن استخدام البحث العشوائي لتحسين الفائقة الفائقة يكون أكثر فاعلية من بحث الشبكة.

المزايا:

- لا داعي للقلق بشأن وقت التشغيل ، حيث يمكنه التحكم في عدد عمليات البحث عن المعاملات.

العيوب:

- اعتماداً على عدد عمليات البحث وحجم مساحة المعامل ، قد لا يتم استكشاف بعض المعاملات.

¹ Random Search

تحسين بايزي¹

الفرضية الأساسية لتحسين بايزي هي: "إذا بحثنا عشوائياً عن بعض النقاط وعرفنا أن بعض هذه النقاط واعدة أكثر من غيرها ، فلماذا لا ننظر إليها؟"

يأخذ تحسين بايزي في الاعتبار التقييمات السابقة عند اختيار مجموعة من المعاملات الفائقة للتقييم التالي. من خلال اختيار تكوين المعاملات الفائقة بوعي ، فإنه يسمح لنفسه بالتركيز على مناطق مساحة المعامل الفائق التي يعتقد أنها تحتوي على أعلى درجة ممكنة. يتطلب هذا النهج عادةً تكراراً أقل في تحقيق المجموعة المرغوبة من قيم المعاملات الفائقة ، لأنه يتجاهل مناطق مساحة المعامل التي يعتقد أنها لا تفعل شيئاً للمساعدة.

المزايا:

- ليس بالضرورة ، ولكن من المحتمل أن يكون البحث فعالاً.

العيوب:

- من الممكن أن نكون محاصرين في المستوى المحلي الأمثل.

الشبكة العصبية المتكررة (RNN)²

عندما يتم ترتيب البيانات بحيث يكون لكل قطعة نوع من العلاقة مع القطع التي تم إنشاؤها قبلها وبعدها، يشار إليها باسم التسلسلات. هناك بعض البيانات المشيرة للاهتمام في العالم، مثل أسعار الأسهم في الأيام القليلة الماضية، أو إطارات لصنع فيلم أو كلمات من جزء من اللغة المنطوقة أو المكتوبة. من الطبيعي طرح أسئلة حول تسلسل البيانات هذا، مثل: هل هذه التسلسلات مثل تسلسل آخر (على سبيل المثال: هل كتب هذا الكتاب نفس مؤلف كتاب آخر؟)، كيف يمكن شرحها بمصطلحات أخرى (على سبيل المثال: ترجمة سلاسل الكلمات إلى لغة أخرى) أو كيف سيتصرفون في المستقبل (على سبيل المثال: ماذا سيكون سعر السهم غداً؟).

¹ Bayesian Optimization

² Recurrent Neural Network

يمكن للشبكات العصبية المعنية الإجابة على هذه الأسئلة بشكل صحيح حتى الآن، ولكن هناك مشكلة في هذه الشبكات، وهي نقص الذاكرة. هذا النقص يضعف استخدام هذه الشبكات لهذا النوع من بنية البيانات. للتعويض عن هذا النقص، يمكننا تعويض هذا النقص في الذاكرة عن طريق استبدال الخلايا العصبية الاصطناعية بعملية أكثر تعقيداً تسمى الوحدة المتكررة. من خلال الجمع بين الطبقات القياسية وطبقات من الوحدات المتكررة، يمكننا إنشاء شبكات تعلم عميق تسمى الشبكات العصبية المتكررة، أو RNNs للاختصار. يمكن لـ RNNs الإجابة على جميع الأسئلة المذكورة أعلاه وغيرها الكثير. يمكن استخدامها في ترجمة اللغة إلى التسميات التوضيحية التلقائية للصور وحتى إنتاج نثر جديد بأسلوب المؤلفين المشهورين.

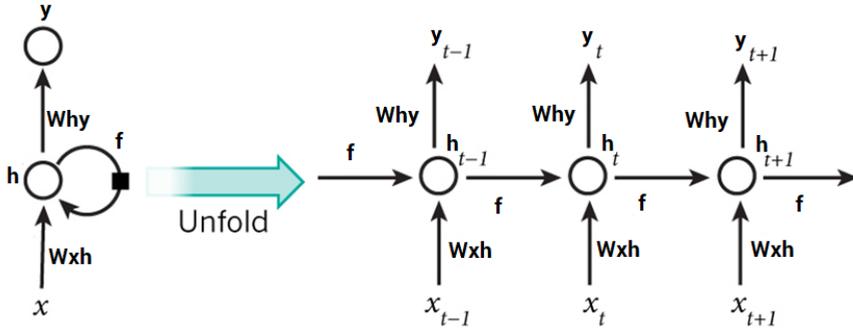
هيكل شبكة عصبية متكررة بسيطة

الشبكات العصبية المتكررة، أو RNNs، هي نوع من الشبكات العصبية التي يمكنها معالجة البيانات المتسلسلة ذات الطول المتغير. تتضمن أمثلة هذه البيانات الكلمات المكونة من جملة واحدة أو أسعار الأسهم في نقاط زمنية مختلفة. يمكن اعتبار RNN كرسم بياني لوحدة RNN، حيث يؤدي كل عنصر تسلسلي نفس الإجراء. أدى نفس الإجراء المتكرر في التسلسل إلى تسمية الشبكة العصبية المتكررة. تعتمد الشبكات العصبية التقليدية على افتراض أن جميع المدخلات مستقلة عن بعضها البعض، كما أنها تستخدم هذا الافتراض للبيانات المتسلسلة. تحتفظ وحدات RNN بهذه التبعيات فيما رأوه حتى الآن، في وضع التخزين المؤقت أو الذاكرة.

يمكن تعريف RNN على أنها حلقة تغذية متكررة على النحو التالي:

$$h_t = f(h_{t-1}, x_t)$$

في هذا الصدد، h_t هو مجموع القيم التي تسمى وضع الشبكة الداخلية في الوقت t و x_t هي إدخال الشبكة في الوقت t . على عكس الشبكات التقليدية، حيث تعتمد الحالة فقط على المدخلات الحالية (وأوزان الشبكة)، تعتمد هذه الشبكات على كل من الإدخال الحالي والحالة السابقة. يمكن اعتبار h_{t-1} بمثابة ملخص لمدخلات الشبكة السابقة. توضح العلاقة المتكررة كيف يتم تنفيذ الحالة التطورية خطوة بخطوة على التسلسل من خلال حلقة تغذية متكررة مقارنة بالحالات السابقة في الشكل 2-19.



الشكل 2-19 شبكة عصبية متكررة بسيطة

لدى RNN ثلاث مجموعات من المعاملات:

- U (w_{xh}) يحول الإدخال x_t إلى الحالة h_t .
- W (w_{hh}) يحول الحالة السابقة s_{t-1} إلى الحالة الحالية h_t .
- V (w_{yh}) تعيين الحالة الداخلية المحسوبة حديثاً إلى ناتج y_t .

يتم إجراء التحويلات الخطية على المدخلات المعنية باستخدام U و W و V . بناءً على ذلك ، يمكن تحديد الحالة الداخلية ومخرجات الشبكة على النحو التالي:

$$h_t = f(h_{t-1} * W + x_t * U)$$

$$o_t = h_t * V + b_y$$

$$y_t = f(o_t)$$

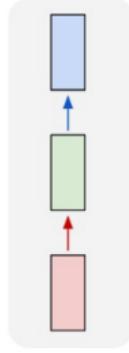
في هذه العلاقة f هي دالة تنشيط غير خطية.

كما هو مذكور في RNN ، تعتمد كل حالة على جميع الحسابات السابقة بواسطة المعادلة المتكررة. ومن النتائج المهمة لذلك إنشاء الذاكرة بمرور الوقت ، لأن الحالات تستند إلى مراحل سابقة. من الناحية النظرية ، يمكن لشبكات RNN تخزين المعلومات لفترة طويلة ، لكنها في الواقع تنظر فقط إلى بضع خطوات.

أنواع بُنية الشبكة العصبية المتكررة

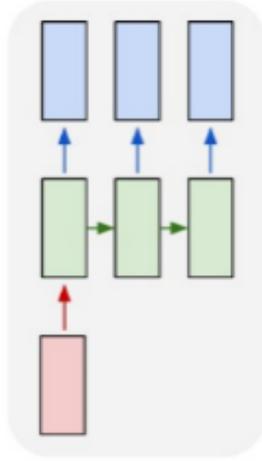
عادة ، تشمل RNNs على بُنيات مختلفة. في هذا القسم ، سوف نلقي نظرة على بعض بُنى RNN الأساسية:

- **واحد لواحد:** كما يتضح من الشكل 2-20 ، في هذه البنية ، يتم تعيين وحدة إدخال RNN إلى وحدة مخفية ووحدة إخراج. هذه البنية هي عملية متسلسلة مثل الشبكات العصبية امامية التغذية والشبكات العصبية الالتفافية. مثال على هذه العملية هو تصنيف الصور.



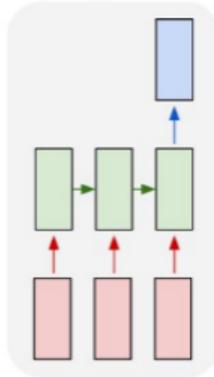
الشكل 2-20 RNN واحد لواحد.

- **واحد لمتعدد:** كما يتضح من الشكل 3-21 ، في هذه البنية ، يتم تعيين وحدة إدخال RNN إلى عدة وحدات مخفية وعدة وحدات إخراج. المثال العملي لهذه البنية هو وصف الصورة. تتلقى طبقة الإدخال صورة وتعيينها إلى عدة كلمات.



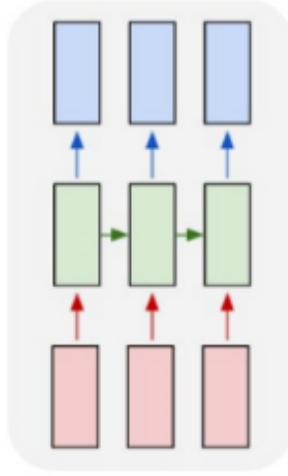
الشكل 2-21 RNN واحد لمتعدد.

- **متعدد لواحد:** كما يتضح من الشكل 2-22 ، في هذه البنية ، يتم تعيين العديد من وحدات إدخال RNN إلى عدة وحدات مخفية ووحدة إخراج واحدة. مثال عملي على هذه البنية هو تصنيف المشاعر. تستقبل طبقة الإدخال عدة إشارات للكلمات في الجملة ، وترسمها على أنها عاطفة إيجابية أو سلبية.



الشكل 2-22 RNN متعدد لواحد.

- **متعدد لمتعدد:** كما يتضح من الشكل 2-23 ، في هذه البنية ، يتم تعيين العديد من وحدات إدخال RNN إلى عدة وحدات مخفية ووحدة إخراج واحدة. مثال عملي على هذه البنية هو الترجمة الآلية. تستقبل طبقة الإدخال عدة أحرف من كلمات اللغة المصدر ، وتقوم بتعيينها إلى أحرف الكلمات في اللغة الهدف.



الشكل 2-23 RNN متعدد لمتعدد.

تدريب الشبكة العصبية المتكررة

غالبًا ما يتم إجراء تدريب الشبكة العصبية المتكررة باستخدام خوارزمية الانحدار الاشتقاقي العشوائي للدفعات الصغيرة. كما هو مذكور في القسم الخاص بخوارزميات التحسين ، تختار هذه الخوارزميات مجموعات فرعية عشوائية من عينات التدريب لحساب التدرجات وتحديث الأوزان. من خلال النظر في عينات أصغر من العينات ، يكون لها تدريب أكثر ثباتًا واتساقًا من التدرج الذي يتم تحديثه بعينة واحدة فقط. كما أنه أكثر كفاءة من التحديث بجميع أمثلة التدريب.

الانتشار الخلفي بمرور الوقت

يتم تدريب الشبكات العصبية المتكررة بمرور الوقت بواسطة نوع خاص من خوارزمية ما الانتشار الخلفي تسمى الانتشار الخلفي بمرور الوقت. مثل خوارزمية الانتشار الخلفي في شبكة العصبية امامية التغذية ، تستخدم هذه الخوارزمية قانون السلسلة لحساب الانحدار الاشتقاقي. يعد الانتشار الخلفي في الشبكات العصبية المتكررة أكثر صعوبة بعض الشيء بسبب الطبيعة المتكررة للأوزان واختفائها بمرور الوقت. لأننا نحتاج إلى تمديد الرسم البياني الحسابي لـ RNN مرة واحدة للحصول على التبعيات بين المتغيرات ومعاملات

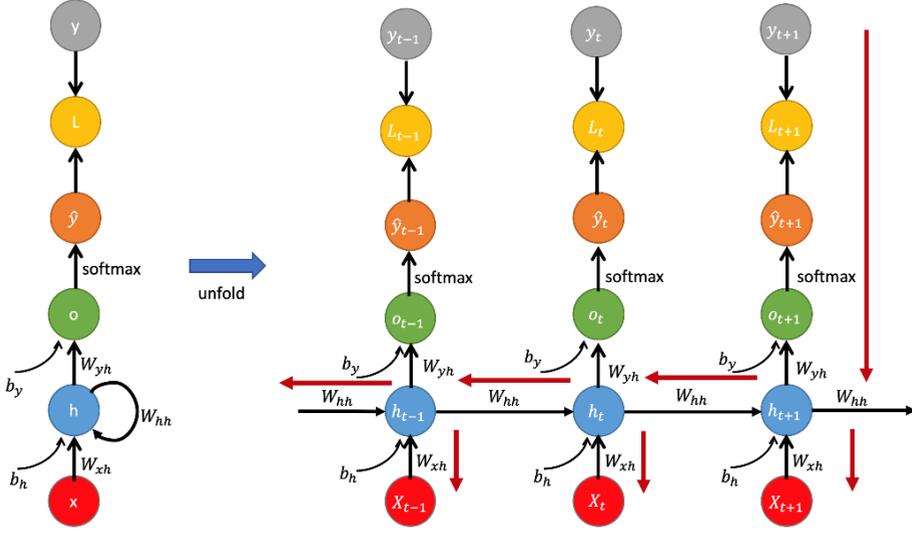
النموذج. ثم باستخدام الانتشار الخلفي وقانون السلسلة لحساب وخرن التدرجات. نظرًا لأن التسلسلات يمكن أن تكون طويلة ، فقد تكون التبعيات طويلة.

على سبيل المثال ، بالنسبة لتسلسل من 1000 حرف ، يمكن أن يكون للحرف الأول تأثير كبير على الحرف في الموقع النهائي. هذا ليس ممكنًا من الناحية الحسابية حقًا. لأنها تستغرق وقتًا طويلًا وتتطلب الكثير من الذاكرة. هذه العملية مليئة بالشكوك الحسابية والإحصائية.

في ما يلي سوف نشرح كيف يتم حل هذه المشكلة عمليًا. لكن قبل ذلك ، دعونا ننظر إلى مرحلة الانتشار الخلفي بطريقة رياضية. لفهم كيفية عمل هذا النهج ، يمكنك الاطلاع على نظرة عامة حول كيفية تدفق المعلومات في الشكل 2-24.

من أجل التمكن من استخدام الانتشار الخلفي بمرور الوقت في عملية تدريب الشبكة العصبية المتكررة ، يجب أولاً حساب دالة الخسارة:

$$\begin{aligned} L(\hat{y}, y) &= \sum_{t=1}^T L_t(\hat{y}_t, y_t) \\ &= - \sum_t y_t \log \hat{y}_t \\ &= - \sum_{t=1}^T y_t \log [\text{softmax}(o_t)] \end{aligned}$$



الشكل 2-24 الانتشار الخلفي في الشبكة العصبية المتكررة البسيطة

نظراً لأن وزن w_{yh} مقسم في جميع المتتاليات الزمنية. ومن ثم ، يمكننا اشتقاقها في أي مرحلة وتجميعها معاً:

$$\begin{aligned} \frac{\partial L}{\partial w_{yh}} &= \sum_t^T \frac{\partial L_t}{\partial w_{yh}} \\ &= \sum_t^T \frac{\partial L_t}{\partial \hat{y}_t} \frac{\partial \hat{y}_t}{\partial o_t} \frac{\partial o_t}{\partial w_{yh}} \\ &= \sum_t^T (\hat{y} - y_t) \otimes h_t \end{aligned}$$

في هذه المعادلة $\frac{\partial o_t}{\partial w_{yh}} = h_t$ و \otimes هما ضرب خارجي لمتجهين.

وبالمثل ، يمكننا الحصول على تدرج التحيز b_y :

$$\begin{aligned} \frac{\partial L}{\partial b_y} &= \sum_t^T \frac{\partial L_t}{\partial \hat{y}_t} \frac{\partial \hat{y}_t}{\partial o_t} \frac{\partial o_t}{\partial b_y} \\ &= \sum_t^T (\hat{y} - y_t) \end{aligned}$$

بالإضافة إلى ذلك ، دعنا نستخدم L_{t+1} للإشارة إلى ناتج الخطوة الزمنية $t + 1$:

$$L_{t+1} = -y_{t+1} \log \hat{y}_{t+1}$$

الآن ، سنراجع تفاصيل الانحدار الاشتقاقي w_{hh} فيما يتعلق بالوقت $t + 1$:

$$\frac{\partial L_{t+1}}{\partial w_{hh}} = \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \frac{\partial h_{t+1}}{\partial w_{hh}}$$

منذ الحالة الكامنة h_{t+1} فيما يتعلق بالمعادلة المتكررة h_t :

$$h_t = \tanh(w_{xh}^T \cdot x_t + w_{hh}^T \cdot h_{t-1} + b_h)$$

لذلك ، في الخطوة الزمنية $t \rightarrow t - 1$ ، يمكن الحصول على المشتق الجزئي فيما يتعلق بـ w_{hh} على النحو التالي :

$$\frac{\partial L_{t+1}}{\partial w_{hh}} = \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \frac{\partial h_{t+1}}{\partial h_t} \frac{\partial h_t}{\partial w_{hh}}$$

لذلك ، في الخطوة الزمنية $t + 1$ ، يمكننا حساب الانحدار الاشتقاقي واستخدام $t + 1$ إلى t من خلال إعادة الإرسال بمرور الوقت للحصول على التدرج الكلي فيما يتعلق بـ w_{hh} :

$$\frac{\partial L_{t+1}}{\partial w_{hh}} = \sum_{k=1}^{t+1} \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \frac{\partial h_{t+1}}{\partial h_k} \frac{\partial h_k}{\partial w_{hh}}$$

لاحظ $\frac{\partial h_{t+1}}{\partial h_k}$ هي نفسها قانون سلسلة. فمثلاً :

$$\frac{\partial h_3}{\partial h_1} = \frac{\partial h_3}{\partial h_2} \frac{\partial h_2}{\partial h_1}$$

لاحظ أيضاً أنه نظراً لأننا نعتبر مشتقة دالة كمتجه ، فهي نتيجة مصفوفة (مصفوفة ياكوبية*) تكون فيها جميع العناصر مشتقات جزئية. يمكننا إعادة كتابة التدرج أعلاه :

* بالنظر إلى دالة التعيين التالي n -ب للمتجه x إلى متجه الإخراج التالي m -، $f: \mathbb{R}^n \rightarrow \mathbb{R}^m$ ، تسمى مصفوفة جميع المشتقات الجزئية من الدرجة الأولى لهذه الدالة بمصفوفة ياكوبية (J).

$$J = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \dots & \frac{\partial f_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \dots & \frac{\partial f_m}{\partial x_n} \end{bmatrix}$$

$$\frac{\partial L_{t+1}}{\partial w_{hh}} = \sum_{k=1}^{t+1} \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \left(\prod_{j=k}^t \frac{\partial h_{j+1}}{\partial h_j} \right) \frac{\partial h_k}{\partial w_{hh}}$$

حيث:

$$\prod_{j=k}^t \frac{\partial h_{j+1}}{\partial h_j} = \frac{\partial h_{t+1}}{\partial h_k} = \frac{\partial h_{t+1}}{\partial h_t} \frac{\partial h_t}{\partial h_{t-1}} \dots \frac{\partial h_{k+1}}{\partial h_k}$$

تتم إضافة التدرجات المتعلقة بـ w_{hh} معاً في جميع خطوات الانتشار الخلفي ، وأخيراً يمكننا الحصول على التدرجات الاشتقاقية التالية فيما يتعلق بـ w_{hh} :

$$\frac{\partial L}{\partial w_{hh}} = \sum_t^T \sum_{k=1}^{t+1} \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \frac{\partial h_{t+1}}{\partial h_k} \frac{\partial h_k}{\partial w_{hh}}$$

الآن دعنا نستخرج التدرج بالنسبة إلى w_{xh} . وبالمثل ، ضع في اعتبارك الخطوة الزمنية $t + 1$ واحصل على التدرج الاشتقاقي فيما يتعلق بـ w_{xh} على النحو التالي:

$$\frac{\partial L_{t+1}}{\partial w_{xh}} = \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \frac{\partial h_{t+1}}{\partial w_{xh}}$$

نظراً لأن كل من h_t و x_{t+1} يساهمان في h_{t+1} ، فنحن بحاجة إلى h_t للانتشار الخلفي. إذا أخذنا في الاعتبار هذه المساهمة ، فسنحصل عليها:

$$\frac{\partial L_{t+1}}{\partial w_{xh}} = \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \frac{\partial h_{t+1}}{\partial w_{xh}} + \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_t} \frac{\partial h_t}{\partial w_{xh}}$$

لذلك ، من خلال جمع جميع المساهمات من $t + 1$ إلى t عبر الانتشار الخلفي ، يمكننا الحصول على التدرج الاشتقاقي في الوقت $t + 1$:

$$\frac{\partial L_{t+1}}{\partial w_{xh}} = \sum_{k=1}^{t+1} \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \frac{\partial h_{t+1}}{\partial h_k} \frac{\partial h_k}{\partial w_{xh}}$$

بالإضافة إلى ذلك ، يمكننا اعتبار المشتق بالنسبة إلى w_{xh} في المتتالية بأكملها:

$$\frac{\partial L}{\partial w_{xh}} = \sum_t \sum_{k=1}^{t+1} \frac{\partial L_{t+1}}{\partial \hat{y}_{t+1}} \frac{\partial \hat{y}_{t+1}}{\partial h_{t+1}} \frac{\partial h_{t+1}}{\partial h_k} \frac{\partial h_k}{\partial w_{xh}}$$

لا تنس أيضاً أن $\frac{\partial h_{t+1}}{\partial h_k}$ هي نفسها قانون السلسلة.

كما ذكرنا ، هناك مشاكل في تلاشي وانفجار الانحدار في الشبكة العصبية المتكررة العادية. بشكل عام ، هناك عاملان يؤثران على مقدار التدرجات: **الأوزان ودوال التنشيط**، أو بشكل أكثر دقة ، **المشتقات** التي يمر منها الانحدار الاشتقاقي. في الشبكة العصبية المتكررة العادية ، ينتج تلاشي الانحدار عن الاتصالات المتكررة. بشكل أوضح ، هاتان المشكلتان ترجعان إلى المشتق المتكرر $\frac{\partial h_{t+1}}{\partial h_k}$ الذي يحدث في المعادلة w_{xh} ويجب حسابه:

$$\prod_{j=k}^t \frac{\partial h_{j+1}}{\partial h_j} = \frac{\partial h_{t+1}}{\partial h_k} = \frac{\partial h_{t+1}}{\partial h_t} \frac{\partial h_t}{\partial h_{t-1}} \dots \frac{\partial h_{k+1}}{\partial h_k}$$

ويمثل ضرب المصفوفة على المتتالية.

نظراً لأن الشبكة العصبية المتكررة العادية تحتاج إلى الحصول على الانحدار الاشتقاقي للانتشار الخلفي بتسلسل طويل (بقيم صغيرة مضروبة في المصفوفة) ، فإن مقدار التدرج ينخفض طبقة تلو الأخرى ويختفي في النهاية بعد بضع خطوات. لذلك ، لن تساعد الحالات البعيدة عن المرحلة الزمنية الحالية في حساب معاملات التدرج ، وهي نفس معاملات التعلم في الشبكة العصبية المتكررة.

لا يقتصر تلاشي الانحدار على الشبكة العصبية المتكررة العادية. كما هو مذكور في الفصل 2 ، تحدث أيضاً في الشبكات العصبية امامية التغذية. النقطة المهمة هي أن الشبكة العصبية المتكررة أكثر شيوعاً بسبب عمقها. تظهر هاتان المشكلتان في النهاية أنه إذا اختفى الانحدار الاشتقاقي ، فهذا يعني أن الحالات المخفية السابقة ليس لها تأثير حقيقي على الحالات المخفية التالية. بمعنى آخر ، لا يتم تعلم التبعية طويلة المدى.

لحسن الحظ ، هناك عدة طرق لإصلاح مشكلة تلاشي الانحدار. يمكن أن يؤدي التهيئة المناسبة لمصفوفات الوزن إلى تقليل تأثير تلاشي الانحدار. يمكن أن يساعد التنظيم أيضاً. هناك حل آخر مفضل أكثر من الحلين السابقين وهو استخدام دالة التنشيط ReLU بدلاً من وظائف Tanh أو Sigmoid. مشتق ReLU هو ثابت من 0 أو 1 ، لذلك على الأرجح لا يحتوي على مشكلة تلاشي الانحدار. الحل الأكثر شيوعاً الأكثر استخداماً اليوم هو استخدام شبكات الذاكرة قصيرة المدى تدوم لفترة أطول (LSTM) أو وحدات إرجاع البوابة (GRUs).

شبكات الذاكرة قصيرة المدى تدوم لفترة أطول (LSTM)¹

شبكات الذاكرة تدوم لفترة أطول ، والمختصرة بـ LSTMs ، هي نوع خاص من الـ RNN. تم تصميم هذه الأنواع من الشبكات العصبية لتعلم التبعيات طويلة المدى بواسطة هوجريتر² و شميتير³ في عام 1997. يمكن أن تحل LSTMs مشكلة التبعيات طويلة المدى لأنها تحتوي على خلية ذاكرة محددة. الفكرة الأساسية لـ LSTM هي منطلق البوابة ، والذي يتيح بنية قائمة على الذاكرة. لمزيد من وصف هذا المفهوم ، ننتقل إلى بنية ذاكرة LSTM. مثل أي نظام قائم على الذاكرة ، تحتوي خلية LSTM النموذجية على ثلاث ميزات رئيسية:

1. الكتابة في الذاكرة.
2. القراءة من الذاكرة.
3. إعادة ضبط الذاكرة.

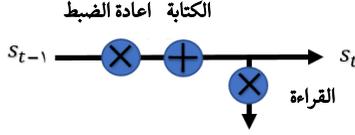
يوضح الشكل 2-25 هذه الفكرة. يتم تمرير قيمة خلية LSTM السابقة أولاً من خلال بوابة إعادة الضبط ، والتي تعمل على قياس قيمة الحالة السابقة في النطاق من 0 إلى 1. إذا كانت النتيجة قريبة من 1 ، فستمرر قيمة حالة الخلية السابقة (تذكر الحالة السابقة). إذا كانت هذه القيمة قريبة من الصفر ، فسيتم حظر حالة الخلية السابقة (نسيان

¹ Long short term memory

² Hochreiter

³ Schmidhuber

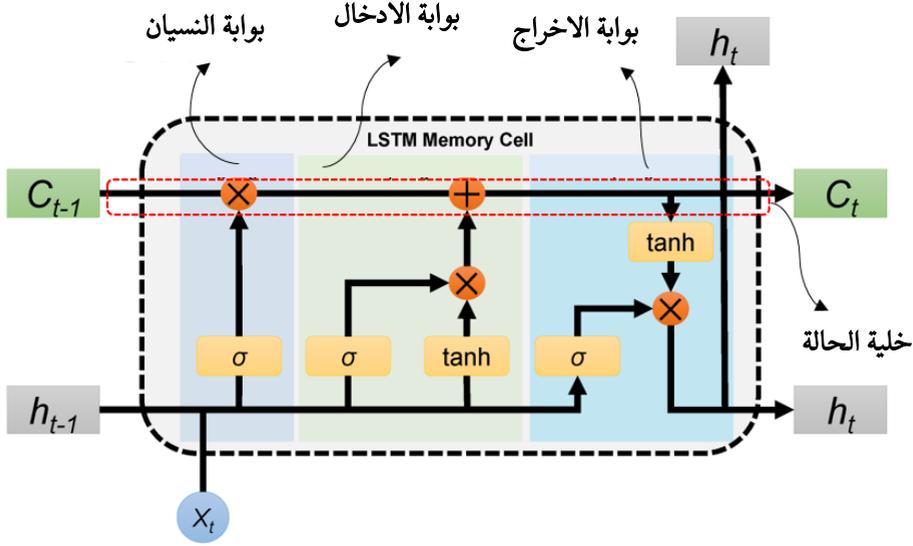
الحالة السابقة). في الخطوة التالية ، تقوم بوابة الكتابة ببساطة بإعادة كتابة الإخراج المعدل لبوابة إعادة التعيين. أخيراً ، تقرأ بوابة القراءة إخراج بوابة الكتابة.



الشكل 2-25 الفكرة الرئيسية ل LSTM

كما ذكرنا ، يتيح LSTM القدرة على حذف أو إضافة معلومات إلى خلية الحالة بواسطة بُنية البوابة. هناك ثلاثة أنواع من البوابات في هيكل LSTM ، والتي يمكنك رؤيتها في الشكل 2-26:

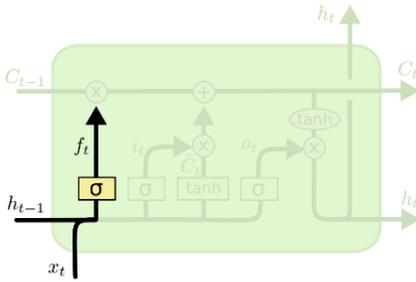
- **بوابة النسيان:** في هذه البوابة ، يتم تطبيق دالة سيكمويد على قيم الإدخال من خلية الحالة السابقة. نظرًا لأن دالة سيكمويد تأخذ أي قيمة بين 0 و 1 ، فإن هذه البوابة تعني نسيان مقدار قيمة الخلية للحالة السابقة الممكنة. بمعنى آخر ، تساعد هذه البوابة على نسيان محتوى الماضي.
- **بوابة الدخول:** بوابة الدخول مسؤولة عن الحماية من المداخل غير المرتبطة.
- **بوابة الإخراج:** تولد هذه البوابة ناتجًا في الوقت t عند h_t باستخدام دالة سيكمويد. بمعنى آخر ، تشارك بوابة الإخراج في إظهار أو عدم عرض المحتويات داخل الخلية.



الشكل 2-26 بُنية LSTM

سننظر الآن في كيفية عمل LSTM خطوة بخطوة:

تتمثل الخطوة الأولى في LSTM في تحديد المعلومات التي يجب نقلها بعيداً عن خلية الحالة. يتم اتخاذ هذا القرار من خلال طبقة سيكمويد تسمى طبقة بوابة النسيان ، والتي يمكن رؤيتها في الشكل 2-27.



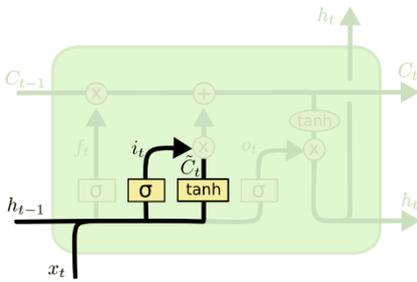
$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

الشكل 2-27 طبقة بوابة النسيان

تقوم المدخلات h_{t-1} و x_t بتنفيذ عملية حذف المعلومات أو تركها من خلية الحالة. إذا كانت القيمة التي تم الحصول عليها هي 1 ، فسيتم نقل خلية الحالة C_{t-1} بالكامل إلى C_t ، وتعني القيمة 0 أنه لن يتم نقل أي شيء من C_{t-1} . على سبيل المثال ، في نمذجة لغة تحاول التنبؤ بالكلمة التالية بناءً على جميع الكلمات التي تسبقها ، إذا كانت

خلية الحالة تحتوي على جنس الموضوع الحالي ، فيجب أن تتخذ قراراً باختيار الضمير بناءً عليها. لذلك ، إذا ظهر موضوع جديد ، فمن الضروري إزالة جنس الموضوع السابق. الخطوة التالية في تحديد المعلومات الجديدة التي سيتم تخزينها في خلية الحالة. يمكن رؤية هذه الخطوة في الشكل 2-28 وتتكون من جزأين.

أولاً ، تحدد طبقة سيكمويد التي تسمى **طبقة بوابة الإدخال** القيم المراد تحديثها ، ثم تنشئ طبقة تانتش متجهاً لقيم C_t المرشحة الجديدة. أخيراً ، يتم دمج الاثنین لتشكيل خلية حالة.

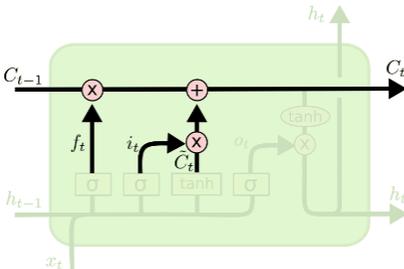


$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

الشكل 2-28 طبقة بوابة الادخال

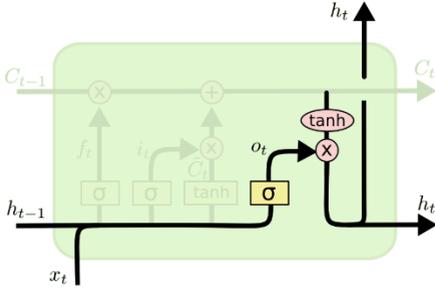
في المثال السابق ، جرت محاولة لاستبدال جنس الموضوع الجديد بخلية حالة بجنس الموضوع السابق. للقيام بذلك ، يتم تحديث خلية الحالة القديمة C_{t-1} بـ C_t ، وضرب قيمة خلية الحالة السابقة بـ f_t ، ثم أضف $i_t * C_t$ إليها ، كما هو موضح في الشكل 2-29. هذه الخطوة ، على سبيل المثال ، هي المكان الذي يتم فيه تجاهل معلومات النوع النشط السابقة ، ويتم إضافة معلومات جديدة إلى خلية الحالة.



$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

الشكل 2-29 تحديث المعلومات

أخيراً ، يجب تحديد ما هو موجود في الإخراج. يعتمد هذا الإخراج على خلية الحالة بإصدار تمت فلتريته. أولاً ، يتم تطبيق طبقة سيكمويد لتحديد أجزاء خلية الحالة المراد إرسالها إلى المخرجات ، ثم نقوم بتمرير قيمة خلية الحالة إلى طبقة تانتش لمضاعفة قيمتها أخيراً بإخراج طبقة سيكمويد السابقة حتى تتم مشاركة الأجزاء المطلوبة في الإخراج. يوضح الشكل 2-30 كيفية القيام بذلك.



$$o_t = \sigma (W_o [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh (C_t)$$

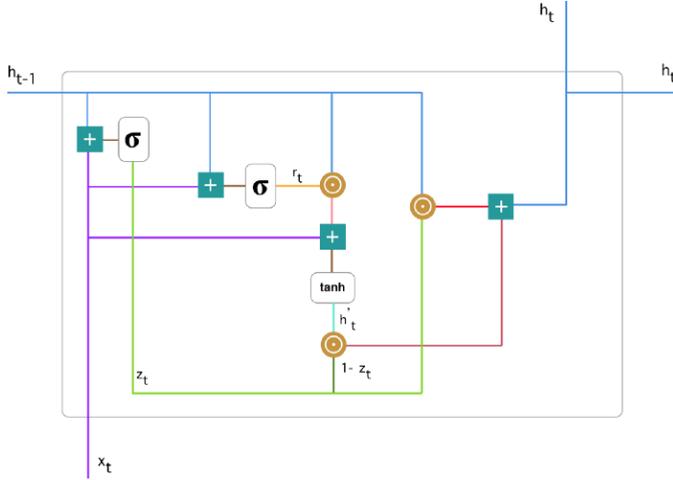
الشكل 2-30 بوابة الاخراج

وحدات إرجاع البوابة (GRU)¹

في محاولة لتبسيط LSTM ، سنة 2014 تم تقديم Gateway Return Unit (GRU). لحل مشكلة تلاشي الانحدار في RNN القياسي مقارنة بـ LSTM ، الذي يحتوي على ثلاث بوابات ، تستخدم GRU بوابتين تسمى: بوابات تحديث وإعادة التعيين. تحدد هاتان البوابتان المعلومات التي يجب عرضها في الإخراج.

على عكس LSTM ، التي تستخدم بوابة النسيان والاخراج مباشرة للتحكم في مقدار تغير المعلومات في الحالة المخفية ، تقوم وحدة GRU بنفس الغرض فقط من خلال بوابة إعادة التعيين. على الرغم من أن GRU مشابه جداً لـ LSTM ، لا ينبغي اعتباره حالة خاصة لـ LSTM. أدى وجود عدد أقل من المعاملات لكل GRU إلى تعقيد حسابي أقل ، وقد ثبت أن GRU يمكن أن تؤدي بشكل أفضل أو مشابه لـ LSTM في معظم المهام. بالطبع ، يبدو أن الأداء النسبي يعتمد على العمل المنجز. تعد GRU أكثر فائدة عندما تتوفر بيانات تدريب أقل بسبب قلة المعاملات. ومع ذلك ، مع زيادة عدد بيانات التدريب ، يفضل LSTM. يمكن رؤية مخطط خلية GRU في الشكل 2-31.

¹ Gated recurrent unit



الشكل 2-31 بوابة الاخراج

في ما يلي ، نشرح الرياضيات وراء عملية وحدة GRU خطوة بخطوة:

1. **بوابة التحديث:** أولاً ، يتم حساب بوابة التحديث z_t في الوقت t باستخدام المعادلة التالية:

$$z_t = \sigma(w_z x_t + U_z h_{t-1})$$

تحدد بوابة التحديث المعلومات التي يجب تجاهلها والمعلومات الجديدة التي يجب تخزينها ، بناءً على الإدخال x_t والحالة الكامنة السابقة h_{t-1} . عندما تكون x_t متصلة بالشبكة ، يتم ضربها بوزنها w_z . يتم أيضاً ضرب h_{t-1} بوزنه U_z ويتم إضافة الاثنين معاً. ثم تنتج دالة سيكمويد نتيجة بين 0 و 1. تساعد بوابة التحديث النموذج في تحديد مقدار المعلومات التي يجب نقلها في المستقبل. هذا سيمنع التدرج من التلاشي. لأن النموذج يمكن أن يقرر الحصول على نسخة من جميع المعلومات السابقة.

2. **بوابة إعادة التعيين:** تستخدم بوابة إعادة التعيين r_t خلية الحالة h_{t-1} وإدخال x_t لتحديد مقدار المعلومات السابقة التي يجب نسيانها. يتم حساب هذه الخطوة بالمعادلة التالية:

$$r_t = \sigma(w_r x_t + U_r h_{t-1})$$

3. **محتوى الذاكرة الحالي:** حان الوقت الآن للنظر في كيفية تحديد البوابات للإخراج. للقيام بذلك ، يتم أولاً حساب الذاكرة الجديدة التي تستخدمها بوابة إعادة التعيين لتخزين معلومات حول الماضي على النحو التالي:

$$\tilde{h}_t = \tanh(Wx_t + r_t \odot Uh_{t-1})$$

سيحدد هذا ما تمت إزالته من الخطوة السابقة. على سبيل المثال ، لنفترض في تحليل المشاعر النظرية حول كتاب ، الجملة: "هذا كتاب تاريخي ...". يظهر في بداية الفقرة وفي الفقرات التالية ، الجملة: "لم يعجبني هذا الكتاب لم يكن لديه تفاصيل كاملة". يأتي. الآن ، لتحديد مشاعر هذا الرأي ، نحتاج فقط إلى الجمل النهائية للنص. لذلك ، يمكن تعيين متجه r_t قريب من الصفر. سيؤدي هذا إلى مسح المعلومات السابقة والتركيز فقط على الجمل الأخيرة.

4. **الذاكرة النهائية:** في الخطوة الأخيرة ، قررت الشبكة تخزين معلومات الذاكرة الحالية ونقلها إلى الشبكة عن طريق حساب المتجه h_{t-1} . يتطلب هذا بوابة تحديث لتحديد المعلومات التي يجب جمعها من محتوى ذاكرة h_t الحالية و الخطوة السابقة h_{t-1} . يتم حساب هذه الخطوة بالمعادلة التالية:

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot h_t$$

كما رأينا ، كان GRU قادرًا على تخزين المعلومات وتصنيفها باستخدام بوابات التحديث وإعادة التعيين. أيضًا ، نظرًا لأن النموذج لا يغسل المدخلات الجديدة في كل مرة وينقلها إلى الخطوات التالية ، فلا توجد مشكلة في تلاشي الانحدارات.

في ما يلي ، سنقارن بإيجاز بين LSTM و GRU.

التشابه بين LSTM و GRU

- يحتوي كل من LSTM و GRU على وحدات تحديث بمكونات مضافة من t إلى $t + 1$ غير موجودة في RNN التقليدية.
- تحتفظ كل من وحدات LSTM و GRU بالمحتوى الحالي وتضيف محتوى جديدًا فوقه.
- تعمل LSTM و GRU على القضاء على مشكلة تلاشي الانحدار وانفجارها في RNN التقليدية.

الاختلاف بين LSTM و GRU

- تمتلك GRU بوابتين للتحديث وإعادة التعيين. في المقابل ، يحتوي LSTM على ثلاثة بوابات ، ادخال واخراج ونسيان. ليس لدى GRU بوابة إخراج مثل LSTM. تعمل بوابة تحديث GRU كمدخل وبوابة نسيان مشابهة لـ LSTM.
- معاملات GRU أقل ، لذا فهي أكثر كفاءة من الناحية الحسابية وتتطلب بيانات أقل للتعميم من LSTM.
- لا تحتوي GRU على ذاكرة داخلية (c_t) لتمييزها عن الحالة المخفية. من ناحية أخرى ، تحافظ LSTM على حالة الذاكرة الداخلية c .

آلة تورينج العصبية (NTM)¹

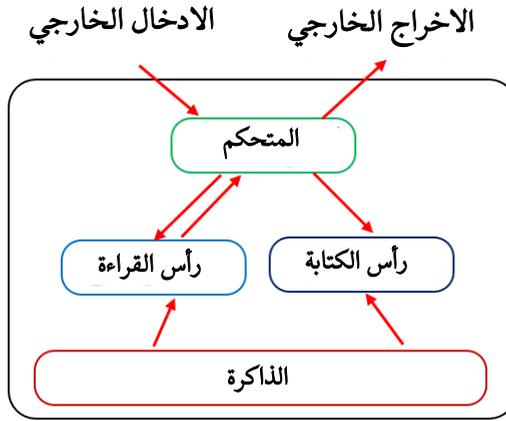
آلة تورينج العصبية هي المحاولة الأولى لبناء بنية التعلم العميق لتكون قادرة على تعلم الخوارزميات المطلوبة. تحاول آلة تورينج العصبية أن تصمم علم النفس المعرفي لـ "الذاكرة العاملة"² للسماح لها بالاقتراب من الطريقة التي يتعامل بها الشخص مع المشاكل. في هذه البنية ، تمت إضافة بنك ذاكرة خارجي إلى نظام يشبه LSTM للسماح لهندسة التعلم العميق باستخدام الذاكرة لحساب الوظائف المعقدة وتخزين المعلومات للمعالجة في نقاط الحوسبة المختلفة. مقارنة بهياكل RNN ذات الذاكرة الداخلية ، تستخدم آلة تورينج العصبية آلية الانتباه لقراءة وكتابة الذاكرة الخارجية بكفاءة. هذا يجعلها خياراً أفضل للاعتماد على المدى الطويل.

الفكرة الرئيسية لمعمارية تورينج العصبية هي فصل الحساب عن الذاكرة. يهدف هذا الفصل إلى تقليل الخلل في الشبكات العصبية المتكررة ، لأنه في الشبكات العصبية المتكررة ، مع زيادة قدرة الحالة الكامنة ، ينمو تعقيدها الحسابي بشكل كبير. تتكون بنية آلة تورينج العصبية من مكونين أساسيين: وحدة تحكم في الشبكة العصبية وبنك ذاكرة. يوضح الشكل 2-32 البنية عالية المستوى لآلة تورينج العصبية. مثل معظم الشبكات العصبية ، تتواصل وحدة التحكم مع العالم الخارجي من خلال متجهات المدخلات

¹ Neural Turing machine

² إنه مفهوم في الإدراك البشري يصف الاحتفاظ بالمعلومات في العقل وكيف يعمل ، على سبيل المثال عند التعامل مع مشكلة رياضية أو تفسير اللغة.

والمخرجات ، وعلى عكس الشبكة العصبية القياسية ، تحقق هذه الشبكة عمليات قراءة وكتابة انتقائية عن طريق الاتصال بين مصفوفة الذاكرة. الذاكرة عبارة عن مصفوفة $N \times W$ ، حيث N هو عدد مواقع الذاكرة (الصفوف) و W هو حجم المتجه في كل موقع. يتحكم في الواجهة بين الطبقات الأخرى للشبكة والذاكرة.



الشكل 2-32 البنية عالية المستوى لآلات تورينج العصبية

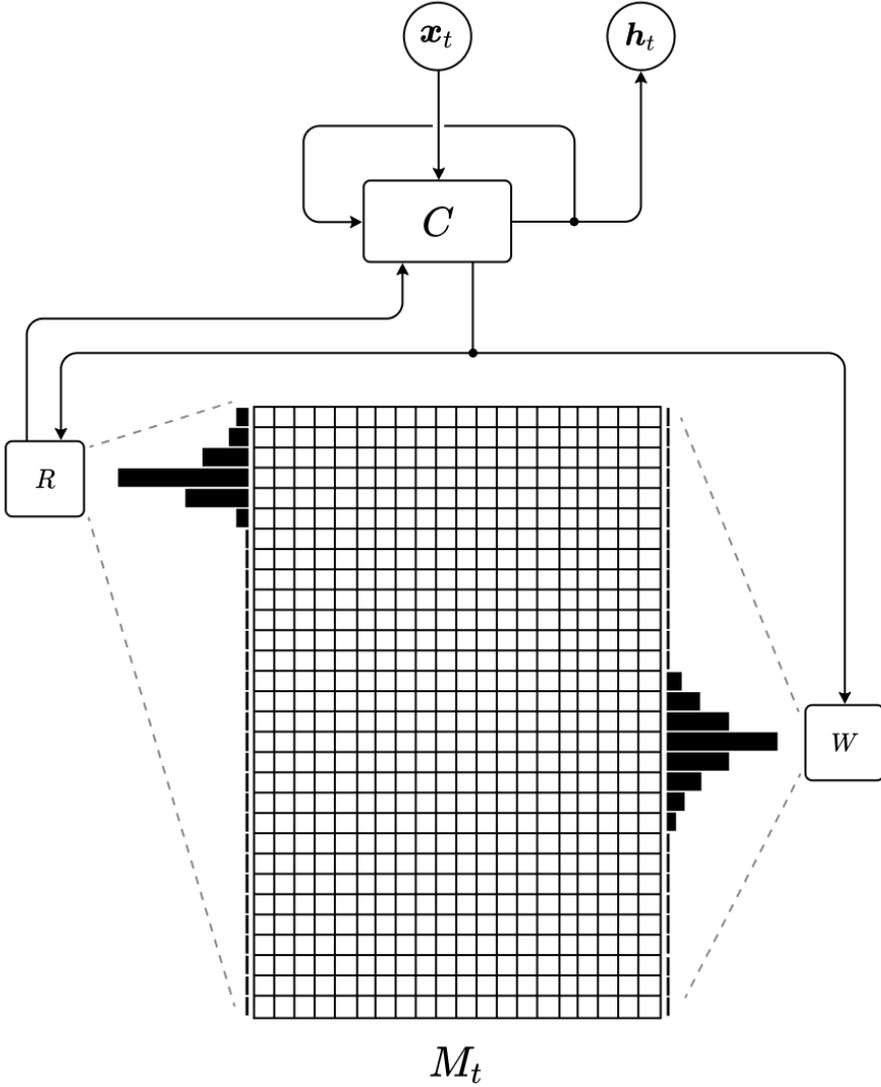
وحدة التحكم: وحدة التحكم عبارة عن شبكة عصبية توفر عرضاً داخلياً للمدخلات التي يستخدمها رأس القراءة والكتابة للتفاعل مع الذاكرة. بمعنى آخر ، إنها العلاقة بين بيانات الإدخال والذاكرة. يعد نوع وحدة التحكم أهم خيار في هندسة آلة تورينج العصبية. يمكن أن تكون وحدة التحكم هذه شبكة عصبية متكررة أو حتى شبكة عصبية أمامية التغذية.

آليات القراءة والكتابة: رأس القراءة والكتابة يجعل آلة تورينج ممتعة. إنها المكونات الوحيدة التي تتفاعل دائماً مع الذاكرة. بناءً على الأوامر الواردة من وحدة التحكم ، يختار الرأس موقعاً واحداً أو أكثر من مواقع الذاكرة للقراءة أو الكتابة من خلال الظهور في فتحات الذاكرة بدرجات متفاوتة.

في ما يلي ، سوف نولي اهتماماً بالتفاصيل الرياضية لكيفية قراءة وكتابة العمليات وكيفية إنشاء متجه* . لذلك ، في الشكل 2-33 ، يتم تقديم بنية الشبكة العصبية بطريقة أكثر ملاءمة للوصف. في هذا المخطط ، تمثل وحدة التحكم بالحرف C ، ومصفوفة الذاكرة

* لمزيد من التفاصيل وكيفية المعالجة، يمكنك الرجوع إلى هذا المصدر:

بالحرف M ، وأهداف القراءة والكتابة بالحرفين R و W ، و t يمثل كل خطوة ، و x_t والمدخلات في كل خطوة ، و h_t الحالة الحالية.



الشكل 2-33 بُنية آلة تورينج العصبية مع مزيد من التفاصيل

القراءة

افترض أن لدينا رأس قراءة R وذاكرة M_t في الوقت t . في مثالنا، تحتوي هذه الذاكرة على 4 فتحات ذاكرة منفصلة، كل منها يخزن متجهًا ثنائيًا خماسي الأبعاد. استنادًا إلى المدخلات الحالية من وحدة التحكم، تولد قراءة الرأس متجهًا قياسيًا للانتباه بقيم بين 0 و 1 وإجمالي المجموعة 1. يحدد الرأس مقدار التركيز المعطى لكل موقع. باستخدام هذه الأوزان، يمكننا تحديد إجراء القراءة بواسطة متجه r_t يمكنه القراءة من الذاكرة:

$$r_t = \sum_i w_t^r(i) M_t(i)$$

يمكن تصور هذه العملية على مرحلتين. أولاً، يتم ضرب كل عنصر من متجه الانتباه w_t^r في الصف المقابل في الذاكرة. ثانيًا، تتم إضافة الصفوف معًا لإنشاء متجه r_t للقراءة، كما هو موضح أدناه:

w_t^r	M_t	$w_t^r(i)M_t(i)$
0.7	0 1 0 1 1	0 0.7 0 0.7 0.7
0.2	1 0 1 1 0	0.2 0 0.2 0.2 0
0.05	0 1 1 1 0	0 0.05 0.05 0.05 0
0.05	1 1 0 1 1	0.05 0.05 0 0.05 0.05
		=
		\sum_i
		↓
		=
		r_t
		0.25 0.8 0.25 1 0.75

متجه القراءة هو نتيجة مجموع الأوزان لمحتويات الأماكن.

الكتابة

مستوحاة من LSTM، يمكن تقسيم عملية الكتابة إلى جزأين: الحذف والإضافة. في الوقت t ، لدينا رأس كتابة W مع أوزان الانتباه w_t^w ومصفوفة ذاكرة من الخطوة الزمنية السابقة M_{t-1} . قبل أن نتمكن من حذف المعلومات، يجب أن نحدد إلى أي مدى ينبغي

حذف كل عنصر من العناصر المخزنة. لهذا الغرض ، نقدم متجه الحذف بنفس أبعاد موقع ذاكرة الوحدة والقيم في النطاق $[0,1]$. يوجد كل عنصر خلية في موقع محدد ويشير إلى النسبة المئوية للخلية التي يجب حذفها. على سبيل المثال ، إذا كان أحد العناصر في e_t له قيمة 1 ، فسيتم حذف قيمة الخلية المقابلة في موقع الذاكرة تمامًا. اضرب الأوزان في متجه الحذف للحصول على مصفوفة بأبعاد مماثلة لذاكرتنا:

$$w_t^{w^T} \times e_t = w_t^{w^T} e_t$$

0.6
0.3
0.1
0

1	0.75	0.5	0.25	0
---	------	-----	------	---

0.6	0.45	0.3	0.15	0
0.3	0.23	0.15	0.075	0
0.1	0.075	0.05	0.025	0
0	0	0	0	0

يمثل كل صف من المصفوفة الناتجة إصدارًا مختلفًا من متجه الحذف الأصلي ، والذي يتم قياسه وفقًا لمقدار انتباه الرأس في ذلك الموقع. يمكننا تفسير هذه المصفوفة على أنها مرشح واضح. لأن محتوياته تصف النسبة المئوية لخلية ذاكرة معينة يجب حذفها. بطرحها من المصفوفة الثانية E يحولها إلى مرشح متبقي بتأثير معاكس.

$$E - w_t^{w^T} e_t = E - w_t^{w^T} e_t$$

1	1	1	1	1
1	1	1	1	1
1	1	1	1	1
1	1	1	1	1

0.6	0.45	0.3	0.15	0
0.3	0.23	0.15	0.075	0
0.1	0.075	0.05	0.025	0
0	0	0	0	0

0.4	0.55	0.7	0.85	1
0.7	0.77	0.85	0.93	1
0.9	0.93	0.95	0.98	1
1	1	1	1	1

لإنهاء خطوة الحذف ، نقوم ببساطة بحساب ضرب العناصر التي تم إنشاؤها بين المرشح وذاكرة الخطوة السابقة:

$$M_{t-1} \circ (E - w_t^w e_t) = \bar{M}_t$$

0	1	1	0	1
1	1	0	0	1
0	1	1	1	0
1	1	1	1	0

0.4	0.55	0.7	0.85	1
0.7	0.77	0.85	0.93	1
0.9	0.93	0.95	0.98	1
1	1	1	1	1

0	0.55	0.7	0	1
0.7	0.77	0	0	1
0	0.93	0.95	0.98	0
1	1	1	1	0

من وجهة نظر رياضية، يمكن التعبير عن الخطوات المذكورة أعلاه بالمعادلة التالية:

$$\bar{M}_t = M_{t-1} \circ [E - w_t^w e_t]$$

في هذه المعادلة، يتم حذف مصفوفة الذاكرة \bar{M}_t .

الخطوة التالية في عملية الكتابة هي إنشاء المعلومات التي تحتاج الذاكرة القديمة للتحديث بها. لتحقيق هذا الهدف، نقدم متجهًا a_t ونضربه في متجه الانتباه. هذه العملية تولد مصفوفة التحديث:

$$w_t^w e_t \times a_t = w_t^w e_t \circ a_t$$

0.6
0.3
0.1
0

1	1	1	1	1
---	---	---	---	---

0.6	0.6	0.6	0.6	0.6
0.3	0.3	0.3	0.3	0.3
0.1	0.1	0.1	0.1	0.1
0	0	0	0	0

مرة أخرى، يمثل كل صف من المصفوفة إصدارًا مختلفًا من المتجه الأصلي، والذي يتم قياسه وفقًا لقيمة رأس الانتباه في ذلك الموقع. أخيرًا، تنتهي عملية الكتابة بإضافة مصفوفة التحديث إلى الذاكرة التي تم حذفها:

$$\bar{M}_t + w_t^w e_t \circ a_t = M_t$$

0	0.55	0.7	0	1
0.7	0.77	0	0	1
0	0.93	0.95	0.98	0
1	1	1	1	0

0.6	0.6	0.6	0.6	0.6
0.3	0.3	0.3	0.3	0.3
0.1	0.1	0.1	0.1	0.1
0	0	0	0	0

0.6	1.1	1.3	0.6	1.6
1	1.1	0.3	0.3	1.3
0.1	1	1	1.1	0.1
1	1	1	1	0

يمكن التعبير عن العملية الكاملة لمرحلة الكتابة من خلال مجموعة المعادلات التالية:

$$\bar{M}_t = M_{t-1} \circ [E - w_t^w e_t]$$

$$M_t = \bar{M}_t + w_t^{wT} a_t$$

أو يمكن التعبير عنها به شكل أكثر إحكاما:

$$M_t = M_{t-1} \circ [E - w_t^{wT} e_t] + w_t^{wT} a_t$$

الشبكات العصبية الالتفافية¹ CNN

الصور هي نوع خاص من بيانات الإدخال. نحن نستخدم الصور للتواصل مع مجموعة متنوعة من الأشياء لأسباب مهنية واجتماعية وشخصية. من وضع علامات على وجه صديق إلى العثور عليه بسهولة أكبر في مجموعة من الصور إلى الحكم على ما إذا كانت صورة الأشعة حالة طبية تتطلب نظرة فاحصة. استخراج المعاني من الصور مهم جدا. في هذا القسم ، يتم استخراج معاني الصور باستخدام فكرة تسمى الالتفاف.

بالنسبة لبعض أنواع البيانات ، وخاصة الصور ، لا تعمل شبكات امامية التغذية بشكل جيد. كما ذكرنا سابقاً ، في شبكات امامية التغذية ، يتم توصيل كل خلية عصبية بشكل كامل بكل من الخلايا العصبية في الطبقة التالية. بتعبير أدق ، تحسب كل خلية عصبية في الطبقة المخفية دالة تعتمد على قيم كل عقدة في طبقة الإدخال. ومع ذلك ، في عمليات التعرف المرئية ، غالباً ما يكون من المفيد استخدام البنية التحتية المحلية في الصورة. على سبيل المثال ، البكسلات القريبة من بعضها في صورة ما (وحدات البكسل المتجاورة) مترابطة بشدة. ومع ذلك ، فإن البكسلات البعيدة في الصورة لها ارتباط أقل أو منعدمة. لذلك ، ليس من المستغرب أن تستند العديد من عروض الميزات المستخدمة في مشاكل رؤية الكمبيوتر إلى الميزات المحلية في الصورة. في بنية الشبكة العصبية الالتفافية ، نُشرك هذه البنية التحتية المحلية عن طريق تقييد كل خلية عصبية للاعتماد فقط على مجموعة فرعية محلية من متغيرات الطبقة السابقة.

¹ Convolutional Neural Networks

الميزة الثانية التي تميز الشبكة العصبية الالتفافية عن الشبكات العصبية التقليدية هي أن أوزان حافة الشبكة شائعة في الخلايا العصبية المختلفة في الطبقات المخفية. تؤكد من تذكر أن كل خلية عصبية في الشبكة تحسب أولاً مجموع الوزن الخطي من مدخلاتها. يمكننا أن نرى هذه العملية كتحسين لفلتر خطي على قيم الإدخال. في هذا السياق ، قسمة وزن العديد من الخلايا العصبية في طبقة مخفية اي تقييم فلتر في عدة نوافذ فرعية لصورة الإدخال. في هذا الصدد ، يمكننا أن نرى الشبكة العصبية الالتفافية كمجموعة تعليمية فعالة من الفلاتر ، كل منها ينطبق على جميع النوافذ الفرعية لصورة الإدخال. يؤدي استخدام نفس الفلاتر في جميع أنحاء الصورة إلى إجبار الشبكة على تعلم الترميز العام أو تمثيل البيانات الأساسية. ميزة أخرى لمشاركة الوزن هي أنها تقلل بشكل كبير من عدد المعاملات في الشبكة وتجعل التدريب أسهل وأكثر كفاءة.

قبل تطوير التعلم العميق في رؤية الكمبيوتر ، كان التعلم يعتمد على استخراج متغيرات مهمة تسمى السمات. ومع ذلك ، تتطلب هذه الأساليب الكثير من الخبرة في معالجة الصور. أحدثت الشبكات العصبية المترابطة التي أدخلها ليكان¹ ثورة في معالجة الصور وألغت استخراج الميزات يدوياً.

الشبكات العصبية الالتفافية هي نوع خاص من الشبكات العصبية في معالجة البيانات، والتي لها بنية مكانية محددة وشبكية. تربط هذه الشبكات المدخلات القريبة من بعضها مكانياً بطريقة مفيدة. على سبيل المثال ، يمكن اعتبار وحدات البكسل في الصور شبكات ثنائية الأبعاد. هذا الافتراض صحيح بالنسبة للصور ، لأن البكسلات المتقاربة ترتبط ارتباطاً وثيقاً ببعضها البعض. ظهرت الشبكات العصبية الالتفافية من دراسة القشرة البصرية للدماغ واستخدمت في التعرف على الصور منذ الثمانينيات. على مدى السنوات العديدة الماضية ، تمكنت شبكات CNN من تحقيق أداء خارق في بعض التطبيقات المرئية المعقدة ، وذلك بفضل زيادة قوة الحوسبة وزيادة بيانات التدريب.

لعبت الشبكات الالتفافية دوراً مهماً في تاريخ التعلم العميق. إنها مثال مهم ونجاح لفهمنا لدراسة الدماغ في تطبيقات التعلم الآلي. كانت الشبكات العصبية الالتفافية من

¹ LeCun

بين الشبكات العصبية الأولى التي تم استخدامها في حل وتنفيذ تطبيقات الأعمال المهمة، وحتى يومنا هذا فهي في طليعة تطبيقات الأعمال في التعلم العميق.

بُنية الشبكات العصبية الالتفافية

تتكون الشبكة العصبية الالتفافية من عدة طبقات: طبقة الالتفاف، وطبقة الدمج، والطبقة المتصلة بالكامل. في المستوى الأول من التعامل مع صورة الإدخال، عادة ما تتعلم الشبكة العصبية الالتفافية ميزات بصرية بسيطة مثل الحواف أو نقاط اللون. ثم، في المستوى الثاني، يجمع بين خصائص المستوى السابق. تؤدي إضافة المزيد من المستويات، اعتمادًا على البيانات وتطبيق المشكلة، إلى العثور على ميزات ذات مستوى أعلى مثل الوجه. في ما يلي، ندرس كل طبقة من الطبقات المكونة في بُنية الشبكة العصبية الالتفافية.

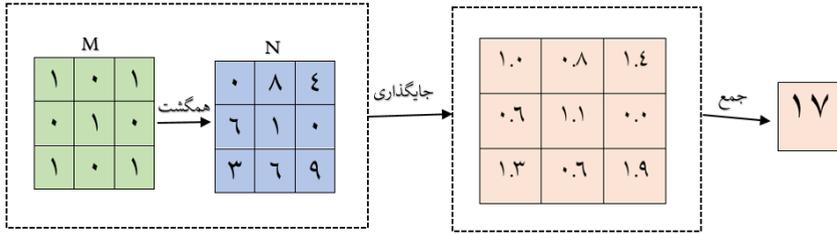
طبقة الالتفاف¹

تعد طبقة الالتفاف أهم جزء في CNN وتُستخدم دائمًا كطبقة أولى. هذه الطبقة هي المسؤولة عن معظم الحمل الحسابي. بشكل عام، CNN عبارة عن شبكة عصبية بها طبقة التفاف واحدة على الأقل في هيكلها. الالتفاف، في تعريفه الأكثر عمومية، هو أداء العمليات الحسابية على دالتين بقيم حقيقية. لتمثيل عامل الالتفاف، افترض أن المصفوفتين M و N تم تعريفهما على النحو التالي:

$$M = \begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix}, \quad N = \begin{bmatrix} 0 & 8 & 4 \\ 6 & 1 & 0 \\ 3 & 6 & 9 \end{bmatrix}$$

لا يمكن تطبيق عامل الالتفاف إلا على المصفوفات التي لها نفس عدد الصفوف والأعمدة. لكل من المصفوفات M و N، يتم إجراء عامل الالتفاف على النحو التالي:

¹ Convolutional Layer



تتمثل المهمة الرئيسية لطبقة الالتفاف في تحديد السمات (المعالم) الموجودة في المناطق المحلية لصورة الإدخال ، والتي تكون مشتركة لمجموعة البيانات بأكملها. يؤدي التعرف على الميزة هذا إلى إنتاج خريطة المعالم عن طريق تطبيق عوامل الفلتر. تطبق طبقة الالتفاف فلترًا محليًا على صورة الإدخال. ينتج عن هذا تصنيف أفضل لوحدات البكسل المجاورة الأكثر ارتباطًا في نفس الصورة. بمعنى آخر ، يمكن أن ترتبط وحدات البكسل الخاصة بالصورة المدخلة ببعضها البعض. على سبيل المثال ، في صور الوجه ، يكون الأنف دائمًا بين العينين والفم. عندما نطبق الفلتر على مجموعة فرعية من الصورة، فإننا نستخرج بعض السمات المحلية.

يشار إلى هذه الطبقة أيضًا باسم طبقة استخراج المعالم. لأنه يتم استخراج سمات الصورة في هذه الطبقة. هناك نوعان من المفاهيم الهامة في طبقة الالتفاف. ¹الخطوات والحشو². الخطوات هي عدد وحدات البكسل الأساسية أو الفلتر الذي يتحرك على مصفوفة الإدخال (حجم الفلتر يتحرك أفقيًا وعموديًا). يتم استخدام الحشو عندما لا يتناسب الفلتر مع مصفوفة الإدخال. هناك نوعان من الحشو: ³طبقات صالحة و ⁴طبقات موحدة أو صفر. في الطبقات الصالحة ، يتم تجاهل وحدات بكسل الإدخال لمصفوفة الإدخال. تضيف الطبقة الموحدة أصفاريًا إلى الهامش بحيث يلائم الفلتر مصفوفة الإدخال.

سنقوم الآن باختبار هذه الطبقة بمثال. هناك ثلاثة مكونات مهمة في طبقة الالتفاف:

- صورة الادخال

¹ strides

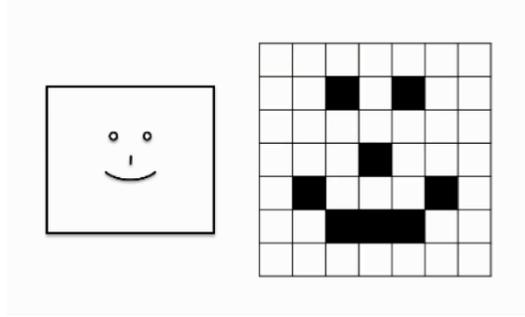
² padding

³ valid padding

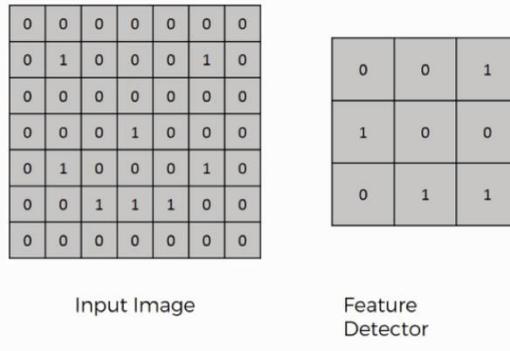
⁴ same padding

- كشف الميزات¹
- خريطة الميزات²

افتراض أن صورتنا الأصلية في الشكل 2-34. بعد تحويلها إلى نموذج إدخال ، كما هو موضح في الشكل 2-35 ، يظهر نمط الأصفار والآحاد وجهًا مبتسمًا.



الشكل 2-34 صورة الادخال



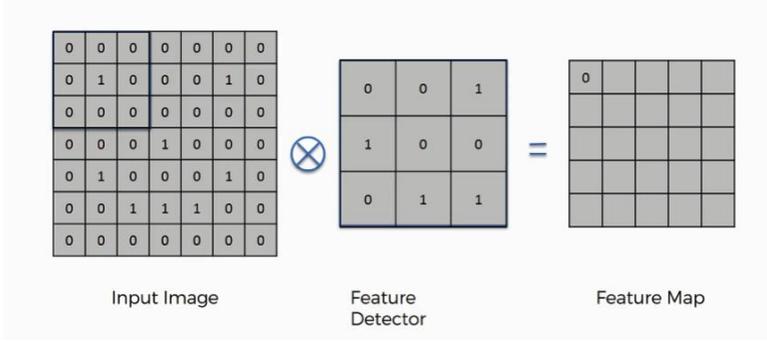
الشكل 2-35 الصورة المدخلة بعد التحويل

يستخدم الشكل 2-35 كاشف الميزة ، يشار إليه عادةً بالنواة أو الفلتر ، بقياس 3×3 . تُستخدم المصفوفة 3×3 هذه من الزاوية اليسرى العلوية للصورة كما هو موضح في الشكل 2-36 لعدد الخلايا التي يتطابق فيها كاشف الميزة مع صورة الإدخال. وبتطبيق عامل الالتفاف ، يتم الحصول على القيمة الأولى لخريطة البيانات الجدولية. ثم ينتقل كاشف الميزة إلى اليمين ويفعل الشيء نفسه لإكمال الصف الأول من خريطة المعالم.

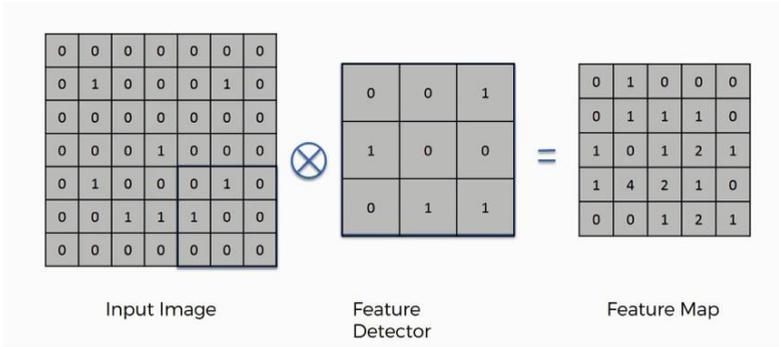
¹ Feature detector

² Feature map

بعد مغادرة الصف الأول ، انتقل إلى الصف التالي وكرر هذه العملية حتى تكتمل خريطة المعالم بالكامل. للحصول على الصورة 2-37.



الشكل 2-36 كيفية الحصول على خريطة الميزات



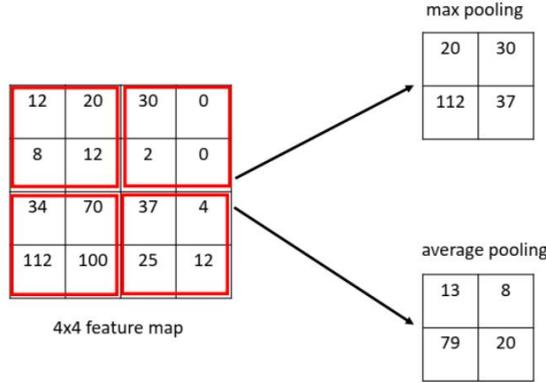
الشكل 2-37 خريطة الميزات

طبقة الدمج¹

عادة ما يتم استخدام طبقة الدمج بشكل دوري بين طبقتين متتاليتين من الالتفاف. وتتمثل مهمتها في تقليل حجم خرائط المعالم. بالإضافة إلى استخراج الميزات المهمة في خريطة المعالم ، فإن هذا يقلل أيضاً من القوة الحاسوبية المطلوبة لمعالجة البيانات عن طريق تقليل كمية المعاملات. هناك طبقتان مهمتان من طبقات الدمج: الحد الأقصى

¹ Pooling Layer

من الدمج¹ ومتوسط الدمج². يمكن رؤية الفرق بين الاثنين في الشكل 2-38. الحد الأقصى من الدمج له أداء أفضل في استخراج الميزات المهيمنة والمهمة.



الشكل 2-38 الفرق بين الحد الأقصى من الدمج ومتوسط الدمج

الطبقة المتصلة بالكامل³

تتكون الشبكات العصبية الالتفافية من مرحلتين رئيسيتين: مرحلة استخراج الميزات ومرحلة التصنيف. طبقات الالتفاف والدمج مسؤولة عن استخراج الميزات. تعمل الطبقة المتصلة بالكامل في الشبكة العصبية الالتفافية مثل الطبقات المخفية للشبكة العصبية القياسية وتقع في نهاية الشبكة العصبية الالتفافية. هذه الطبقة هي بالضبط المكان الذي يحدث فيه التصنيف. بعد استخدام عدة طبقات مختلفة، يمكن استخدام الطبقة المتصلة بالكامل في نهاية شبكة CNN لحساب الميزات المرغوبة ودرجات الإخراج. الإخراج هو متجه N بعدي حيث يشير N إلى عدد الفئات. على سبيل المثال، نريد إجراء تصنيف بين الطيور وغروب الشمس والكلب والقط. تصبح قيمة N في هذا المثال 4. يشير كل رقم في المتجه إلى احتمال وجود فئة معينة. تحدد الطبقة المتصلة بالكامل السمة الأكثر صلة بفئة معينة. على سبيل المثال، في صورة طائر، توجد قيم عالية المستوى في خريطة المعالم تمثل ميزة جناح الطائر. افترض أن قيم المتجه التي تم الحصول عليها في هذه الطبقة هي كما يلي:

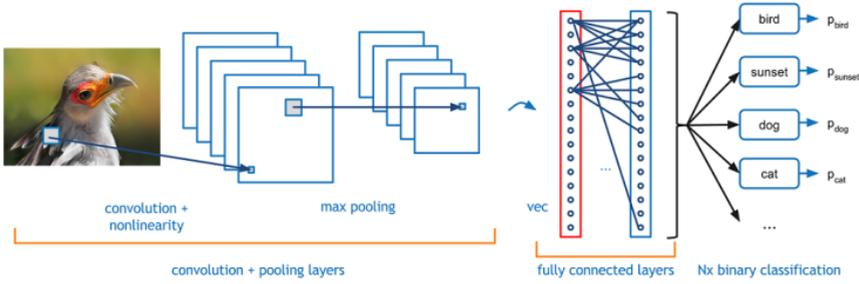
¹ Max Pooling

² Average Pooling

³ Fully connected Layer

$$[0.4, 0, 0.003, 0.87]$$

تظهر هذه النتائج أن هناك احتمال بنسبة 0.87% أن تكون الصورة لطائر. يوضح الشكل 2-39 مثالاً لشبكة عصبية التفاضلية في تصنيف الصور.



الشكل 2-39 مثال على الشبكة العصبية التفاضلية في تصنيف الصور

الحشو والخطوات

في كثير من الحالات ، نستخدم طرق الحشو والخطوات المتقاربة التي تؤثر على حجم المخرجات. نظراً لأن الفلاتر يبلغ ارتفاعها وعرضها أكثر من 1 ، فإن استخدام الالتفاف المستمرة يقلل بشكل كبير من المخرجات بالنسبة للإدخال. على سبيل المثال، إذا بدأنا بصورة 240×240 بكسل. تصغر 10 طبقات التفاف 5×5 الصورة إلى 200×200 بكسل. والنتيجة هي قطع 30% من الصورة وإزالة المعلومات الشيقة داخل حدود الصورة الأصلية. تعد الحشو هي الأداة الأكثر شيوعاً لحل هذه المشكلة ، ويتمثل حلها في إضافة وحدات بكسل حشو إضافية حول حدود صورة الإدخال. عادةً ما نضبط قيم هذه البكسلات على صفر. في حالات أخرى ، قد نرغب في تقليل البعد بشكل كبير (على سبيل المثال ، إذا كانت دقة صورة الإدخال الأصلية ليست جيدة). خطوات الالتفاف هي الطريقة الأكثر شيوعاً للمساعدة في ذلك.

يمكن استخدام الخطوات والحشو بشكل فعال لضبط أبعاد البيانات

التدريب في CNN

تشبه عملية التحسين على CNN تلك الخاصة بالشبكات العصبية للتغذية الامامية. وبالمثل ، يتم تعلم معاملات الشبكة عن طريق خوارزمية الانتشار الخلفي وتحسين الانحدار الاشتقاقي. المرحلة الأولى هي الانتشار الأمامي ، حيث تنتشر الإشارات من مدخلات الشبكة إلى الخرج. في الطبقة الأخيرة ، تتم مقارنة الإخراج بواسطة دالة التكلفة بالقيمة المطلوبة ويتم تقدير الخطأ. في المرحلة الثانية ، يتم استخدام خوارزمية الانتشار الخلفي مرة أخرى لتعويض هذا الخطأ. ومع ذلك ، فإن عملية التعلم في الشبكة العصبية الالتفافية أكثر تعقيداً مما هي عليه في الشبكة العصبية للتغذية الامامية ، حيث تتكون من أنواع مختلفة من الطبقات ، وتتبع مرحلتا الانتشار الأمامي والخلفي قواعد محددة في كل طبقة. الخلايا العصبية في الشبكة العصبية الالتفافية لها وزن مشترك ، على عكس الشبكة العصبية أمامية التغذية، حيث يكون لكل خلية عصبية متجه وزن منفصل. يؤدي تقاسم الأوزان هذا إلى تقليل إجمالي عدد الأوزان القابلة للتدريب.

الانتشار الامامي في طبقة الالتفاف

كل طبقة التفاف تدور حول مدخلاتها في حالة تطبيق عامل الالتفاف. بافتراض أن مدخلات الطبقة هي $N \times N$ وأن فلترها هو $M \times M$. الالتفاف دون استخدام التسلسل الصفري $(N - m + 1) \times (N - m + 1)$ وحساب الالتفاف الناتج x_{ij}^l سيكون على النحو التالي:

$$x_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \omega_{ab} y_{(i+a)(j+b)}^{l-1}$$

حيث $l, i, j \in (0, n - m + 1)$ هو مؤشر الطبقة الحالية، ω_{ab} وزن الفلتر و $y_{(i+a)(j+b)}^{l-1}$ هو ناتج الطبقة السابقة.

بعد ذلك ، يتم حساب ناتج طبقة الالتفاف y_{ij}^l من خلال تطبيق دالة تنشيط غير خطية على خرج الالتفاف x_{ij}^l :

$$y_{ij}^l = \sigma(x_{ij}^l)$$

حيث σ هي دالة تنشيط غير خطية.

الانتشار الخلفي في طبقة الالتفاف

يتبع الانتشار الخلفي في طبقة الالتفاف نفس مبادئ خوارزمية الانتشار الخلفي الموضحة في الفصل الثاني. الاختلاف الوحيد هو أن فلتر الالتفاف يشترك في وزن الطبقة بأكملها ولا يوجد تحيز في الفلتر. إذا افترض أن قيمة دالة الخطأ هي E ، فيجب حساب تأثير وزن الفلتر على دالة التكلفة، بالنظر إلى مقدار الخطأ في طبقة الالتفاف والمشتق الجزئي لخطأ الطبقة السابقة فيما يتعلق بكل خلية عصبية انتاج:

$$\frac{\partial E}{\partial w_{ab}} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial E}{\partial x_{ij}^l} \frac{\partial x_{ij}^l}{\partial w_{ab}}$$

لأننا كان لدينا:

$$x_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \omega_{ab} y_{(i+a)(j+b)}^{l-1}$$

ينتج عن ذلك:

$$\frac{\partial x_{ij}^l}{\partial w_{ab}} = y_{(i+a)(j+b)}^{l-1}$$

لذلك لدينا:

$$\frac{\partial E}{\partial w_{ab}} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial E}{\partial x_{ij}^l} y_{(i+a)(j+b)}^{l-1}$$

لحساب الانحدار الاشتقاقي، نحتاج إلى معرفة القيمة $\frac{\partial E}{\partial x_{ij}^l}$ ، والتي تسمى غالباً دلتا. حساب دلتا بسيط نسبياً. نحن نستخدم قانون السلسلة:

$$\frac{\partial E}{\partial x_{ij}^l} = \frac{\partial E}{\partial y_{ij}^l} \frac{\partial y_{ij}^l}{\partial x_{ij}^l} = \frac{\partial E}{\partial y_{ij}^l} \frac{\partial}{\partial x_{ij}^l} (\sigma(x_{ij}^l)) = \frac{\partial E}{\partial y_{ij}^l} \sigma'(x_{ij}^l)$$

كما يمكن رؤيته، نظراً لأن خطأ الطبقة الحالية $\frac{\partial E}{\partial y_{ij}^l}$ قد تم تقديمه بالفعل ونعرف قيمتها، يمكننا بسهولة حساب دلتا $\frac{\partial E}{\partial x_{ij}^l}$ في الطبقة الحالية فقط وذلك باستخدام مشتق دالة

التنشيط $\sigma(x)$. نظراً لأننا نعرف الأخطاء في الطبقة الحالية ، فلدينا الآن كل ما نحتاجه لحساب الانحدار الاشتقاقي ، بالنظر إلى الأوزان المستخدمة بواسطة طبقة الالتفاف هذه. بالإضافة إلى ذلك ، لحساب وزن طبقة الالتفاف هذه ، نحتاج إلى نقل الأخطاء إلى الطبقة السابقة. يمكننا استخدام قانون السلسلة مرة أخرى:

$$\frac{\partial E}{\partial y_{ij}^{l-1}} = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \frac{\partial E}{\partial x_{(i-a)(j-b)}^l} \frac{\partial x_{(i-a)(j-b)}^l}{\partial y_{ij}^{l-1}}$$

من المعادلة:

$$x_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \omega_{ab} y_{(i+a)(j+b)}^{l-1}$$

يتضح ان $\omega_{ab} = \frac{\partial x_{(i-a)(j-b)}^l}{\partial y_{ij}^{l-1}}$ لذلك لدينا:

$$\frac{\partial E}{\partial y_{ij}^{l-1}} = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \frac{\partial E}{\partial x_{(i-a)(j-b)}^l} \omega_{ab}$$

تعطينا هذه القيمة خطأ الطبقة السابقة.

أسباب استخدام CNN لتصنيف الصور

هناك عدة أسباب لاستخدام CNN بدلاً من بيرسيبترون متعددة الطبقات لتصنيف الصورة:

- عادةً ما تؤدي الصورة كمدخلات إلى طبقات كبيرة جداً ، لأن كل بكسل هو قيمة إدخال. إذا تم استخدام شبكة عصبية عادية فقط ، فإن الاتصال الكامل بين الطبقات يتطلب قدرًا كبيرًا من الذاكرة لتخزين الأوزان. في طبقة الالتفاف لا يوجد اتصال كامل ، على النقيض من ذلك هناك اتصال مبعثر. ينتج عن هذا الاتصال المبعثر ترابط أقل من الطبقة المترابطة بالكامل ، مما يؤدي إلى تخزين وزن أقل.

- في طبقة متصلة بالكامل ، يكون كل وزن مستقلاً عن الآخر ، مما ينتج عنه كميات كبيرة من تخزين وتسوية قيم كثيرة. ومع ذلك ، في الطبقة الالتفافية ، تكون الأوزان مشتركة لأن الأوزان هي القيم في الفلتر. في كل مرة يتم إجراء تبديل لمنطقة معينة من الإدخال ، يتم إجراؤه بنفس الفلتر ، وبالتالي تكون الأوزان هي نفسها.
- من الممكن استخدام نوى متعددة في الطبقة الالتفافية. يمكن استخدام النواة كفلتر لاكتشاف نمط صغير معين في صورة الإدخال. باستخدام نوى متعددة ، يمكن البحث في أنماط صغيرة متعددة في وقت واحد.

بُنْيَة CNN

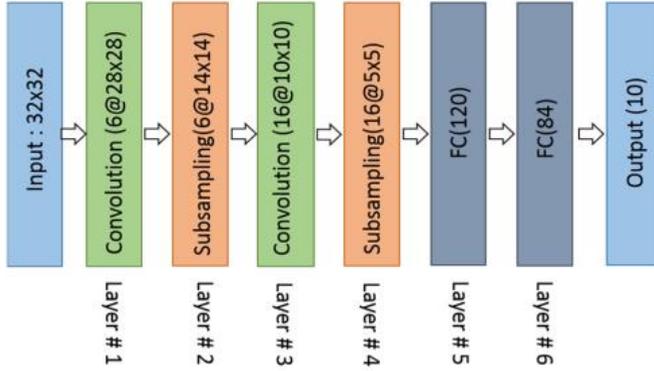
في هذا القسم ، نراجع بعض بُنْيَة CNN.

LeNet

تم تصميم LeNet في عام 1998 ، وكان أول بُنْيَة قائمة على الالتفاف تستخدم خوارزمية الانتشار الخلفي للتدريب على الشبكة. تم تصميم هذه البُنْيَة لتصنيف المستندات المكتوبة بخط اليد. على الرغم من أن البُنْيَة قامت بعمل جيد ، إلا أنها لم تكن ناجحة جداً في ذلك الوقت وظلت في الغموض لعقود من الزمن بعد تقديمها ، حيث واجهت المشاكل التالية:

- مجموعات البيانات ذات العلامات القليلة.
- أجهزة الكمبيوتر البطيئة.
- استخدام دالة التنشيط غير الخطية الخاطئة.

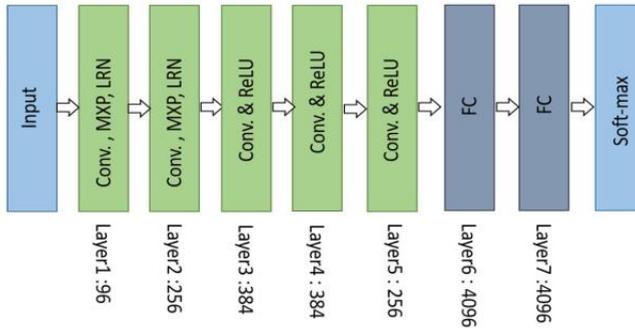
در شكل 1-40 معمارى LeNet قابل مشاهدته است.



الشكل 2-40 بُنية LeNet

AlexNet

في عام 2012، قدم أليكس كريشوفسكي¹ وزملاؤه نموذج AlexNet. كان هذا النموذج قادراً على الفوز بأصعب تحدي ImageNet يسمى تحدي الكشف البصري واسع النطاق (ILSVRC) وكان نجاحاً كبيراً في ذلك الوقت. خفض هذا النموذج معدل الخطأ من 26٪ إلى 15٪. كان هذا تقدماً كبيراً في اكتشاف وتصنيف رؤية الآلة. هذه نقطة في التاريخ نما فيها الاهتمام بالتعلم العميق بسرعة. تظهر بنية AlexNet في الشكل 2-41.

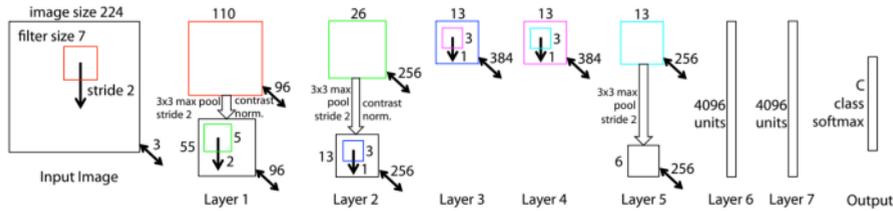


الشكل 2-41 بُنية AlexNet

¹ Alex Krizhevsky

ZFNet

ZFnet هو نسخة محسّنة من AlexNet تم تقديمه في 2013 عن طريق زايلر¹ وزملاؤه. مقارنةً بـ AlexNet ، قللت هذه البنية حجم الفلتر من 11×11 إلى 7×7 في الطبقة الأولى واستخدمت الخطوة 2 بدلاً من 4 ، مما قلل بشكل كبير من عدد المعاملات وزاد الدقة من خلال استخراج المزيد من المعالم المميزة. كان السبب الرئيسي لشعبية هذه البنية هو فهم أفضل لكيفية عمل CNN. يمكن رؤية بنية هذه الطريقة في الشكل 2-42.



الشكل 2-42 بنية AlexNet

تحديات CNN

على الرغم من أن شبكات CNN العميقة قد حققت أداءً جيداً في معالجة البيانات المهيكلية مكانياً ، إلا أن هناك بعض التحديات التي تواجه عملية التدريب لهذه الشبكات ، والتي تم سردها أدناه:

- تشبه شبكات CNN العميقة بشكل عام الصندوق الأسود ، لذا لا يوجد تفسير لها. لذلك ، أحياناً يصعب دراستها.
- يمكن أن يؤدي تدريب CNN على بيانات الصور عالية الضوضاء إلى زيادة خطأ التصنيف. يمكن أن تؤدي إضافة قدر صغير من الضوضاء العشوائية إلى صورة الإدخال إلى خداع الشبكة إلى تصنيف مختلف.
- تعتمد شبكات CNN العميقة على التعلم الخاضع للإشراف ، لذا فهم بحاجة إلى بيانات ضخمة للتعلم بشكل صحيح.

¹ Zeiler

- اختيار المعامل الفائق المناسب له تأثير كبير على أداء CNN.
- يتطلب تدريب CNN الفعال موارد أجهزة قوية مثل وحدة معالجة الرسومات (GPU).

خلاصة الفصل الثاني

- ◆ يحدث التعلم في الشبكة العصبية عن طريق تغيير الأوزان المرتبطة بالخلايا العصبية.
- ◆ أبسط شكل هو الشبكة العصبية بيرسيبترون وهو مصنف ثنائي.
- ◆ تعد الشبكات امامية التغذية العميقة واحدة من أكثر شبكات التعلم العميق استخداماً نظراً لعدم وجود قيود على المدخلات.
- ◆ تلعب دالة المنشط دوراً مهماً ورئيسياً في بنية الشبكة العصبية.
- ◆ تحدد دالة التنشيط الخلايا العصبية التي يجب أن تكون نشطة أو غير نشطة.
- ◆ تحدد دالة الخسارة مدى قرب الشبكة المدربة من المعيار المثالي.
- ◆ يعتبر تهيئة القيم الأولية للأوزان خطوة مهمة في بناء شبكة عصبية لتحقيق أفضل أداء.
- ◆ يحاول محسنوا الشبكة العميقة تقليل دالة الخسارة عن طريق تحديث الأوزان في الشبكة.
- ◆ يعد الانحدار الاشتقاقي أحد أكثر خوارزميات التحسين شيوعاً في الشبكات العصبية العميقة.
- ◆ تسمى الخوارزمية المستخدمة لمعرفة الأوزان في الشبكة خوارزمية الانتشار الخلفي. يتم تنفيذ هذه الخوارزمية على مرحلتين ، امامية وعكسية.
- ◆ يواجه التدريب على الشبكة العميقة تحديات مثل مشكلة تلاشي التدرجات وانفجارها ، والضبط الزائد وحجم مجموعات التدريب .

- ◆ التسوية هو نهج عملي لتجنب الضبط الزائد.
- ◆ أحدثت الشبكات العصبية الالتفافية ثورة في معالجة الصور عن طريق استخراج الميزات تلقائياً.
- ◆ تلعب الشبكات العصبية الالتفافية دوراً مهماً في تاريخ التعلم العميق.
- ◆ تتكون الشبكة العصبية الالتفافية من ثلاث طبقات: الالتفاف والدمج وملتصلة بالكامل.
- ◆ تتمثل المهمة الرئيسية للطبقة الالتفافية في تحديد الميزات الموجودة في المناطق المحلية للصورة المدخلة. تسمى طبقة الالتفاف طبقة استخراج المعالم.
- ◆ طبقة الدمج مسؤولة عن تقليل حجم خريطة المعالم.
- ◆ تحدث مرحلة التصنيف في الشبكات العصبية المترابطة في الطبقة المتصلة بالكامل.
- ◆ تم تصميم الشبكات العصبية المتكررة لمعالجة البيانات المتسلسلة.



أسئلة للمراجعة

1. قم بتسمية الطبقات المختلفة في شبكات التغذية العميقة ووصف استخدام كل منها.
2. كيف يتم تحديد عدد الخلايا العصبية في طبقة إدخال الشبكة؟
3. كيف يتم تحديد عدد الخلايا العصبية في الطبقة المخفية؟
4. كيف يتم تحديد عدد الخلايا العصبية في طبقة الإخراج؟
5. ما هي بعض الأمثلة على دوال التنشيط في التعلم العميق؟
6. ما الخطأ في تعيين أوزان الشبكة إذا تم ضبط جميع القيم على صفر؟
7. ما سبب تفضيل الانحدار الاشتقاقي العشوائي على الانحدار الاشتقاقي؟
8. ما هي بعض الأمثلة على خوارزميات التحسين ذات معدل التعلم التكيفي؟
9. ما الذي يسبب تلاشي التدرجات وانفجار التدرجات؟ ما هي السبل للهروب من هذه المشاكل؟

10. ما الذي يسبب الضبط الزائد في الشبكات العصبية؟
11. ما فائدة التسوية بالدفعات في الشبكات العميقة؟
12. لماذا يتم استخدام الحشوفي الشبكات العصبية الالتفافية؟
13. سمي طبقتين من طبقات الدمج؟
14. يتم استخراج الميزات في أي طبقات من الشبكة العصبية الالتفافية؟
15. ما سبب استخدام الشبكات العصبية الالتفافية في تصنيف الصور؟
16. ماهي مشاكل الشبكة العصبية المتكررة البسيطة؟
17. ماهي أنواع بُنى الشبكة العصبية المتكررة وما تطبيق كل منها؟
18. ما هي أنواع البوابات في بُنية LSTM ووصف وظيفة كل منها؟

الفصل 3

التعلم التمثيلي غير الخاضع للإشراف العميق: المشفرات الذاتية والنماذج الانتاجية

الأهداف :

- التعرف على كيفية عمل المشفرات الذاتية وأنواعها.
- الفرق بين النماذج القابلة للفصل والنماذج الإنتاجية
- التعرف على مجموعة متنوعة من نماذج التوليد العميق
- سبب استخدام التعلم العميق في المسائل.

المقدمة

يرجع النجاح المذهل للتعلم العميق إلى حد كبير إلى الخوارزميات الخاضعة للإشراف. من أجل تحقيق أداء جيد ، يتطلب تدريب هذه الشبكات الكثير من مجموعات البيانات المصنفة. تكمن المشكلة في أن الحصول على مجموعة البيانات الموسومة على نطاق واسع لا يمكن الوصول إليه بالضرورة ، كما أن عملية التعليق التوضيحي تستغرق وقتاً طويلاً وتتطلب معرفة المجال بالموضوع.

على الرغم من نجاح التعلم الخاضع للإشراف في السنوات الأخيرة ، في الأيام الأولى من دورة التعلم العميق ، أظهر هينتون وزملاؤه نتائج مقبولة في تقليل الأبعاد باستخدام المشفرات الذاتية. وبالتالي ، أدى نجاح التعلم الخاضع للإشراف في القضايا الأساسية ، مثل التعرف على الكلام وتصنيف الصور ، إلى زيادة اهتمام مجتمع البحث بهذا النوع من التعلم ، بينما تم إهمال التعلم غير الخاضع للإشراف إلى حد ما.

في الآونة الأخيرة ، ظهر اهتمام متجدد بالتعلم غير الخاضع للإشراف مع إدخال نموذجين جديدين للتوليد العميق ، وهما شبكة الخصومة التوليدية وشبكة المشفر الذاتي المتغير. من المتوقع أن يلعب التعلم غير الخاضع للإشراف دوراً مهماً في مستقبل التعلم العميق. تجدر الإشارة إلى أن التعلم غير الخاضع للإشراف لا يزال يمثل مجالاً صعباً للغاية ، وفي كثير من الحالات ، من المرجح أن يستخدم الباحثون الأساليب الخاضعة للإشراف. ومع ذلك ، من المثير للاهتمام ملاحظة أن الطريقة البشرية للرد على الملاحظات غير المتوقعة للعالم تشبه إلى حد بعيد طريقة التعلم غير الخاضع للإشراف. أخيراً ، وفقاً لما ذكره يانلكان¹ ، "الثورة القادمة في الذكاء الاصطناعي غير خاضعة للإشراف".

التعلم النشط والتعلم التمثيلي بدون إشراف

يعد التعلم التمثيلي مجالاً نشطاً في التعلم الآلي الذي يهدف إلى الحصول على تمثيل مفيد للبيانات ، ولأنه يمكن تفسيره على أنه تعلم ميزات مفيدة ، فإنه يُعرف أيضاً باسم

¹ <https://engineering.nyu.edu/news/revolution-will-not-be-supervised-promises-facebooks-yann-lecun-kickoff-ai-seminar>

تعلم الميزة. غالبًا ما يكون الدافع وراء هذه الأساليب هو العثور على تمثيل جيد للبيانات لاستخدامه في مشاكل التصنيف والانحدار لطريقة مؤتمتة ومعقدة. ركز العمل الأخير في مجال التعلم العميق على تطوير الخوارزميات التي يمكنها تلقائيًا تعلم التمثيلات الأساسية أو الميزات من البيانات نفسها. الشبكات العصبية العميقة، على سبيل المثال، يمكن اعتبارها تعلمًا خاضعًا للإشراف؛ التعلم الهرمي للتمثيلات الموزعة التي تشبه الطبقات المخفية ويتم إنشاؤها من التمثيلات منخفضة المستوى إلى التمثيلات عالية المستوى لتحقيق الهدف النهائي الخاضع للإشراف. في حالة الخوارزميات غير الخاضعة للإشراف، يتم تعلم هذه الميزات من البيانات غير المسماة. من بين الخوارزميات المختلفة المعروفة لتعلم التمثيل غير الخاضع للإشراف، المشفرات الذاتية والآت بولتزمان.

تتطلب معظم نماذج التعلم الآلي الخاضعة للإشراف كميات كبيرة من البيانات للتدريب وتحقيق نتائج جيدة. في معظم الحالات، يتم تزويد الباحثين في علم البيانات بمجموعة كبيرة من البيانات غير المصنفة ويطلب منهم تدريب نماذج جيدة الأداء. يشكل تصنيف كميات كبيرة من البيانات يدويًا تحديًا كبيرًا. هذا هو المكان الذي يكون فيه التعلم النشط مفيدًا. التعلم النشط هو مجال من مجالات التعلم الآلي الذي يتعامل مع الموقف الذي يستغل مشكلة البيانات غير المسماة من خلال تحديد أولويات البيانات التي يجب تسميتها من أجل جعل النموذج أكثر فعالية. بمعنى آخر، التعلم النشط هو تحسين نقاط البيانات التي يجب تحديدها لوضع العلامات وتدريب النموذج.

على الرغم من التطورات الحديثة في التعلم التمثيلي الخاضع للإشراف، فإن السؤال الذي يطرح نفسه؛ هل من الممكن الحصول على تمثيل "قوي" لهذا النهج من البيانات غير المسماة دون أي إشراف؟ يمكن الإجابة على هذا السؤال بالإيجاب، لأنه يمكن تعلم العديد من الأشياء (الميزات المفيدة) من البيانات غير المسماة، وخاصة البيانات الكبيرة الشبيهة بالصور (يتم عرض بيانات الصورة بشكل عام بقيم البكسل ويتم إخفاء معظم المعاني فيها). يمكننا استخدام طرق غير خاضعة للإشراف لتعلم العروض غير المسماة بشكل أفضل (غالبًا ما يكون الحصول عليها أسهل بكثير) حتى قبل استخدام سيناريو التعلم النشط للحصول على علامة للتعلم الإشرافي. هناك العديد من الطرق للعمل مع البيانات غير المسماة. في هذا الفصل، نركز على الفرضية القائلة بأنه يمكن استخدام البيانات غير المسماة للتعلم التمثيلي الجيد. يعد التعلم غير الخاضع للإشراف أحد

مجالات البحث النشطة في التعلم الآلي ويعتبر حلها خطوة مهمة في تطوير الذكاء الاصطناعي العام. فيما يلي، سوف ندرس المناهج غير الخاضعة للإشراف للتعلم العميق.

المشفرات الذاتية

في الشبكات العصبية الاصطناعية ، تم تطوير الانتشار الخلفي لتحسين التعلم التمثيلي. تتضمن عملية الانتشار الخلفي إعادة ترتيب الأوزان اعتماداً على المخرجات المتوقعة. في الثمانينيات ، تم تقديم المشفرات الذاتية لإعادة نشرها بدون معلم. وهذا يعني أن المشفرات الذاتية توفر طريقة لتعلم الميزات تلقائياً من البيانات غير المصنفة التي تسمح بالتعلم غير الخاضع للإشراف. في الشبكات العصبية التي تمت مناقشتها حتى الآن ، كانت هناك حاجة إلى البيانات ذات العلامات لتكون بمثابة أمثلة لتدريب ضرورية لضبط الانتشار الخلفي ، حيث تُستخدم هذه العلامات لإعادة تعيين المعاملات. ومع ذلك ، توفر المشفرات الذاتية فرصة للتعلم دون الاعتماد على البيانات المصنفة.

تؤدي الشبكة العصبية ذاتية التشفير الانتشار الخلفي عن طريق ضبط قيم الإخراج المستهدفة التي تساوي قيم الإدخال ، وبالتالي تدريب المشفر الذاتي لتقليل الاختلاف بين البيانات وإعادة بنائها (أي الفرق بين متجه الإخراج الفعلي ومتجه الإخراج المتوقع، حيث يكون الناتج المتوقع هو نفسه متجه الإدخال). نتيجة لذلك ، يمكن للمشفرات الذاتية التعلم بدون معلم (مشرف).

بشكل عام ، المشفر الذاتي هو نوع من الشبكات العصبية الاصطناعية التي تحاول محاكاة أكبر قدر ممكن من المخرجات من خلال تلقي المدخلات قدر الإمكان. الهدف هو إعادة بناء المدخلات الرئيسية بأكبر قدر ممكن من الدقة (بدلاً من محاولة التنبؤ بنتيجة محددة ، يحاولون إعادة بناء المدخلات الخاصة بهم). بمعنى آخر ، يقوم بنسخ الإدخال. عادةً ما يتم تقييد المشفرات الذاتية بطريقة تسمح فقط بنسخها. نظراً لأنه يتعين على النموذج تحديد أولويات سمات الإدخال التي يجب نسخها ، فإنه غالباً ما يتعلم سمات البيانات المفيدة. ظاهرياً ، قد يبدو إنشاء نسخة من المدخلات إلى المخرجات (إخراج الشبكة يساوي الإدخال) مهمة تعليمية غير مهمة ، لكننا سنرى أنها ليست كذلك. الفكرة هي أنه بالإضافة إلى تدريب الشبكة على النسخ من المدخلات إلى المخرجات ، يتم تطبيق بعض القيود.

القيود الشائع هو وضع عنق الزجاج في منتصف الشبكة. يتم إعطاء هذا الاختناق بعداً أصغر بكثير من المدخلات والمخرجات. هذا يفرض على الشبكة عدم نقل المدخلات فقط إلى المخرجات وعدم الحصول على جميع المعلومات الموجودة في الإدخال. يمكن اعتبار طبقة عنق الزجاج نسخة مضغوطة من الإدخال. تسمى هذه النسخة المضغوطة الإدخال أو التمثيل أو الترميز أو أحياناً ببساطة التشفير.

كما رأينا ، يمكن أن يمثل هذا القيد على الشبكة بُنية بيانات مثيرة للاهتمام. تسمح هذه الطريقة باكتشاف التمثيلات الداخلية للبيانات التي تعتمد على ميزات أقل. على سبيل المثال ، في التعرف على الوجوه ، يمكن عرض كل بكسل من الصورة في طبقة الإدخال. يتم ضغط هذه البيانات في ميزات مثل "الفم الصغير" أو "العيون الكبيرة" في الطبقة المخفية. أي أنه يمكن وصف بيانات إدخال الوجه باستخدام بيانات أقل من تلك الواردة في الصورة. بعد ذلك ، يمكن إلغاء ضغط البيانات المضغوطة لتمثيل بيانات الإدخال مرة أخرى في طبقة الإخراج ، مما يسمح بإعادة بناء صورة الوجه بالكامل من الميزات التي تعلمها.

يسمى هذا النوع من التعلم في المشفر الذاتي أيضاً **التعلم بالإشراف الذاتي** ، لأن النظام يتعلم بالفعل بطريقة خاضعة للإشراف باستخدام دالة التكلفة والانتشار الخلفي ، ولكنه لا يحتاج إلى بيانات مصنفة. نتيجة لذلك ، يعد استخدام المشفر الذاتي طريقة شائعة للتدريب على الشبكة عندما يكون لديك وصول فقط إلى القليل جداً من البيانات المصنفة ولكن بكميات كبيرة من البيانات غير المسماة يتم استخدام المشفرات الذاتية بشكل تقليدي للتدريب المسبق: أي أنك تقوم أولاً بتدريب المشفر الذاتي على مجموعة بيانات غير مسماة ، ثم تضيف عدة طبقات مترابطة تماماً وتجمد الأوزان الأصلية. تقوم بعد ذلك بتعليم الطبقات الأخيرة على مجموعة أصغر من البيانات المسماة. بهذه الطريقة ، يتم استخدام المشفر الذاتي كأساس لتدريب المصنف.

بُنية المشفرات الذاتية

تعتبر المشفرات الذاتية نفسها نوعاً خاصاً من الشبكة العصبية امامية التغذية التي يكون مدخلها هو الإخراج. في هذه الشبكة ، يتم ضغط الإدخال في شفرة بأبعاد أقل ثم يُعاد بناء ناتج هذا التمثيل. الشفرة هي إدخال "ملخص" أو "ضغط" ، وتسمى أيضاً تمثيل

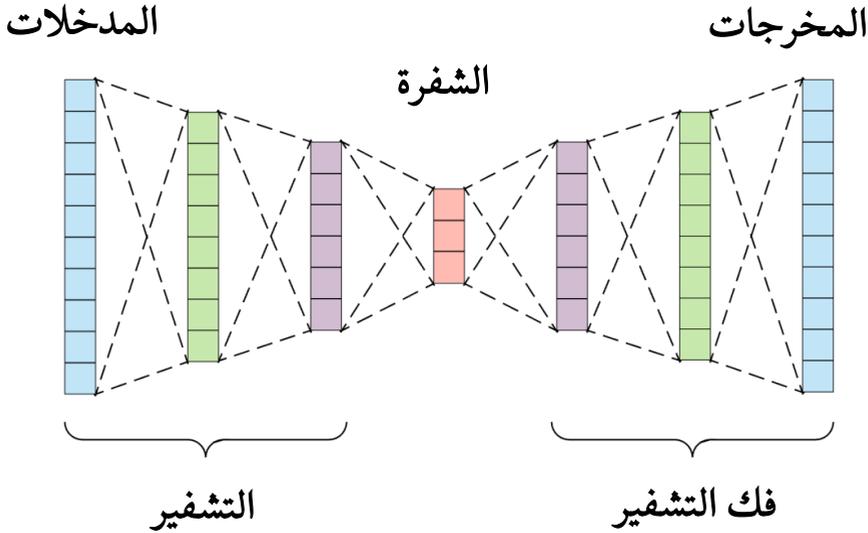
الفضاء الكامن¹. كما ذكرنا ، فإن الفكرة وراء هذه الشبكة العصبية هي إعادة بناء بيانات الإدخال بأقل تشويه ممكن.

يتكون المشفر الذاتي من ثلاثة مكونات: المشفر ، والشفرة ، ومفكك التشفير ، على التوالي. يقوم المشفر بضغط المدخلات وإنشاء كلمة المرور ، ويقوم مفكك التشفير بإعادة بناء الإدخال بناءً على الشفرة (الشكل 3-1). كل من المشفر ووحدة فك التشفير عبارة عن شبكات عصبية متجهة إلى الأمام وغالبًا ما يتم تضمينهما بشكل متماثل في بنية المشفر. الشفرة مكون ذو أبعاد وفقاً لاختيارنا (عدد الخلايا العصبية في طبقة الكود هو معامل فاتق).

دعنا نلقي نظرة فاحصة على هيكل المشفر التلقائي. يتم تمرير الإدخال أولاً من خلال مشفر بشبكة عصبية اصطناعية متصلة بالكامل لإنشاء الشفرة. بعد ذلك ، يقوم جهاز فك التشفير ، الذي له هيكل مشابه لجهاز التشفير ومتماثل له ، بتوليد الإخراج باستخدام جهاز التشفير فقط. الهدف هو الحصول على نفس الناتج مثل المدخلات المعطاة للشبكة. يمكن أن تكون مكونات جهاز التشفير وفك التشفير من أي نوع. في أبسط أشكالها ، يمكن استخدام شبكة عصبية ذات طبقة مخفية واحدة فقط. ومع ذلك ، فقد ثبت أن الشبكات الأعمق يتم تمثيلها بشكل أفضل من الأنواع الضحلة. بالإضافة إلى ذلك ، يُفضل عادةً استخدام طبقات الالتفاف لمهام معالجة الصور المعروفة باسم المشفرات الذاتية الالتفافية. في أبسط أشكاله ، فهو عبارة عن مشفر ذاتي لشبكة من ثلاث طبقات. أي شبكة عصبية ذات طبقة مخفية تسمى المشفر التلقائي العادي² أو البسيط. أحياناً يكون أداء المشفر الذاتي هذا أقل من أداء المشفرات الذاتية الأخرى. هناك أنواع مختلفة من المشفرات الذاتية ، والتي سنقوم بفحصها في الأقسام التالية.

¹ latent-space representation

² Vanilla autoencoder



الشكل 3-1 بُنية المشفرات الذاتية

معاملات المشفرات الذاتية

عند تدريب المشفر الذاتي ، ستواجه العديد من المعاملات التي تؤثر على أداء النموذج ويجب ضبطها مسبقاً. ترتبط هذه المعاملات بالبنية (حجم الشفرة وعدد الطبقات) ومعاملات التدريب (دالة التكلفة). في هذا القسم ، يتم مناقشة هذه المعاملات.

- **حجم الشفرة:** عدد العقد في الطبقة الوسطى للمشفّر الذاتي. من الأفضل دائماً أن يكون عدد العقد في هذه الطبقة أقل من حجم الإدخال. كلما كان حجم طبقة التشفير أصغر ، زاد ضغطها. وفقاً لحجم الشفرة ، يمكن تصنيف عمليات المشفرات الذاتية إلى مجموعتين: مشفرات ذاتية غير مكتملة وكاملة للغاية.
- **عدد الطبقات:** يمكن تحديد العدد المطلوب من طبقات المشفرات الذاتية وفك التشفير على النحو المطلوب. اعتماداً على عدد الطبقات المخفية ، يمكن تقسيم المشفرات الذاتية إلى عميقة وضحلة. يمكنك أيضاً تحديد عدد العقد في هذه الطبقات. عادة ، مع زيادة عدد الطبقات ، يتناقص عدد العقد.
- **دالة الكلفة:** يقيم فعالية تدريب الشبكة العصبية. تُرجع النتيجة التي تشير إلى أداء الشبكة الجيد. في حالة المشفرات الذاتية ، فإنه يقيس جودة إعادة البناء. عادةً ما

تكون دالة التكلفة المستخدمة في المشفر الذاتي هي متوسط الخطأ التربيعي أو الانتروبيا المتقاطعة.

كيف يعمل المشفر الذاتي؟

يتم عرض كل إدخال في المشفر الذاتي مع المتجه $x \in \mathbb{R}^n$ والأبعاد n ، والتي تساوي حجم الإدخال. يأخذ المشفر الإدخال ويضعه أولاً في تمثيل مخفي (تشفير) بواسطة المشفر، والذي يمكن رؤيته كدالة:

$$h = f_{\theta}(x) = \sigma(xW + b)$$

حيث $\theta = \{W, b\}$ ؛ $W \in \mathbb{R}^{m \times n}$ مصفوفة الوزن؛ $b \in \mathbb{R}^m$ هو متجه التحيز؛ $f_{\theta}(x)$ هو المشفر التلقائي و σ هو دالة التنشيط.

يتم إعادة برمجة التمثيل المخفي بواسطة وحدة فك التشفير، والتي تنتج طبقة الإخراج $\hat{x} \in \mathbb{R}^n$ بنفس أبعاد الإدخال n . يمكن كتابة هذه العملية كدالة:

$$\hat{x} = g_{\hat{\theta}}(h) = \sigma(h\hat{W} + \hat{b})$$

حيث $\hat{\theta} = \{\hat{W}, \hat{b}\}$ و $g_{\hat{\theta}}(h)$ هو فك التشفير.

المشفر الذاتي الانكماشى¹

المشفر الذاتي الانكماشى هو نهج تنظيمي يجبر الشبكة على تعلم التمثيلات المفيدة الأقل حساسية (أقوى) للتغيرات الصغيرة في المدخلات (البيانات). يتم تحقيق ذلك عن طريق إضافة غرامة إلى دالة الخسارة. هذه الغرامة هي مجموع العناصر التربيعية لمصفوفة ياكوبية للمشتقات الثانوية لدالة المشفر الذاتي.

$$L(x, g(f(x))) + \varepsilon(h)$$

¹ Contractive Autoencoder

حيث $g(h)$ هو ناتج وحدة فك التشفير ، $h = f(x)$ هو خرج المشفر الذاتي، و $\varepsilon(h)$ هو مجموع العناصر التربيعية لمصفوفة ياكوبية على النحو التالي:

$$\varepsilon(h) = \lambda \left\| \frac{\partial f(x)}{\partial x} \right\|_F^2$$

حيث λ هي معامل فائقة تستخدم للتحكم في قوة التنظيم.

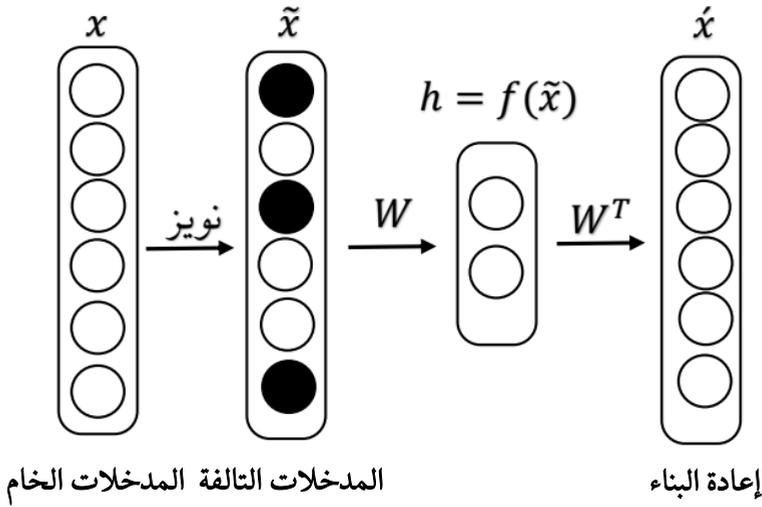
والنتيجة النهائية هي انخفاض حساسية التمثيل المكتسب للمدخلات التعليمية. بمعنى آخر ، يتم تدريب المشفر الذاتي الانكماش على تحمل اضطراب المدخلات.

المشفر الذاتي لإزالة الضوضاء¹

في المشفر الذاتي لإزالة الضوضاء، بدلاً من إضافة غرامة إلى دالة الخسارة ، يمكن الحصول على المشفر الذاتي لتعلم أشياء مفيدة عن طريق تغيير خطأ إعادة بناء دالة الخسارة. يمكن القيام بذلك عن طريق إضافة بعض الضوضاء إلى طبقة الإدخال عن قصد. عن طريق إدخال قيم الضوضاء هذه ، يقوم المشفر الذاتي لإزالة الضوضاء بإنشاء نسخة صاخبة من الإدخال. يساعد هذا في منع النسخ الوارد والصادر دون تعلم ميزات البيانات بواسطة المشفر الذاتي وإجبار الشبكة على تعلم أقوى الميزات.

الإدخال في هذه الشبكة هو الإصدار التالف (الصاخب) $\tilde{x} \in \mathbb{R}^n$ للمدخل الأصلي $x \in \mathbb{R}^n$. لا يقوم هذا المشفر الذاتي بنسخ المدخلات إلى المخرجات فحسب ، بل يسمح البيانات من الضوضاء ثم يُنشئ الإدخال من الإصدار التالف (الشكل 3-2).

¹ Denoising autoencoder



الشكل 2-3 بُنية المشفر الذاتي لازالة الضوضاء

تعمل دالة الخسارة على تقليل الخطأ عند الإدخال التالف ، وليس عند الإدخال الرئيسي، وهي كما يلي:

$$L(x, g(f(\tilde{x})))$$

حيث $g(f(\tilde{x}))$ هو خرج وحدة فك التشفير ، $f(\tilde{x})$ هو الإخراج المشفر للمدخل.

المشفر الذاتي غير الكامل¹

تتمثل إحدى طرق تعلم التمثيلات المفيدة باستخدام المشفرات التلقائية في تحديد حجم تشفير المشفر الذاتي. في هذه الحالة ، يضطر المبرمج إلى استخراج السمات البارزة من البيانات. المشفرات الذاتية غير الكاملة لها حجم شفرة أصغر من حجم الإدخال. يساعد هذا في الحصول على السمات الهامة والبارزة للبيانات. تم تصميم هذه المشفرات الذاتية لتمثيل ميزات البيانات المفيدة وتقليل الأبعاد. يتم وصف عملية التعلم ببساطة عن طريق تقليل دالة الخسارة:

¹ Undercomplete Autoencoder

$$L(x, g(f(x)))$$

المشفّر الذاتي المبعثر¹

على عكس المشفرات الذاتية غير الكاملة ، والتي تكون أصغر من أبعاد الإدخال ، عادةً ما تكون المشفرات الذاتية المبعثرة مكتملة للغاية. ومع ذلك ، لا يزال بإمكانهم اكتشاف الميزات المهمة من البيانات.

تسمح بنية المشفر الذاتي المبعثر بمزيد من الوحدات المخفية في طبقة التشفير. لكن هذا يتطلب أنه بالنسبة لمدخل معين ، لكل خلية عصبية مخفية ، يجب أن تكون قيمة دالة التنشيط المتوسطة قريبة من الصفر (إذا تم استخدام دالة التنشيط سيكمويد أو كانت القيمة 1 - عند استخدام دالة التنشيط تانتش). إذا كان الناتج قريباً من 1 ، تعتبر الخلية العصبية نشطة وغير نشطة. الآن ، السؤال الذي يطرح نفسه. ما هو الغرض من وجود وحدات مخفية تزيد عن الصفر؟ الفكرة هي تنشيط الخلايا العصبية لجزء صغير فقط من عينات التدريب. نظراً لأن العينات لها خصائص مختلفة ، يجب ألا يكون التنشيط العصبي هو نفسه لجميع الخلايا العصبية ويجب تنسيقه. الهدف هو إظهار العناصر المخفية مع العديد من الأصفار وعدد قليل من العناصر غير الصفيرية إلى أبرز الميزات.

تم عملية التدريب في هذا التشفير عن طريق إضافة غرامة إلى دالة الخسارة في طبقة الشفرة:

$$L(x, g(f(x))) + \varepsilon(h)$$

حيث $g(h)$ هو خرج وحدة فك التشفير ، $h = f(x)$ هو خرج المشفر و $\varepsilon(h)$ هي عقوبة التبعر مع دالة لوغاريتمية على النحو التالي:

¹ Sparse autoencoder

$$\varepsilon(h) = \sum_{j=1}^s KL(p||\hat{p}_j)$$

حيث p هي معامل الانتثار وعادة ما تكون قيمة صغيرة قريبة من الصفر، \hat{p}_j هي متوسط التنشيط للوحدة الكامنة j التي تكون تقريباً p ، s هو عدد الخلايا العصبية في الطبقة الكامنة، KL هو تباعد كولباك - ليبلير بين متغير عشوائي برنولي بمتوسط p ومتغير عشوائي برنولي بمتوسط p :

$$KL(p||\hat{p}_j) = p \log \frac{p}{\hat{p}_j} + (1-p) \log \frac{1-p}{1-\hat{p}_j}$$

المشفر الذاتي الالتفافي

المشفر الذاتي الالتفافي هو نوع من شبكات العصبية الالتفافية المستخدمة كأداة متقدمة في التعلم غير الخاضع للإشراف لفلاتر الالتفاف. يعمل المشفر الذاتي الالتفافي من منظور آخر لتحديد الفلتر؛ بدلاً من الفلاتر المترابطة المصممة يدوياً، نترك النموذج يتعرف على الفلاتر المثلى التي تقلل من أخطاء إعادة البناء. بمجرد التعرف على هذه الفلاتر، يمكن تطبيقها على أي إدخال لاستخراج الميزات. لذلك، يمكن استخدام هذه الميزات للقيام بأي شيء يتطلب عرضاً مضغوطاً للإدخال، مثل التصنيف.

تُستخدم هذه الأنواع من الشبكات بشكل عام في إعادة بناء الصورة لتقليل خطأ إعادة البناء من خلال تعلم الفلاتر المثلى. يتعلم المشفر الذاتي الالتفافي تشفير المدخلات في مجموعة من الإشارات البسيطة ثم فك تشفير المدخلات منها. في هذا النوع من المشفرات الذاتية، تسمى طبقات المشفر باسم طبقة الالتفاف وتسمى طبقات مفكك التشفير باسم طبقة فك الالتفاف¹.

¹ deconvolution

النماذج المميزة والانتاجية

يتمثل أحد أهداف التعلم الآلي في تطوير خوارزميات إحصائية تستخدم الملاحظات السابقة لعمل استنتاجات حول حالة البيانات المستقبلية. في العديد من التطبيقات، مثل التصنيف أو الانحدار، يكفي وصف شكل المتغير الموضوعي y كدالة لمتغير التوقع x . بالنظر إلى وجود مجموعة بيانات D ، فإن الهدف هو تحديد المعاملات θ ، بحيث تستنتج $p_{\theta}(y|x)$ بشكل صحيح قيمة y لبيانات اختبار معينة، $x = x^*$. هذا الاحتمال الشرطي $p_{\theta}(y|x)$ هو نموذج مميز او قابل للفصل.

في المقابل، يُظهر النموذج الإنتاجي او المولد التوزيع الشائع المحتمل لـ $p_{\theta}(y, x)$ على جميع المتغيرات. ميزة هذا هو أنه يمكننا استخدام النماذج المولدة لإنتاج عينات مماثلة لتلك المعدة من التوزيع الفعلي. هذه القدرة على أخذ العينات مفيدة للغاية لزيادة البيانات في سيناريوهات القرار.

النماذج الإنتاجية¹ والقابلة للفصل² هما نهجان مختلفان تمت دراستهما على نطاق واسع في مشاكل التصنيف واختيار مسار مختلف تماماً لتحقيق النتيجة النهائية. عمل النماذج القابلة للفصل أسهل من عمل النماذج الإنتاجية، لأنه إذا تم عرض البيانات ذات الفئات المختلفة عليها، فيجب أن تكون قادرة على التمييز بينها، وإذا كانت هناك بيانات مناسبة، فهذا النهج أكثر شيوعاً وأكثر كفاءة. في المقابل، تواجه النماذج الإنتاجية مهمة أكثر صعوبة، حيث يتعين عليها الحصول على توزيع البيانات وفهمه ثم تصنيفه. أيضاً، نظراً لأن هذه النماذج تعلمت كيفية توزيع البيانات، فلديها القدرة على إنشاء بيانات مشابهة للبيانات التعليمية. كمثال على هاتين الطريقتين، افترض أن المتغير العشوائي x عبارة عن صورة و y تسمية تصف محتوى الصورة. لا يمكن استخدام النموذج القابل للفصل $p_{\theta}(y|x)$ إلا لاستنتاج تسمية صورة جديدة. في المقابل، يمكن استخدام النموذج الانتاجي لأخذ العينات لإنتاج عينات مماثلة للصورة التي تحتوي على علامة y . يمكن أن ينتج النموذج الانتاجي عينات مماثلة عن طريق أخذ الاحتمال المشترك لبيانات الإدخال والمسمى $p_{\theta}(y, x)$ في وقت واحد. على سبيل المثال، من خلال اعتبار الصور

¹ Generative

² Discriminative

على أنها بيانات إدخال، يكون لكل عينة (صورة) آلاف الأبعاد (بكسل) ، ويكون منتج النموذج المولد هو الحصول على التبعيات بين وحدات البكسل.

يمكن تعريف النماذج الإنتاجية على أنها فئة من النماذج التي تهدف إلى تعلم كيفية إنشاء عينات جديدة يبدو أنها من نفس مجموعة بيانات التدريب. أثناء مرحلة التدريب، يحاول نموذج إنتاجي حل مشكلة تقدير الكثافة. في تقدير الكثافة، يتعلم النموذج إجراء تقدير أقرب ما يمكن إلى دالة كثافة الاحتمال غير المرئي. النقطة المهمة هي أن نموذج التوليد يجب أن يكون قادرًا على تكوين حالات جديدة للتوزيع، وليس مجرد نسخ الموجودة.

يجب أن تكتشف النماذج المولدة وتتعلم التوزيعات والخصائص الأساسية للبيانات لإعادة بناء أو إنتاج عينات مماثلة بكفاءة. يمكننا التفكير في النماذج الإنتاجية كألة يمكنها النظر إلى أي شيء، مثل السيارة، ومن خلال فحص عدد كبير من طرازات السيارات ، يتعلم النموذج أخيراً خطة إنتاج لكيفية بناء أنواع السيارات الجديدة بمجموعة متنوعة من الألوان والأشكال والارتفاعات وعدد الأبواب والمزيد.

إذا كان النموذج قادرًا حقًا على إنتاج عينات جديدة تتبع ظهور كائنات في العالم الحقيقي، فيمكن في الواقع القول إنه تعلم وفهم مفهومًا بدون تدريب. لذلك، تدرج هذه المجموعة من النماذج في فئة النماذج غير الخاضعة للإشراف (يمكن أيضًا تضمين النماذج الإنتاجية في فئة نماذج الخاضعة للإشراف الذاتية).

أنواع النماذج الانتاجية

يتم تصنيف النماذج التوليد على أنها نهج غير خاضع للإشراف، وبشكل عام نموذج التوليد هو نموذج قادر على تعلم تقدير $p_{\theta}(x)$ من هذا التوزيع من خلال النظري عدد من العينات التعليمية التي تم إعدادها من توزيع $p(x)$. هناك طرق تقدير مختلفة تعتمد على نماذج التوليد. ومع ذلك، بافتراض استخدام أقصى احتمالية للتقدير، يمكن تقسيم النماذج الإنتاجية على نطاق واسع إلى فئتين: النماذج الضمنية والصريحة.

تقدير الاحتمالية القصوى

تستخدم إحدى الطرق المناسبة لتدريب نموذج إنتاجي على مجموعة بيانات تعليمية $X = \{x^{(i)}\}_{i=1}^N$ وإيجاد معاملات مناسبة لتوزيع النموذج $p_{\theta}(x)$ تقدير احتمالية القصوى¹. تكمن الفكرة وراء هذه الطريقة في نمذجة تقريب توزيع البيانات السابق من خلال بعض المعاملات $\theta: p_{\theta}(x)$ ثم تحديد المعاملات التي تزيد الاحتمال إلى أقصى حد.

بعبارة أخرى ، يحدد الحد الأقصى لتقدير الاحتمالية المعامل الأمثل θ^* والتي وفقاً لها يكون الاحتمال مرتفعاً قدر الإمكان لكل نقطة في بيانات X .

$$\theta^* = \arg_{\theta} \max \prod_{i=1}^n p_{\theta}(x^{(i)})$$

من الناحية العملية ، من أجل بساطة العمليات الحسابية والاستقرار العددي ، من الأفضل استخدام قيمة $\log p_{\theta}(x)$ بدلاً من $\log p_{\theta}(x)$.

$$\theta^* = \arg_{\theta} \max \sum_{i=1}^n \log p_{\theta}(x^{(i)})$$

النماذج الضمنية

لا توفر نماذج المولدات الضمنية أداة لتحقيق توزيع $p_{\theta}(x)$ ولا تقدر كثافات الاحتمال، ولكن بدلاً من ذلك تتعلم كيفية إنشاء عينات مباشرة (بيانات). في هذه الطريقة، يتم إجراء مقارنة بين البيانات الحقيقية وعينات الإنتاج. ومن أشهر هذه النماذج شبكات الخصومة المولدة.

¹ Maximum Likelihood Estimation

النماذج الصريحة

باستخدام نماذج صريحة، يمكن الحصول على توزيع $p_\theta(x)$ من إطار النموذج. هناك ثلاث فئات رئيسية من النماذج الصريحة: نماذج الانحدار الذاتي¹، والنماذج القائمة على التدفق²، والنماذج المتغيرة الكامنة الاحتمالية³.

- **نماذج الانحدار الذاتي:** باستخدام نماذج من قانون سلسلة الاحتمالات ، تشتت هذه النماذج إخراجها على البيانات التي لوحظت في الماضي ، وليس على البيانات المستقبلية. على سبيل المثال ، يعتمد كل بكسل جديد في الصورة على وحدات البكسل التي تم عرضها مسبقاً.
- **النماذج القائمة على التدفق:** يتم إنشاء النموذج القائم على التدفق كسلسلة من التحويلات العكسية⁴ تسمى تدفق المجانسة⁵ ، والتي تسمح باستبدال المتغيرات بشكل متكرر وفقاً لنظرية التغيير المتغير. نتيجة لذلك ، تتعلم النماذج القائمة على التدفق بالضبط التوزيع الفعلي للبيانات وتجعل تقدير الاحتمال الدقيق ممكناً.
- **النماذج المتغيرة الكامنة الاحتمالية:** تشكل هذه النماذج مجموعة واسعة من النماذج الصريحة وتستخدم المتغيرات المساعدة للتوزيعات المعقدة التي هي جوانب أكثر واقعية للعالم. نموذج المتغير الكامن هو نموذج اتجاهي رسومي (الشكل 6-1) لمتغيرات x المحتملة التي تحتوي على المتغيرات الكامنة z . يسمح لنا إدراج المتغيرات الكامنة بالحصول على التبعيات المخفية بين المتغيرات المرصودة ومعرفة البنية الأساسية لآلية توليد البيانات ، والأهم من ذلك ، يمكن أن توفر المتغيرات الكامنة تمثيلاً أصغر وأصغر للمتغيرات المرصودة. ومن ثم ، فإن هذه النماذج تفعل التعلم التمثيلي. يعتمد هذا النموذج على افتراض أن متغير الملاحظة x يتم إنشاؤه بواسطة عملية عشوائية تعتمد على متغير مستمر غير مرصود. بمعنى آخر ، يتم إنشاء z الكامنة في البداية من التوزيع السابق $p(z)$. بعد ذلك ، يتم إنشاء x من التوزيع الشرطي $p(x|z)$. يمكن تفسير

¹ autoregressive

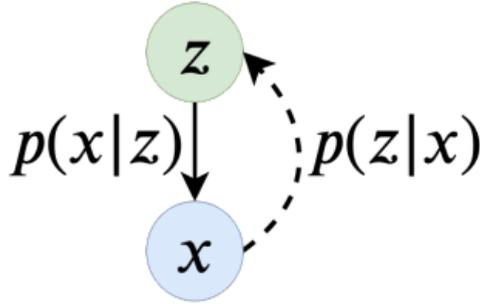
² low-based models

³ probabilistic latent variable models

⁴ invertible transformations

⁵ Normalizing Flows

المتغير Z غير المرصود على أنه تمثيل كامن. بشكل عام ، هذه النماذج لها غرض مزدوج: نمذجة التوزيع الشائع $p_\theta(x, Z)$ ، واستنتاج توزيع $p_\theta(z|x)$ لتعلم التمثيل. النماذج المتغيرة الكامنة لديها القدرة على الكشف التلقائي عن مبادئ عملية الإنتاج وتقديم تمثيلات خفية قابلة للتفسير. المشفر التلقائي المتغير هو مثال على نموذج متغير كامن محتمل.



الشكل 3-3 مخطط لنموذج متغير كامن محتمل

نظرية تغيير المتغيرات

وفقاً لمتغير مرصود $x \in X$ ، توزيع احتمالي بسيط مسبقاً p_z على متغير كامن $z \in Z$ ، وتعيين واحد تلو الآخر $f: X \rightarrow Z$ (مع $g = f^{-1}$) ، معادلة تغيير المتغير ، تحدد توزيع النموذج على X على النحو التالي:

$$p_x(x) = p_z(f(x)) \left| \det \left(\frac{\partial f(x)}{\partial x^T} \right) \right|$$

$$\log(p_x(x)) = \log(p_z(f(x))) + \log \left(\left| \det \left(\frac{\partial f(x)}{\partial x^T} \right) \right| \right)$$

حيث $\frac{\partial f(x)}{\partial x^T}$ يكون f على x . باستخدام قانون أخذ العينات العكسي ، يمكن إنشاء عينات دقيقة للتوزيع الذي تم الحصول عليه. مثال $p_z \sim Z$ مرسوم في الفضاء الكامن وصورته العكسية $g(z) = f^{-1}(z) = x$ تشبه مثالاً في المساحة الأصلية.

النموذج المولد العميق

أصبح التعلم العميق قادراً الآن على إنشاء بيانات جديدة بعد التعلم من بيانات الإدخال غير المسماة. ومن ثم ، فقد أصبح "ذكاءً مبدعاً". على سبيل المثال ، يمكن لشبكات الخصومة التوليدية ، والتي تعد أكثر نماذج التوليد العميق شيوعاً اليوم ، إنتاج صور عالية

الجودة ، وتحسين جودة الصورة ، وتحويل الصورة إلى نص ، وتغيير مظهر صورة الوجه مع تقدم العمر ، وفي الأمن السيبراني لمحاكاة الهجوم ، والمساعدة في الطب في تشخيص السرطان من خلال إنشاء فحوصات واقعية جديدة ، واستخدامه في مجموعة واسعة من الامكانيات الأخرى التي لا نهاية لها.

من الجدير بالذكر أنه نظراً لأن الشبكات الخصومة التوليدية لديها القدرة على إنشاء بيانات جديدة ، فقد يكون هذا أمراً خطيراً في بعض الأحيان. على سبيل المثال ، يمكن أن تخلق صوراً مزيفة قد تبدو حقيقية ، ويمكن أن يكون لهذه الحقيقة عواقب أخلاقية واجتماعية وسياسية خطيرة بين البلدان ، ويرجع ذلك أساساً إلى الخبرة المحدودة للسياسيين بالذكاء الاصطناعي. بالإضافة إلى ذلك ، إذا تم إرسالها إلى خوادم مضيئة باستخدام مفتاح خاص مشفر ، فيمكن تدريبها على اكتشاف كلمات مرور المستخدم. يمكن استخدام الهاش كضوضاء تغذي المولد ، ومع الوقت الكافي ، ستتمكن الشبكة من اكتشاف كلمة مرور المستخدم.

على الرغم من المخاطر التي يمكن أن تنجم عن الاستخدام غير الأخلاقي وغير المسؤول لشبكات الخصومة التوليدية، فهي تقنية جديدة مبتكرة للغاية تعزز العديد من العمليات الآلية اليومية التي تحدث في مجتمعنا حتى تتمكن من التركيز على مسائل الآخرين.

لا تزال القدرة على تعلم تمثيلات مفيدة للبيانات دون توجيه بشري تمثل تحدياً كبيراً للتقدم البحثي في الذكاء الاصطناعي. التقدم في إنشاء الخوارزميات له أهمية كبيرة. لأن البشر لا يتصرفون تماماً مثل النماذج القابلة للفصل ولديهم قدرات إنتاج خيالية عالية جداً. على سبيل المثال، إذا قدمنا ميزات معينة لسيارة، مثل سيارة زرقاء على الطريق، للإنسان، فيمكنه على الفور إنشاء صورة لها في ذهنه. يسعى الذكاء الاصطناعي إلى توفير نفس النوع من الذكاء للآلات. أدى استخدام تقنيات التعلم العميق إلى تطورات كبيرة في إنتاج النماذج الإنتاجية على مدى السنوات العديدة الماضية.

تندرج النماذج الإنتاجية في فئة الأساليب غير الخاضعة للإشراف لأنها تحاول معرفة توزيع بيانات مجموعة البيانات التعليمية. كانت النماذج الإنتاجية في طليعة التعلم العميق

غير الخاضع للإشراف على مدار العقد الماضي. هذا لأنها توفر طريقة فعالة للغاية لتحليل وفهم البيانات غير المصنفة.

باختصار، الفكرة وراء النماذج الانتاجية هي التقاط التوزيع الاحتمالي الداخلي لفئة البيانات من أجل توليد بيانات مشابهة لها. نظراً لأن نماذج توليد التوزيع المشترك غالباً ما تُظهر المتغيرات المرصودة والكامنة، فإن الاستدلال على معاملات النموذج والمتغيرات الكامنة يمكن أن يكون مشكلة أو حتى غير قابل للحل (خاصة في مساحات الإدخال عالية الأبعاد مثل الصور، وتصميم مساحة مميزة للقدرة الكافية لشرح البيانات الموجودة). للتغلب على هذه المشكلة، تم استخدام نماذج التوليد العميق بنجاح.

بشكل عام، يتم تدريب نماذج التوليد العميق بمساعدة تقنيات الانتشار الخلفي لمعرفة التوزيع المحتمل الأقرب قدر الإمكان لتوزيع الإنتاج. تتمثل الطريقة الشائعة في أخذ عينة من متغير الضوضاء من توزيع بسيط، مثل التوزيع العادي القياسي، وتحويل هذه العينة إلى عينة من توزيع توليد البيانات باستخدام هيكل الشبكة العصبية.

يمكن تقسيم نماذج التوليد العميق إلى ثلاث فئات رئيسية:

1. النماذج القائمة على دالة الكلفة مثل المشفر التلقائي وشبكة الخصومة التوليدية.
2. النماذج القائمة على الطاقة التي يتم فيها تعريف الاحتمال المشترك باستخدام دالة الطاقة. تندرج أنواع مختلفة من آلات بولتزمان وشبكات الطاقة العميقة في هذه الفئة.
3. النماذج القائمة على التدفق التي يتم إجراؤها بواسطة التحولات المعكوسة. تعد النماذج القائمة على تيار التعادل وتيار التردد الذاتي أمثلة على هذه النماذج الإنتاجية.

المشفر التلقائي المتغير

تُستخدم المشفرات الذاتية عموماً بشكل أساسي في تقليل الأبعاد والتعلم التمثيلي. ومع ذلك، أدت الروابط النظرية بين النماذج المتغيرة الكامنة إلى إنشاء مشفر ذاتي متغير يمكن استخدامه كنموذج إنتاجي. يعد المشفر التلقائي المتغير مثلاً على نموذج متغير كامن عميق يستخدم الشبكات العصبية لتقريب المتغيرات اللاحقة وإنشاء عينات بيانات.

المشفر الذاتي المتغير هو نموذج توليد احتمالي يتم فيه نمذجة كثافة الاحتمال $p(x)$ بواسطة متغير كامن z . هدفنا هو نمذجة $p(x)$ بحيث يتم إنشاء عينة مقنعة من مجموعة البيانات الخاصة بنا غير الموجودة في مجموعة البيانات من خلال أخذ عينات التوزيع (إنه قادر على إنشاء عينات بيانات جديدة تشبه عينات البيانات التي شاهدها النموذج أثناء عملية التدريب).

سيناريو مسألة

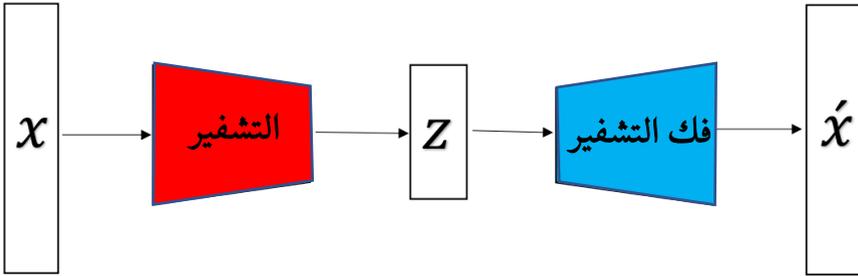
لفهم المشفر الذاتي للمتغير بشكل أفضل، نحدد سيناريو واضحًا للمسألة. افترض أن مجموعة البيانات $X = \{x^{(1)}, x^{(2)}, \dots, x^{(n)}\}$ تتكون من n عينات لبعض المتغيرات المستمرة أو المنفصلة x والبيانات ببعض العمليات يتم إنشاء العشوائيات التي تحتوي على متغير عشوائي z . في هذه العملية، يتم إنشاء قيمة كامنة لـ $z^{(i)}$ من بعض التوزيعات السابقة $p_{\theta^*}(z)$. بعد ذلك، يتم إنشاء $x^{(i)}$ من بعض التوزيعات الشرطية $p_{\theta^*}(x|z)$. في هذا السيناريو، نفترض أن $p_{\theta^*}(z)$ وكذلك الاحتمال $p_{\theta^*}(x|z)$ تأتي من عائلات التوزيع البارامترية $p_{\theta}(z)$ و $p_{\theta}(x|z)$ ، على التوالي، والدوال يمكن تغيير كثافتهم الاحتمالية في كل مكان تقريبًا فيما يتعلق بـ θ و z . المعاملات الحقيقية θ^* وكذلك القيم الكامنة لـ $z^{(i)}$ غير معروفة لنا.

لوصف توزيع البيانات الأصلية وعلاقتها بالمتغيرات الكامنة، نهتم باستخدام احتمالية الحدود $p_{\theta}(x^{(i)}) = \int p_{\theta}(x^{(i)}|z)p_{\theta}(z)dz$ لدينا أيضًا الكثافة السابقة الحقيقية $p_{\theta}(z|x) = \frac{p_{\theta}(x|z)p_{\theta}(z)}{p_{\theta}(x)}$. هذا التكامل وكذلك الكثافة السابقة غير قابلة للحل بالنسبة لدالة الاحتمال $p_{\theta}(x|z)$ المعبر عنها بواسطة شبكة عصبية ذات طبقة غير خطية مخفية. لذلك، نحن مهتمون بالتقريب الفعال لهذه التوزيعات. للقيام بذلك، نقدم نموذج $q_{\phi}(z|x)$ ، وهو تقريب غير قابل للحل تقريبًا للسابق الفعلي $p_{\theta}(z|x)$.

بُنية المشفر الذاتي المتغير

المشفر التلقائي المتغير هو نهج محتمل لوصف عينات بيانات x في مساحة z الكامنة. لذلك، يتم وصف كل متغير موجود في الرمز الكامن z من خلال توزيع الاحتمالات. في المشفر الذاتي المتغير يمكننا أن نرى المتغيرات الكامنة z كرمز للتشفير الذاتي. يمكن اعتبار $q_\varphi(z|x)$ مشفر ذاتي محتمل؛ بإعطاء بيانات x ، يتم إنشاء توزيع بالقيم الممكنة للرمز z الذي يمكن من خلاله إنشاء x . وبالمثل، يمكن اعتبار $p_\theta(x|z)$ بمثابة مفكك تشفير محتمل. وفقاً للرمز z ، يتم إنشاء توزيع بالقيم المقابلة لـ x . وتجدر الإشارة إلى أن المشفر في هذه الحالة لا ينتج فعلياً قيمة الرمز z . بل هو توزيع لهذه القيم. أثناء عمل المشفر الذاتي، يمكننا أخذ عينة من قيمة z من هذا التوزيع وإدخال وحدة فك التشفير.

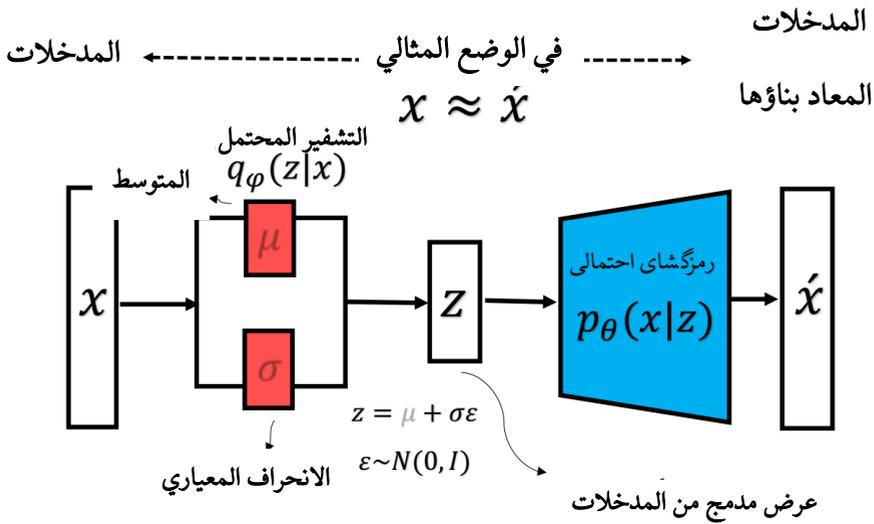
يمكن عرض بنية نموذج المشفر الذاتي المتغير في الشكل 3-5. يمكن أن تكون شبكة التشفير وفك التشفير بشكل عام أي نوع من الشبكات العصبية. ومع ذلك، فإن الاختيار الشائع هو استخدام بيرسيبترون متعدد الطبقات.



الشكل 3-5 بُنية المشفر الذاتي المتغير

إذا تم تقريب توزيع التوحيد الغاوسي متعدد المتغيرات $N(0, I)$ مثل السابق $p_{\theta^*}(z)$ واللاحق $q_\varphi(z|x^{(i)})$ من خلال توزيع التوحيد الغاوسي متعدد المتغيرات $N(\mu, \text{dig}(\sigma))$ ، مع المعاملات $\sigma = (\sigma_1, \dots, \sigma_k)$ ، عن طريق فتح وحدة فك التشفير في عملية أخذ العينات العشوائية، يمكن رؤية المزيد من التفاصيل حول بُنية هذا المشفر الذاتي في الشكل 3-6.

يتلقى المشفر التلقائي المتغير بيانات x كمدخلات ويحولها إلى المعاملات μ و σ عبر شبكة عصبية، وهو تقريب لـ $q_\varphi(z|x^{(i)})$. لذلك، في هذه الحالة $\varphi = (\mu, \sigma)$. من أجل السهولة والدقة العددية، نتعلم قيمة السجل σ بدلاً من $\log \sigma$. بعد ذلك، يتم أخذ عينات من القيمة الكامنة لـ z من التوزيع $N(\mu, \text{dig}(\sigma))$. أخيراً، يتم إعادة بناء هذا z (تحويله) إلى \hat{x} من إدخال x من خلال وحدة فك ترميز. تمثل إعادة بناء هذه القيمة المتوسطة للتوزيع $p_\theta(x|z)$ ، والذي نستخدمه لتقييم خطأ إعادة البناء.



الشكل 3-6 بنية المشفر الذاتي المتغير مع عملية تشفير دقيقة

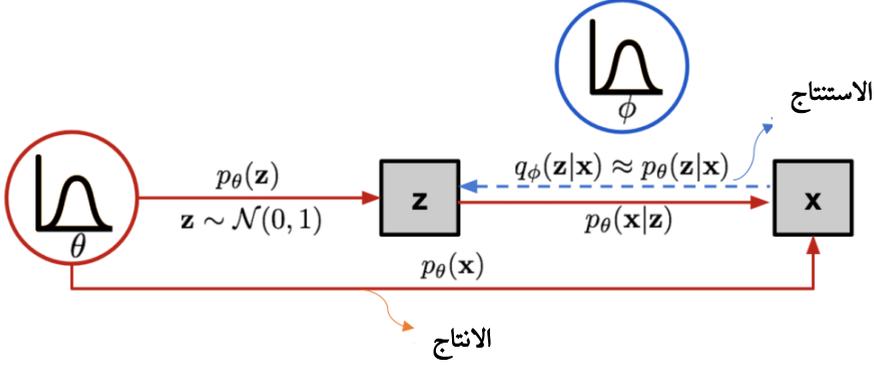
تدريب المشفر الذاتي المتغير

يمكن تحديد العلاقة بين بيانات الإدخال x و متجه التشفير الكامن z بشكل كامل من خلال الاحتمالات التالية:

- $p(z)$ السابق.
- احتمالية $p_\theta(x|z)$ ؛ الذي يتم تعريفه بواسطة وحدة فك الترميز.
- $q_\varphi(z|x)$ اللاحق؛ والذي يتم تعريفه بواسطة المشفر الذاتي.

حيث φ هي مجموعة المعاملات التي تنتمي إلى دالة المشفر الذاتي و θ هي معاملات دالة مفكك التشفير.

بمعرفة التعريفات المذكورة أعلاه، يمكننا رسم مخطط ممكن كما هو موضح في الشكل 3-7.



الشكل 3-7 مخطط المشفر الذاتي المتغير (استنتاج + إنتاج)

بافتراض أن θ^* هي المعاملات الحقيقية لهذا التوزيع، يمكننا تنفيذ الخطوتين التاليتين لإنشاء عينات بيانات جديدة تبدو مشابهة لنقطة بيانات $x^{(i)}$:

1. أخذ عينات من متجه المتغيرات الكامنة $z^{(i)}$ من خلال التوزيع اللاحق $p_{\theta^*}(z)$.

2. استخدم وحدة فك التشفير كشبكة توليد وإعادة بناء المتجه الكامن للعينة باستخدام دالة الاحتمال الشرطي $p_{\theta^*}(x|z = z^{(i)})$ وقم بإنشاء قيمة $x^{(i)}$.

المعاملات المثلى θ^* هي المعامل التي تزيد من احتمالية إعادة البناء لأي نقطة $x^{(i)}$. ومن هنا هدفنا هو ذلك:

$$\theta^* = \arg_{\theta} \max \prod_{i=1}^n p_{\theta}(x^{(i)})$$

كما ذكرنا سابقاً، لتبسيط العمليات الحسابية والاستقرار العددي، يمكننا إعادة كتابتها على النحو التالي:

$$\theta^* = \arg_{\theta} \max \sum_{i=1}^n \log p_{\theta}(x^{(i)})$$

إذا أردنا حساب التوزيع اللاحق الحقيقي للفضاء الكامن $p_{\theta}(z|x)$ ، يجب علينا تحديد $p_{\theta}(x)$ وفقاً لنظرية بايز:

$$p_{\theta}(z|x) = \frac{p_{\theta}(x|z)p_{\theta}(z)}{p_{\theta}(x)}$$

الآن دعنا نحدث المعادلة لتوضيح عملية توليد البيانات بشكل أفضل وإشراك متجه المشفر الذاتي:

$$p_{\theta}(x^{(i)}) = \int p_{\theta}(x^{(i)}|z)p_{\theta}(z)dz$$

من الواضح أن هذه ليست طريقة جيدة. لأن حساب الأخير $p_{\theta}(x^{(i)})$ لكل عينة بيانات $x^{(i)}$ مكلف. وبالتالي، للحد من مساحة البحث الأسرع، يستخدم المشفر الذاتي المتغير الاستدلال التقريبي للتوزيع غير القابل للحل¹، والذي يتم تمثيله بواسطة دالة التشفير عبر $q_{\phi}(z|x)$.

نظراً لأن $q_{\phi}(z|x)$ هو التقدير اللاحق الحقيقي الوحيد الذي لا يمكن حله، يجب علينا التمييز بين الاحتمالين. بمعنى آخر، يجب أن يكون $q_{\phi}(z|x)$ قريباً جداً من $p_{\theta}(z|x)$ الحقيقي $(z|x)$. لتحديد المسافة بين هذين التوزيعين، يمكن قياس الفرق بمساعدة تباعد كولباك - ليبلير.

بالنسبة للتوزيعين، يتم حساب احتمال تباعد كولباك - ليبلير على النحو التالي:

$$D_{KL} = (q_{\phi}(z|x) \parallel p_{\theta}(z|x)) = \int q_{\phi}(z|x) \log \left(\frac{q_{\phi}(z|x)}{p_{\theta}(z|x)} \right) dz$$

¹ intractable

ومع متباينة ينسن ، يكون تباعد كولباك - ليبلير دائماً غير سلبى $D_{KL}(p||q) \geq 0$.
ومن ثم يمكننا تحديد مدى اختلاف السابق التقريبي $q_\varphi(z|x)$ عن الحقيقي $p_\theta(z|x)$.
الآن ، من خلال تحليل معادلة تباعد كولباك - ليبلير التي تم الحصول عليها أعلاه،
نحصل على دالة الهدف ، أو دالة التكلفة ، للمشفرات الذاتية المتغيرة.

$$\begin{aligned}
D_{KL} &= (q_\varphi(z|x) \parallel p_\theta(z|x)) = \int q_\varphi(z|x) \log \left(\frac{q_\varphi(z|x)}{p_\theta(z|x)} \right) dz \\
&= \int q_\varphi(z|x) \log \left(\frac{q_\varphi(z|x)p_\theta(x)}{p_\theta(z,x)} \right) dz \quad \text{"زيرا: } p(z|x) = \frac{p(z,x)}{p(x)} \text{"} \\
&= \int q_\varphi(z|x) (\log p_\theta(x) + \log \left(\frac{q_\varphi(z|x)}{p_\theta(z,x)} \right)) dz \\
&= \log p_\theta(x) + \int q_\varphi(z|x) \log \left(\frac{q_\varphi(z|x)}{p_\theta(z,x)} \right) dz \quad \text{"زيرا: } \int q(z|x) dz = 1 \text{"} \\
&= \log p_\theta(x) + \int q_\varphi(z|x) \log \left(\frac{q_\varphi(z|x)}{p_\theta(x|z)p_\varphi(z)} \right) dz \quad \text{"زيرا: } p(z,x) = p(z|x)p_\varphi(z) \text{"} \\
&= \log p_\theta(x) + \mathbb{E}_{z \sim q_\varphi(z|x)} \left[\log \left(\frac{q_\varphi(z|x)}{p_\varphi(z)} \right) - \log p_\theta(x|z) \right] \\
&= \log p_\theta(x) + D_{KL}(q_\varphi(z|x) \parallel p_\theta(z)) - \mathbb{E}_{z \sim q_\varphi(z|x)} [\log p_\theta(x|z)]
\end{aligned}$$

الآن لدينا المعادلة أعلاه:

$$\log p_\theta(x) - D_{KL}(q_\varphi(z|x) \parallel p_\theta(z)) =$$

$$\mathbb{E}_{z \sim q_\varphi(z|x)} [\log p_\theta(x|z)] - D_{KL}(q_\varphi(z|x) \parallel p_\theta(z)) = -ELBO$$

الجانب الأيسر من المعادلة هو بالضبط ما نريد تعظيمه عند تعلم التوزيعات الحقيقية. في الواقع ، نريد تعظيم احتمال توليد بيانات حقيقية ، والتي في الجزء الأول

من المعادلة هي $\log p_{\theta}(x)$ ؛ وأيضاً تقليل الاختلاف بين التوزيع التقريبي والتوزيع المقدر (الجزء الثاني من المعادلة).

بالنظر إلى أن العديد من خوارزميات التحسين، مثل الانحدار الاشتقاقي، تعمل عن طريق تقليل دالة الهدف، ستكون دالة الهدف النهائية لمتغير المشفر الذاتي على النحو التالي:

$$L_{\text{خودرمزنگار متغير}}(\varphi, \theta, x, z) = -ELBO$$

$$= \mathbb{E}_{z \sim q_{\varphi}(z|x)}[\log p_{\theta}(x|z)] - D_{KL}(q_{\varphi}(z|x) \| p_{\theta}(z))$$

ELBO هو مصطلح محدد للطرق المتغيرة بايزي. تُعرف دالة الخسارة هذه بالحد الأدنى للمتغير أو الحد الأدنى للملاحظات. ينبع الحد الأدنى في هذه التسمية في الواقع من حقيقة أن تباعد كولباك - ليبليز دائماً ما يكون غير سلبي. لذلك، فإن دالة هدف المشفر الذاتي المتغير تكون دائماً أصغر من $\log p_{\theta}(x|z)$:

$$\log p_{\theta}(x) - D_{KL}(q_{\varphi}(z|x) \| p_{\theta}(z)) = L_{\text{المشفر الذاتي المتغير}} = -ELBO \leq \log p_{\theta}(x)$$

يمكن الآن ملاحظة أننا نقوم بالتحسين عن طريق تقليل لوغاريتم الاحتمال السلبي، وهو الجزء الأول من المعادلة السابقة. لذلك، من خلال تقليل دالة الخسارة المشفر الذاتي المتغير L إلى الحد الأدنى، نقوم بتعظيم احتمال إنشاء عينات بيانات حقيقية باستخدام الانحدار الاشتقاقي واسترداد أفضل المعاملات:

$$\theta^*, \varphi^* = \arg_{\theta, \varphi} \min L_{\text{المشفر الذاتي المتغير}}$$

كما يمكن رؤيته، من خلال تقليل المشفر الذاتي المتغير L ، نقوم في نفس الوقت بتعظيم ELBO الذي نتصرف به بما يتناسب مع احتمالية حدوثه، وبالتالي زيادة احتمالية إعادة البناء.

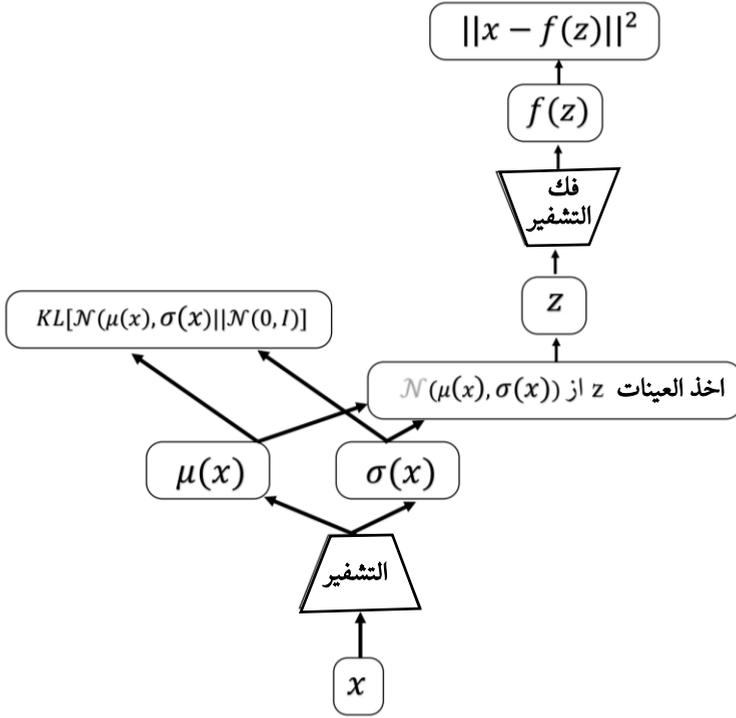
خدعة إعادة بناء المعاملات¹

في المشفر الذاتي المتغير ، يقوم مفكك الشفرة بأخذ عينات عشوائية من السابق الحقيقي $z \sim q_\varphi(z|x)$. يمكن أن يؤدي هذا إلى مشاكل عند تدريب النموذج باستخدام التدرج الاشتقائي العشوائي. لأن الاشتقاق غير ممكن بسبب معاملات المتغير φ . بمعنى آخر ، لا يمكن نشر التدرجات للخلف من خلال المتغير الكامن z . تنشأ هذه المشكلة لأن الانتشار الخلفي لا يمكن أن يتدفق عبر العقد العشوائية ويتوقع الانتشار الخلفي قيماً محددة لتحديد هذه المعاملات. يمكن رؤية هذه المشكلة في الشكل 3-8. للتغلب على هذه المشكلة ، تم استخدام خدعة إعادة بناء المعاملات.

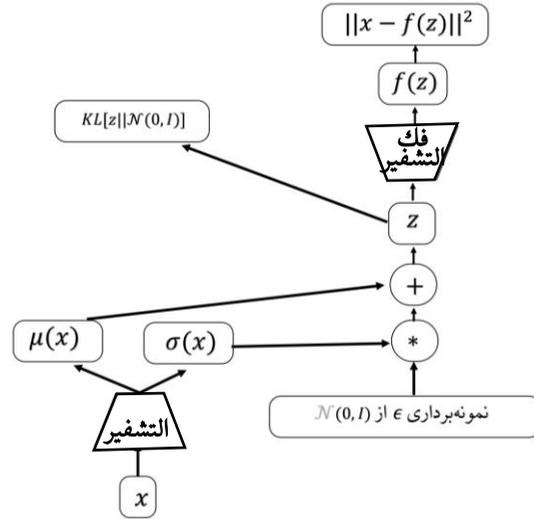
تتضمن الحيلة أخذ عينات من متغير عشوائي مساعد من توزيع ثابت $\mathcal{N}(0, I)$ معادل. بمعنى آخر ، يمكننا معاملتها كمدخلات من خلال تحديد المتغيرات العشوائية المساعدة $\mathcal{N}(0, I)$. بعد ذلك ، من خلال حساب $z = \mu + \sigma \odot \epsilon$ ، نقوم بمحاكاة أخذ العينات $z \sim q_\varphi(z|x) = \mathcal{N}(z, \mu, \sigma^2 * I)$. حيث μ و σ هما الاخراج المحدد الناتج عن طبقة المشفر و $\epsilon \sim \mathcal{N}(0, I)$.

تعتمد إعادة بناء المعاملات فقط على المعاملات المحددة لشبكة الاستدلال. لذلك ، يمكننا حساب التدرجات الناتجة عن وحدة فك التشفير $f(z)$ فيما يتعلق بمعاملات التوزيع المتغير المخفية μ و ثم نشر هذه المعلومات إلى المشفر. لذلك ، فإن عملية أخذ العينات العشوائية باستخدام حيلة إعادة بناء المعاملات كما هو موضح في الشكل 3-9.

¹ Parameterization Trick

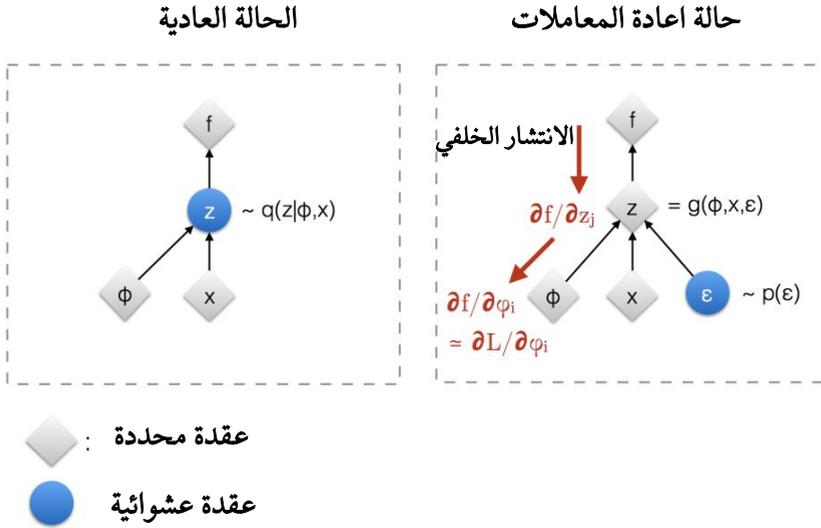


الشكل 3-8 الانتشار الخلفي والحاجة الى حيلة إعادة بناء المعاملات.



الشكل 3-9 إعادة بناء المعاملات بدون أي عقد عشوائية في مسار الإخراج إلى الإدخال وجدوى الانتشار الخلفي.

يوضح الشكل 3-10 مقارنة الرسم البياني الحسابي في المشفر الذاتي المتغير مع عرض أكثر عمومية في الوضع العادي ووضع المعاملات.



الشكل 3-10 مقارنة بين الوضع العادي ووضع إعادة بناء المعاملات. تؤثر المعاملات اللاحقة التقريبية φ على دالة الهدف f باستخدام المتغير الكامن $z \sim q_\varphi(z|x)$. ولكن نظراً لأنه لا يمكن الحصول على المشتق f فيما يتعلق بـ φ (نظراً لأن التدرجات ليست لها قابلية الانتشار الخلفي لاحقاً من خلال المتغيرات العشوائية z)، يتم أخذ عينات من المتغير العشوائي الخارجي من التوزيع الثابت $p(\epsilon) = \mathcal{N}(0, I)$ ثم يتم تنفيذ تحويل متغير بسيط.

شبكات الخصومة التوليدية¹

كما رأينا في القسم السابق، أتاح تدريب النماذج الإنتاجية إمكانية استنتاج المساحة الكاملة. أجبر المشفر الذاتي المتغير الشبكة على تعلم تعيين مساحة غاوسية مستقلة للتوزيع المستهدف. تم تدريب هذا النوع من النموذج الانتاجي عن طريق تقليل دالة الخسارة بين البيانات الأصلية والبيانات المضغوطة. ومع ذلك، في هذا القسم سوف نتعرف على مثال آخر لشبكات التوليد العميقة تسمى شبكات الخصومة التوليدية والتي يتم تدريبها بطريقة عداوية.

¹ Generative Adversarial Network (GAN)

شبكات الخصومة التوليدية هي طريقة حسابية تعتمد على نظرية اللعبة، وفي جوهرها مزيج من شبكتين عصبيتين. تسمى إحدى هاتين الشبكتين بالمولد والأخرى تسمى المُميّز، وهناك علاقة عدائية بين الشبكتين. ببساطة، يتم تدريب أحدهما على إنشاء البيانات والآخر على تحديد ما هو حقيقي وما هو مزيف. يحاول المولد (المزور) خداع الشبكة الثانية (محقق يحاول أن يميز المزيف عن الشيء الحقيقي)، ومع كل محاولة فاشلة، يمكن أن يتحسن من خلال الحصول على ردود الفعل منها. باختصار، أحدهما ينتج والآخر يستكشف الأخطاء، ومعاً وفي تعاون مثالي، يحققون نتائج جيدة جداً.

لتصور عملية الصراع بشكل أفضل، افترض أن شخصاً (مولداً) يريد كتابة قصائد تشبه قصائد المتنبي؛ دون أن يتم عرض أي من قصائد المتنبي أو حتى أدنى معلومات عنها. بالنسبة إلى الشخص الآخر (المميز) الذي يجهل بنفس القدر بالمتنبي، يتم عرض العناصر التي كتبها المولد وأجزاء من قصائد المتنبي بشكل عشوائي. بعد ذلك، يجب أن يقول المميز ذو الاحتمال على مقياس من 0 إلى 1 أنه يعتقد أن القصيدة المكتوبة حقيقية. إذا قام بتصنيف خاطئ، فسيتم معاقبته.

سرعان ما يبدأ المميز في التعلم بطريقة تتجنب العقوبة وتعمل بشكل أفضل في التمييز بين القصائد التي كتبها المولد وقصائد المتنبي. أيضاً، يتم معاقبة المولد عندما يحدد المميز الخطوط بشكل صحيح على أنها مزيفة. بدافع تجنب العقوبة، يبدأ المولد في تعلم كيفية إنتاج قصائد مقنعة، مثل المتنبي، الذي يخدع المُميّز. تستمر هذه اللعبة إلى النقطة التي نأمل أن نحقق فيها توازناً، والذي لن يقوم المولدين والمميزين بتحسين أدائهم. يؤدي وجود هاتين الدائرتين من العقاب إلى التعلم. بعد هذه الخطوة، يتم إرسال المميز إلى المنزل، بينما يحصل المولد على صيغة معقدة لإنتاج قصائد على غرار المتنبي. يتم الحصول على صيغة الإنتاج التي يتم إجراؤها بواسطة المولد من التغييرات وضغط اختيار (المميز). مقياس النجاح في هذه الطريقة هو مدى تصرف المولد بشكل جيد في خداع المُميّز، للاعتقاد بأن المثال الجيد حقيقي.

لقد كانت قدرات شبكات الخصومة التوليدية على توليد بيانات جديدة تحاكي بيانات التعلم مثيرة للإعجاب ولم يسبق رؤيتها من قبل. يقول جان ليكون عن شبكات

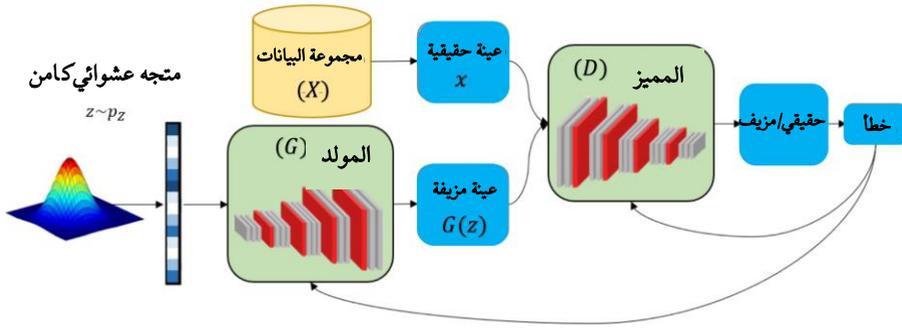
الخصومة التوليدية: "تعد شبكات الخصومة التوليدية واحدة من أكثر الأفكار إثارة للاهتمام في التعلم الآلي في السنوات العشر الماضية".

الآن بعد أن أصبحنا على دراية بالمفهوم العام لشبكات الخصومة التوليدية، نعتزم شرحه رياضياً. الهدف من شبكة الخصومة التوليدية هو تعلم مولد (G) يمكن أن يولد من توزيع البيانات (p_x) ، عن طريق تحويل المتجهات المضمنة من مساحة كامنة منخفضة الأبعاد (Z) إلى عينات في مساحة بيانات عالية الأبعاد (x) . عادة ما يتم أخذ عينات المتجهات الكامنة باستخدام التوزيع المنتظم أو الطبيعي لـ Z. لتدريب G، يتم تدريب المميز (D) على تمييز عينات التدريب الحقيقية من العينات المزيفة التي ينتجها G. وبالتالي، فإن المميز يُرجع القيمة p_x ، والتي يمكن تفسيرها على أنها احتمالية أن تكون عينة الإدخال x مثلاً حقيقياً للتوزيع المحدد. في هذا التكوين، يتم تدريب المولد على منع المميز من خلال إنتاج عينات أكثر تشابهاً مع عينات التدريب الحقيقية. من ناحية أخرى، يتم تدريب المميز بالاستمرار على التمييز بين العينات الحقيقية والعينات المزيفة.

النقطة المهمة في هذا التكوين هي أن المولد ليس لديه وصول مباشر إلى عينات حقيقية لمجموعة التدريب. لأنه يتم تدريبه فقط من خلال التفاعل مع المميز. يوضح الشكل 3-11 هيكل شبكة الخصومة التوليدية. من وجهة نظر رياضية، يتم التعبير عن الغرض من شبكة الخصومة التوليدية على النحو التالي:

$$\begin{aligned} \min_G \max_D L(D, G) &= \mathbb{E}_{x \sim p_r(x)} \log D(x) + \mathbb{E}_{z \sim p(z)} \log (1 - D(G(z))) \\ &= \mathbb{E}_{x \sim p_r(x)} \log D(x) + \mathbb{E}_{z \sim p_g(x)} \log (1 - D(x)) \end{aligned}$$

في المعادلة أعلاه، $p_r(x)$ هو توزيع البيانات الحقيقية و $p_g(x)$ هو توزيع البيانات التي تم إنشاؤها بواسطة المولد.



الشكل 3-11 بنية شبكة الخصومة التوليدية.

بالإضافة إلى ذلك، من أجل تدريب المولد والمميز، يتم إعادة نشر الأخطاء في مخرجاتهما في النموذج.

تكون معادلة التحديث الخاصة بالمميز كما يلي:

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m [\log D(x^{(i)}) + \log (1 - D(G(z^{(i)})))]$$

أيضاً، تكون معادلة التحديث للمولد كما يلي:

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log (1 - D(G(z^{(i)})))$$

حيث تمثل m العدد الإجمالي للعينات المختبرة على دفعات قبل تحديث كلا النموذجين، وتمثل θ_d و θ_g وزن كل نموذج.

تجدر الإشارة إلى أنه نظرًا لأن شبكة الخصومة التوليدية ليست سوى بنية نظام، فالأمر متروك للمستخدم لتحديد العناصر لبناء هذا النظام (المولد والمميز).

آلة بولتزمان

في هذا القسم، سنقوم بوصف نوع خاص من نموذج التعلم الآلي يسمى آلة بولتزمان، وهو نموذج قائم على الطاقة. لكن قبل أن ندخل في تفاصيل هذا النموذج، لفهم هذه النماذج بشكل أفضل، دعنا نعود قليلاً إلى أيام المدرسة. قد تتذكر أن معلمك في المدرسة أوضح سبب عدم تجمع الغازات بالتساوي في غرفة اللعب وفي الزاوية. هل سمعت مصطلح توزيع ماكسويل-بولتزمان؟ تشكل معادلة ماكسويل بولتزمان أساس نظرية حركة الغاز. يحدد توزيع سرعة الغاز عند درجة حرارة. بعبارات أخرى:

" في درجة حرارة الغرفة، من المرجح أن يتم توزيع الغازات بالتساوي في جميع أنحاء الغرفة، لأن هذا التكوين يقلل من طاقة النظام بأكمله."

هذا هو أصل المبادئ الأساسية لآلة بولتزمان. الطاقة مصطلح قد لا يرتبط بالتعلم العميق في المقام الأول. بدلا من ذلك، الطاقة هي سمة كمية للفيزياء. ومع ذلك، تستخدم بعض هياكل التعلم العميق فكرة الطاقة كمقياس لجودة النموذج. على الرغم من أن هذا الاتصال قد يبدو غامضاً في الوقت الحالي، إلا أنه سيكون منطقياً في المستقبل.

أحد أهداف نماذج التعلم العميق هو ترميز التبعيات بين المتغيرات. تحصل النماذج القائمة على الطاقة على التبعيات بين المتغيرات عن طريق ربط طاقة قابلة للتطوير بكل تكوين من المتغيرات، والتي تعمل كمقياس للتوافق. الكثير من الطاقة يعني ضعف التوافق. يحاول النموذج المعتمد على الطاقة دائماً تقليل دالة الطاقة المحددة مسبقاً.

يتضمن التعلم في نموذج قائم على الطاقة إيجاد دالة طاقة يكون فيها التكوين الملحوظ للمتغيرات له طاقة أقل من تلك التي لا يتم ملاحظتها. يعتمد جوهر نماذج البيانات المستندة إلى الطاقة على هذا المبدأ: إيجاد تكوين النموذج لتقليل طاقة النظام. بمعنى آخر، الهدف هو تعلم العثور على دالة طاقة (في مساحة دالية محددة مسبقاً) تربط القيم الأصغر للتكوينات الصحيحة والقيم الأعلى بالقيم غير الصحيحة، سواء داخل عينات التدريب أو خارجها. ثم، من خلال اختيار التكوين الذي يقلل من الطاقة، يتم عمل التنبؤات. لقياس جودة دوال الطاقة الحالية، يتم استخدام دالة الخسارة، والتي يتم تصغيرها أثناء التعلم. مع أخذ ذلك في الاعتبار، دعونا نلقي نظرة على آلة بولتزمان:

آلة بولتزمان هي بُنية قائمة على الطاقة تعلم توزيع الاحتمالات على متغيرات الإدخال الخاصة بها. الفكرة وراء آلة بولتزمان هي أن النموذج يجب أن يكون قادرًا على تعلم السلوك الإحصائي لمعاملات الإدخال وحدها ودون أي إشراف على عينات الإدخال. عندما يتم تقديم مجموعة من العينات، يجب أن تكون قادرة على تعلم التوزيع الإحصائي من خلال خصائص الإدخال. بمجرد أن يلاحظ النموذج جميع عينات الإدخال هذه، يجب أن يكون قادرًا على إنشاء عينات بمفرده يتم الحصول عليها من التوزيع الاحتمالي المشترك مع عينات الإدخال الأصلية، وبالتالي يكون لها نفس السلوك الإحصائي.

الطاقة في آلة بولتزمان

آلات بولتزمان قادرة نظريًا على تعلم أي توزيع معين من خلال عرض العينة المأخوذة ببساطة. بشكل أساسي، تنشئ الشبكة اتصالات قوية بين العقد لالتقاط الارتباطات التي تربطها لإنشاء شبكة مولدة يمكنها إنشاء عينات جديدة من نفس التوزيع. التعلم في هذه النماذج هو طبيعة هيب¹. بمعنى آخر، لتحديث الأوزان، نحتاج فقط إلى المعلومات من الخلايا العصبية المجاورة. في الممارسة العملية، تقرر الخلايا العصبية تقوية أو إضعاف روابطها بناءً على عدد المرات التي تنفق فيها على الإنتاج.

في آلة بولتزمان، لا ترتبط الخلايا العصبية بالخلايا العصبية في الطبقات الأخرى فقط، ولكن أيضًا بالخلايا العصبية داخل نفس الطبقة.

من الناحية المعمارية، فإن آلة بولتزمان عبارة عن شبكة من العقد الثنائية. جميع العقد متصلة ببعضها البعض بحافة عديمة الوزن لها وزن. إذا كان الوزن 0، فيمكن تخيل العقد بدون اتصال، وإذا كان 1، فيمكن أن يحدث العكس. العقد، في أبسط الحالات، هي آلات بولتزمان، عشوائية وثنائية. بمعنى، يمكن للعقدة اتخاذ قرار عشوائي بشأن تشغيلها أو إيقاف تشغيلها، اعتمادًا على تكوين العقد الأخرى والوزن المرتبط الذي يربطها معًا. هذا يختلف عن الشبكات العصبية المغذية في أن دالة تنشيط العقدة هي تحديد العقد وأوزان النموذج.

¹ Hebbian

كل عقدة في آلة بولتزمان متحيزة وملتصدة بالعقد المجاورة ذات الوزن المتماثل. العقدة i مجاورة للعقدة j ، إذا فقط إذا كانت العقدة i والعقدة j ذات وزن غير صفري. تعتمد حالة (أو تنشيط) العقدة فقط على تنشيط العقد المجاورة لها والوزن المرتبط بها، وهي مستقلة بشكل مشروط عن العقد الأخرى ووزن الشبكة.

لتحديد حالة العقدة ، نقوم بإجراء حساب إحصائي:

$$Z_i = b_i + \sum_j s_j W_{ij}$$

في هذه المعادلة b_i تحيز، $s_{j=1}$ إذا كانت العقدة j في وضع التشغيل والعكس صحيح و W_{ij} هو وزن الحافة بين العقدة i والعقدة j .

ثم ، بناءً على قيمة Z_i ، تعمل العقدة i بالاحتمال التالي:

$$P(s_i = 1) = \frac{1}{1 + e^{-Z_i}}$$

إذا تم تحديد عقد آلة بولتزمان بالتسلسل والتحديث العشوائي ، فإن آلة بولتزمان تصل في النهاية إلى توازن يتم فيه تثبيت توزيع الاحتمالات على العقد x . نظرًا لأن التحديثات عشوائية ، لا يمكن توقع تكوين الشبكة في تكوين واحد للعقد. ولكن من المتوقع أن يتم إصلاحه في توزيع احتمالي واحد على تلك العقد.

يتم تحديد طاقة آلة بولتزمان بالمعادلة التالية:

$$E(x) = - \sum_{i=1}^N b_i x_i - \sum_{i=1}^{N-1} \sum_{j=i+1}^N w_{i,j} x_i x_j$$

$$E(x) = -x^T W_x - b^T x$$

حيث W هي مصفوفة الوزن $d \times d$ بين العقدة i والعقدة j و b هو متجه التحيز للعقدة i .

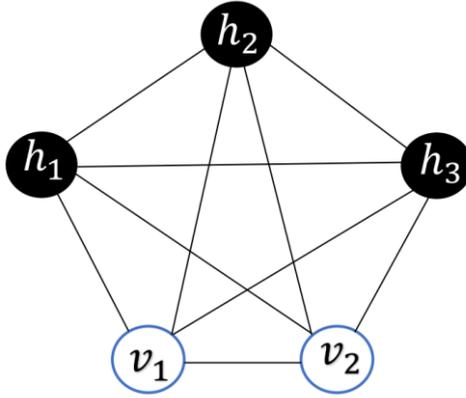
بناءً على الطاقة ، بالنسبة للعقد x الخاصة بآلة بولتزمان في حالة توازن ، يتم تحديد توزيع الاحتمالات على العقد على النحو التالي:

$$P(x) = \frac{1}{Z} e^{-E(x)}$$

في المعادلة أعلاه $z = \sum_x \exp(-E(x))$ هو ثابت معادلة للتأكد من أن $\sum_x P(x) = 1$. تسمى Z أيضاً دالة القسمة¹. من المعادلة أعلاه يمكن ملاحظة أن الاحتمال x يتناقص بشكل موحد مع زيادة الطاقة.

في آلة بولتزمان ، يمكن إخفاء العقدة أو رؤيتها. تتوافق كل عقدة مرئية مع ميزة فريدة للمدخلات والمخرجات التي تمت ملاحظتها. يتم اشتقاق قيم العقد المرئية من خصائص عينة الإدخال ويمكن استنتاج قيم العقد الكامنة. يوضح الشكل 3-12 بنية آلة بولتزمان.

بعد ذلك ، نعرض مجموعة العقد المرئية كـ v ومجموعة العقد المخفية كـ h . نحدد أيضاً مجموعة جميع العقد على أنها $x = v \cup h$.



الشكل 3-12 بنية آلة بولتزمان مع عقدتين ظاهرتين و3 عقد مخفية.

¹ partition function

يمكن أن تعتمد معادلة الطاقة في آلة بولتزمان على التكوين الشائع للعقد المخفية والمرئية، حيث $v \in \{0,1\}^a$ و $h \in \{0,1\}^b$ و $a + b = d$ ، يمكن كتابتها كأدناه:

$$E(v, h) = -v^T w_{1v} - v^T w_{2h} - h^T w_{3h} - b_1^T v - b_2^T h$$

في المعادلة أعلاه، w_1 هو متجه الوزن للوصلات بين أزواج العقد المرئية، و w_2 هو متجه الوزن للوصلات بين أزواج العقد المخفية والمرئية، و w_3 هو متجه الوزن للوصلات بين أزواج العقد المخفية.

- آلات بولتزمان هي نماذج توليد عميقة غير محددة (أو عشوائية)، والتي تحتوي على نوعين فقط من العقد: العقد المخفية والمرئية، حيث لا توجد عقد إخراج!
- على عكس الشبكات العصبية الأخرى التي ليس لها اتصال بين عقد الإدخال، فإن آلة بولتزمان لديها اتصالات بين عقد الإدخال. هذا يسمح لهم بمشاركة المعلومات مع بعضهم البعض وإنشاء البيانات اللاحقة بأنفسهم.

آلة بولتزمان المحدودة

آلة بولتزمان المحدودة، نوع خاص من آلة بولتزمان ذات الطبقة المزدوجة، بما في ذلك: طبقة مخفية وطبقة مرئية، مصممة لحل مشكلة التوزيع المشترك لآلة بولتزمان. ما يميز آلة بولتزمان المحدودة عن آلة بولتزمان هو أنه لا يوجد اتصال مرئي-مرئي ولا اتصال خفي-مخفي في هيكلها. بخلاف ذلك، فإن آلة بولتزمان المحدودة هي بالضبط نفس آلة بولتزمان. تعد آلة بولتزمان المحدودة بديلاً قوياً لآلات بولتزمان المتصلة بالكامل عند بناء بنية عميقة، نظراً لاستقلالية العقد البينية، حيث توفر قدرًا أكبر من الحرية والمرونة.

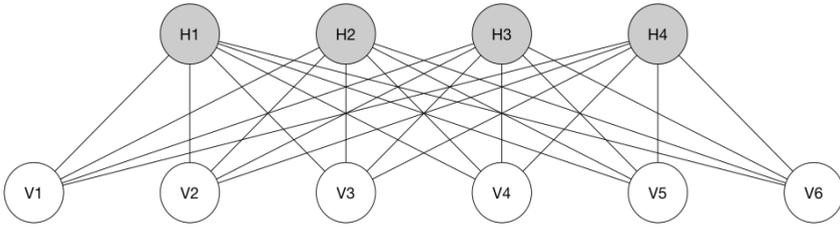
يمكن وصف آلة بولتزمان المحدودة باستخدام مفهوم النموذج الرسومي المحتمل، والذي يستخدم التمثيل القائم على الرسم البياني للتعبير عن الاعتماد بين المتغيرات العشوائية. في آلة بولتزمان المحدودة، تشكل الوحدات المخفية والمرئية رسمًا بيانيًا من جزأين (كما في الشكل 11). من حيث الاحتمالية، هذا يعني أن المتغيرات المخفية مستقلة عن حالة المتغيرات المرئية، والعكس صحيح. توفر خاصية الاستقلال الشرطي هذه التعبيرات الشرطية التالية:

$$p(h|v) = \prod_{i=1}^n p(h_i|v)$$

و

$$p(v|h) = \prod_{j=1}^m p(v_j|h)$$

في هذه المعادلات ، يكون عدد العقد مخفياً و m هو عدد العقد المرئية.



الشكل 3-13 مثال على آلة بولتزمان المحدودة مع 6 عقد مرئية و 4 عقد مخفية.

في آلة بولتزمان المحدودة، لا يوجد اتصال بين الطبقات بين العقد المرئية. لا يوجد أيضاً اتصال داخل الطبقة بين العقد المخفية. لا يوجد سوى اتصالات بين العقد المخفية والمدخلات. سبب تسميتها، مقصوداً على آلة بولتزمان، هو نفس قيود اتصال الطبقة البينية بين العقد. يسمح هذا القيد باستخدام خوارزميات تدريب أكثر كفاءة.

التوزيع الاحتمالي ودالة الطاقة في آلة بولتزمان المحدودة

يتم تعريف دالة الطاقة في آلة بولتزمان المحدودة على النحو التالي:

$$E(v, h) = -v^T W h - b^T v - c^T h$$

في هذه المعادلة ، W هي مصفوفة الوزن حيث w_{ij} هو وزن الحواف بين العقدة المرئية v_i والعقدة المخفية h_i . b متجه التحيز للعقد المرئية حيث b_i هو انحياز العقدة v_i . وبالمثل فإن c هو متجه التحيز للعقد المخفية.

كما هو الحال مع آلة بولتزمان ، يقتصر توزيع الاحتمال الشائع لآلة بولتزمان على

h و v على النحو التالي:

$$P(v, h) = \frac{1}{Z} e^{(-E(v, h))}$$

حيث Z هي دالة القسمة المعرفة على انها $Z = \sum_{v, h} e^{(-E(v, h))}$.

شبكات الاعتقاد العميقة¹

كانت شبكات الاعتقاد العميقة واحدة من أولى النماذج غير الارتباطية التي احتضنت بنجاح تعليم الهياكل العميقة. كان إدخال شبكات الاعتقاد العميقة في عام 2006 بمثابة بداية نهضة في التعلم العميق الحالي. لأنه قبل ذلك، كان تحسين النماذج العميقة يعتبر صعباً للغاية. تهيمن الآلات الأساسية ذات الدوال المستهدفة المحدبة على مساحة البحث. تظهر شبكات الاعتقاد العميقة أن الهندسة المعمارية العميقة يمكن أن تنجح بأداء أفضل من آلات المتجهات الداعمة الأساسية في قاعدة بيانات MNIST.

اليوم، شبكة الاعتقاد العميقة لا تحظى بشعبية عمليا ونادرا ما تستخدم. ومع ذلك، لا تزال معروفة بدورها المهم في تاريخ التعلم العميق.

نماذج التوليد القائمة على التدفق

القدرة على تقدير الكثافة الصحيحة قابلة للتطبيق بشكل مباشر على العديد من مشاكل التعلم الآلي، ولكنها صعبة للغاية. يسمح التقدير الجيد بأداء العديد من الأشياء بكفاءة، بما في ذلك: عينات بيانات جديدة ولكنها واقعية غير ملحوظة (توليد البيانات)، والتنبؤ بالأحداث المستقبلية، واستنتاج المتغيرات الكامنة، وملء عينات البيانات غير المكتملة، والمزيد.

أظهرت شبكات الخصومة التوليدية والمشفرات الذاتية المتغيرة أداءً رائعاً في المهام الصعبة مثل تعلم توزيع الصور الواقعية. ومع ذلك، هناك عدة عيوب لهذه الشبكات. لا يسمح أي منها بتقدير دقيق لكثافة احتمالية النقاط الجديدة. بالإضافة إلى ذلك، يعد تدريب شبكات الخصومة التوليدية أمراً صعباً بسبب مجموعة متنوعة من الظواهر، بما

¹ Deep belief Network (DBN)

في ذلك تلاشي التدرج ، وعدم استقرار التدريب ، وانهيار الحالة¹ ، والانهيار اللاحق²، ويتطلب ضبطاً دقيقاً للمعاملات الفائتة.

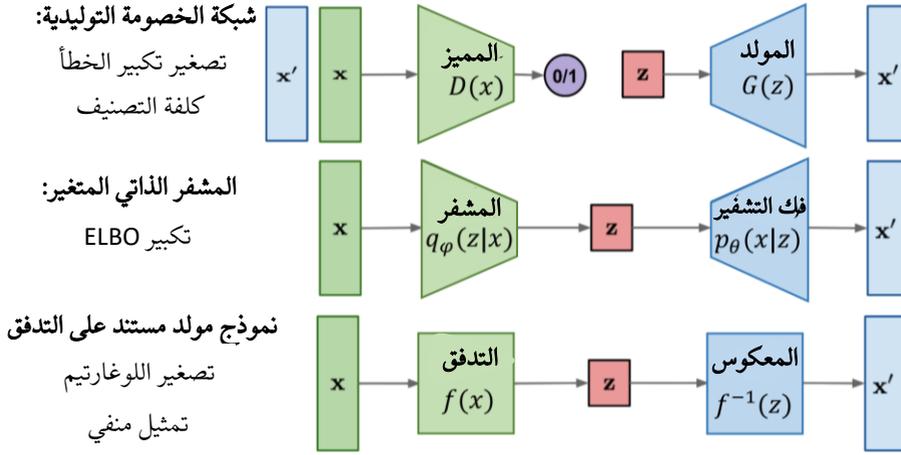
انهيار الحالة

عادة في شبكة الخصومة التوليدية نريد أن ننتج مجموعة متنوعة من المخرجات. على سبيل المثال ، نريد وجهاً مختلفاً لكل إدخال عشوائي للمولد. ومع ذلك ، إذا كان المولد ينتج مخرجات مقبولة ، فقد يتعلم المولد إنتاج هذا المخرج فقط. بمعنى آخر ، يحاول المولد دائماً العثور على مخرجات منطقية للمميز. إذا بدأ المولد في إنتاج نفس الإخراج مراراً وتكراراً ، فإن أفضل استراتيجية للمميز هي رفض هذه النتيجة دائماً. ولكن إذا توقف الجيل التالي من أدوات المميز في الحد الأدنى المحلي ولم يجد أفضل استراتيجية ، فمن السهل جداً على المميز الحالية العثور على النتيجة الأكثر قبولاً لتكرار المولد التالي. يتم تحسين كل تكرار للمولد بشكل مفرط لمميز معين ، ولا يتمكن المميز أبداً من معرفة طريقه للخروج من المصيدة. نتيجة لذلك ، تدور المولدات خلال مجموعة صغيرة من أنواع المخرجات. هذا النوع من الفشل يسمى انهيار الحالة.

النماذج المستندة إلى التدفق هي عائلة من نماذج التوليد ذات التوزيعات القابلة للحل والتي يمكن أن يكون فيها أخذ العينات وتقدير الكثافة بالتدفقات المعيارية أكثر كفاءة ودقة. تعمل النماذج القائمة على التدفق على تحسين الاحتمالية مباشرة من خلال التدفقات المعيارية. بمعنى آخر ، تتعلم النماذج القائمة على التدفق بالضبط التوزيع الفعلي للبيانات وتجعل تقدير الاحتمال الدقيق ممكناً. يوضح الشكل 3-14 مقارنة بين نماذج التوليد العميق.

¹ mode collapse

² posterior collapse



الشكل 3-14 مقارنة بين نماذج التوليد العميق

تستخدم نماذج التوليد المستندة إلى التدفق تسلسلات عكسية لإنشاء تحويلات كثافة الاحتمال لتقريب التوزيع اللاحق. يبدأ التدفق بمتغير أساسي ، ومن خلال تطبيق النظرية بشكل متكرر ، يغير المتغير إلى متغير بتوزيع بسيط. نظراً لأن النموذج القائم على التدفق قابل للانعكاس ، فمن السهل إنتاج عينات تركيبيّة عن طريق أخذ عينات "التوزيع البسيط" و "التدفق" عن طريق التعيين العكسي.

من الجدير بالذكر أن النماذج القائمة على التدفق ، على الرغم من توفير ميزات جذابة للغاية مثل القدرة على تقدير اللوغاريتمات بدقة ، والتوليف الفعال والاستدلال الدقيق للمتغيرات الكامنة قد حظيت باهتمام أقل من المشفرات الذاتية المتغيرة وشبكات الخصومة التوليدية. على عكس شبكات الخصومة التوليدية والمشفرات الذاتية المتغيرة ، يمكن لهذه النماذج حساب احتمال كل عينة تم إنشاؤها.

يمكن تقسيم البحث حول نماذج التوليد القائمة على التدفق إلى فئتين: نماذج القائمة على التدفق المعادل (الموازن) بالكامل والنماذج القائمة على التدفق ذاتية التنظيم. فيما يلي سوف نصف هذه النماذج.

النماذج ذات التدفق المعادل

الهدف من نماذج التوليد القائمة على التدفق هو تقريب توزيع البيانات الحقيقية $x \sim p(x)$ من مجموعة محدودة من الملاحظات $\{x^{(i)}\}_{i=1}^N$. يتم نمذجة البيانات من خلال تعلم تحويل معكوس $z = f^{-1}(x)$ إلى التعيين لمساحة كامنة ذات كثافة معروفة $\pi(z)$ إلى x ، ينشئ متغيراً عشوائياً جديداً باستخدام دالة تعيين عشوائية $x = f(z)$:

$$z \sim \pi(z) \quad , \quad x = f(z) \quad , \quad z = f^{-1}(x)$$

التي نستخدمها باستخدام نظرية المتغيرات المتغيرة:

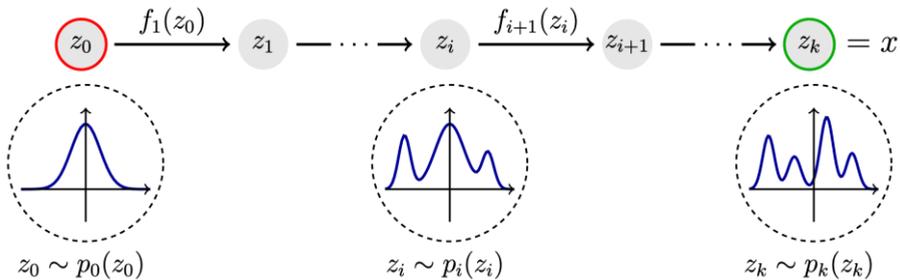
$$p(x) = \pi(z) \left| \det \frac{dz}{dx} \right| = \pi(f^{-1}(x)) \left| \det \frac{df^{-1}}{dx} \right|$$

حيث z هو متغير كامن و $\pi(z)$ هو عادة توزيع غاوسي $N(z; 0, I)$. طريقة استنتاج $p(x)$ من $\pi(z)$ تسمى تيار المعادل. بمعنى آخر، يجعل تيار المعادل توزيع الاحتمالات (مثل غاوسي) ممكناً لتوزيع أكثر تعقيداً عن طريق سلسلة من التحويلات العكسية.

الآن دعنا نلقي نظرة خطوة بخطوة على كيفية تحويل توزيع بسيط مثل z_0 إلى توزيع z_k معقد وفقاً للشكل 3-15.

بافتراض أن لدينا:

$$z_0 \sim p_0(z_0) \quad , \quad z_k \sim p_k(z_k)$$



الشكل 3-15 كيفية تحويل توزيع بسيط إلى توزيع z_k معقد.

لدينا 3-15 وفقاً للصورة:

$$z_{i-1} \sim p_{i-1}(z_{i-1})$$

$$z_i = f_i(z_{i-1})$$

لذا:

$$z_{i-1} = f_i^{-1}(z_i)$$

الآن ، من أجل التمكن من الاستنتاج من التوزيع الأساسي ؛ نقوم بتحويل المعادلة إلى دالة z_i :

$$p_i(z_i) = p_{i-1}(f_i^{-1}(z_i)) \left| \det \frac{df_i^{-1}}{dz_i} \right|$$

وفقاً لنظرية الدالة العكسية: $y = f(x)$ و $x = f^{-1}(y)$. إذا كان لدينا:

$$\frac{df^{-1}(y)}{dy} = \frac{dx}{dy} = \left(\frac{dy}{dx} \right)^{-1} = \left(\frac{df(x)}{dx} \right)^{-1}$$

إذا لدينا:

$$p_i(z_i) = p_{i-1}(z_{i-1}) \left| \det \left(\frac{df_i}{dz_{i-1}} \right)^{-1} \right|$$

ووفقاً للخاصية العكسية لمصفوفة ياكوبية ، لدينا:

$$p_i(z_i) = p_{i-1}(z_{i-1}) \left| \det \frac{df_i}{dz_{i-1}} \right|^{-1}$$

$$\log p_i(z_i) = \log p_{i-1}(z_{i-1}) - \log \left| \det \frac{df_i}{dz_{i-1}} \right|^{-1}$$

بالنظر إلى هذه السلسلة من دوال كثافة الاحتمال ، فإننا نعرف العلاقة بين كل زوج من المتغيرات المتتالية ، لذا يمكننا توسعة معادلة المخرجات x خطوة بخطوة حتى نعود إلى توزيع z_x الأصلي:

$$x = z_k = f_k \circ f_{k-1} \circ \dots \circ f_1(z_0)$$

$$\begin{aligned}
\log p(x) &= \log \pi_k(z_k) = \log \pi_{k-1}(z_{k-1}) - \log \left| \det \frac{df_k}{dz_{k-1}} \right| \\
&= \log \pi_{k-2}(z_{k-2}) - \log \left| \det \frac{df_{k-1}}{dz_{k-2}} \right| - \log \left| \det \frac{df_k}{dz_{k-1}} \right| \\
&= \dots \\
&= \log \pi_0(z_0) - \sum_{i=1}^k \log \left| \det \frac{df_i}{dz_{i-1}} \right|
\end{aligned}$$

يسمى المسار الذي تسلكه المتغيرات العشوائية $z_i = f_i(z_{i-1})$ التيار وتسمى السلسلة الكاملة المكونة من التوزيعات المتتالية π_i بالتيار المتعادل.

النماذج ذات التدفق الذاتي

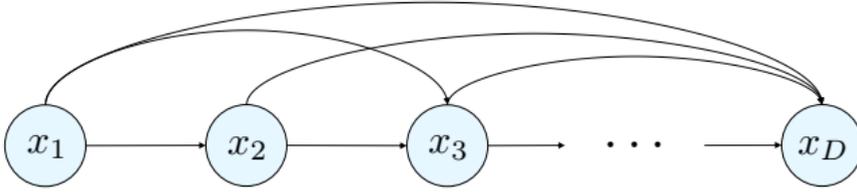
قيود العودية الذاتية هي طريقة لنمذجة البيانات المتسلسلة $X = [x_1, \dots, x_D]$. في نماذج ذات التدفق الذاتي، يعتمد كل عنصر فقط على العناصر السابقة ولا يعتمد على العناصر المستقبلية (يمكن رؤية هيكل هذا النموذج في الشكل 3-16).

بعبارة أخرى، فإن احتمال ملاحظة x_i مشروط بـ x_1, \dots, x_{i-1} ، وحاصل ضرب هذه الاحتمالات الشرطية يعطينا احتمال ملاحظة تسلسل كامل:

$$p(x) = \prod_{i=1}^D p(x_i | x_1, \dots, x_{i-1}) = \prod_{i=1}^D p(x_i | x_{1:i-1})$$

إذا تم تعيين التحويل الحالي في المعادل كنموذج ذاتي العودية، بمعنى آخر، يتم تكييف كل بُعد على متجه متغير للأبعاد السابقة، فهو جريان ذات تدفق ذاتي.

جريان ذات عودية ذاتية هي مزيج من تحويلات ذاتية العودية لإنشاء فئة جديدة من الجريانات الموحدة تسمى جريانات العودية الذاتية، والتي تحقق نتائج متقدمة في مجموعة متنوعة من معايير التقدير ومتغيرات الكثافة.



الشكل 3-16 رسم بياني لتمثيل التبعيات في نموذج العودة الذاتية

خلاصة الفصل الثالث

- ◆ يرجع النجاح المذهل للتعلم العميق إلى حد كبير إلى الخوارزميات الخاضعة للإشراف. ومع ذلك، من أجل تحقيق أداء جيد، يتطلب تدريب هذه الشبكات الكثير من مجموعات البيانات المصنفة.
- ◆ نشأت إعادة الاهتمام بالتعلم غير الخاضع للإشراف مع إدخال نموذجين جديدين للتوليد العميق، وهما شبكة الخصومة التوليدية وشبكة المشفر الذاتي المتغير.
- ◆ توفر شبكة المشفر الذاتي طريقة لتعلم الميزات تلقائياً من البيانات غير المسماة التي تسمح بالتعلم غير الخاضع للإشراف.
- ◆ تقوم الشبكة العصبية للمشفّر الذاتي بإجراء الانتشار الخلفي عن طريق ضبط قيم إخراج الهدف التي تساوي قيم الإدخال، وبالتالي تدريب المشفر الذاتي لتقليل التناقض بين البيانات وإعادة بنائها.
- ◆ يسمى التعلم في المشفر الذاتي أيضاً بالتعلم الخاضع للإشراف ذاتياً. لأن النظام يتم تدريبه بالفعل بطريقة خاضعة للإشراف باستخدام دالة التكلفة والانتشار الخلفي؛ لكنها لا تحتاج إلى بيانات مصنفة.
- ◆ تتكون بنية المشفر الذاتي من ثلاث مكونات: المشفر، والشفرة، ومفكك التشفير، على التوالي. يقوم المشفر بضغط الإدخال، وإنشاء الشفرة، وإعادة بناء وحدة فك تشفير الإدخال بناءً على الشفرة.

- ◆ يعتبر كل من المشفر ووحدة فك التشفير من الشبكات العصبية امامية التغذية وغالبًا ما يتم تضمينهما بشكل متماثل في بنية المشفر.
- ◆ تتمثل إحدى طرق تعلم التمثيلات المفيدة مع المشفرات الذاتية في الحد من حجم الشفرة للمشفرات الذاتية. في هذه الحالة، يضطر المبرمج إلى استخراج السمات البارزة من البيانات.
- ◆ النماذج الإنتاجية والقابلة للفصل هما طريقتان مختلفتان تمت دراستهما على نطاق واسع في مشاكل التصنيف.
- ◆ عمل النماذج القابلة للفصل أسهل من عمل النماذج الإنتاجية. لأنه إذا تم عرض بيانات من فئات مختلفة عليها، فيجب أن تكون قادرة على التمييز بينها. في المقابل، تواجه النماذج الإنتاجية مهامًا أكثر صعوبة. لأنه يجب أن تحصل على توزيع للبيانات وفهمها ثم القيام بالفرز.
- ◆ يمكن تعريف النماذج الإنتاجية على أنها فئة من النماذج التي تهدف إلى معرفة كيفية إنشاء عينات جديدة تبدو وكأنها من نفس مجموعة البيانات التعليمية.
- ◆ تندرج النماذج الإنتاجية في فئة الأساليب غير الخاضعة للأشراف. لأنه يحاول معرفة توزيع بيانات مجموعة البيانات التعليمية.
- ◆ يحاول نموذج إنتاجي حل مشكلة تقدير الكثافة.
- ◆ يمكن تقسيم النماذج الإنتاجية بشكل عام إلى فئتين: النماذج الضمنية والصريحة.
- ◆ تتعلم نماذج المولدات الضمنية إنشاء عينات مباشرة (بيانات).
- ◆ يمكن تقسيم نماذج التوليد العميق إلى ثلاث فئات رئيسية: النماذج القائمة على التكلفة والنماذج القائمة على الطاقة والنماذج القائمة على التدفق.
- ◆ المشفر التلقائي المتغير هو مثال على نموذج مولد عميق.

- ◆ شبكات الخصومة التوليدية هي طريقة حسابية تعتمد على نظرية اللعبة، وفي جوهرها مزيج من شبكتين عصبيتين. واحدة من هذه الشبكات تسمى المولد والأخرى تسمى المميز.
- ◆ يتضمن التعلم في نموذج قائم على الطاقة إيجاد دالة طاقة يكون فيها التكوين الملحوظ للمتغيرات له طاقة أقل من تلك التي لا يتم ملاحظتها.
- ◆ آلة بولتزمان هي بنية قائمة على الطاقة تعلم توزيع الاحتمالات على متغيرات الإدخال الخاصة بها.
- ◆ تعمل النماذج القائمة على التدفق على تحسين الاحتمالية مباشرة من خلال التدفقات المعيارية.
- ◆ تتعلم النماذج القائمة على التدفق بالضبط التوزيع الفعلي للبيانات.
- ◆ تستخدم نماذج التوليد المستندة إلى التدفق تسلسلات عكسية لإنشاء تحويلات كثافة الاحتمال لتقريب التوزيع اللاحق.



أسئلة للمراجعة

1. ما هو التعلم التمثيلي؟
2. ما هو التعلم النشط وما هو استخدامه؟
3. هل من الممكن الحصول على تمثيلات قوية من البيانات غير المسماة؟
4. هل المشفر الذاتي هي طريقة خاضعة للأشراف أم غير خاضعة للأشراف؟
5. ما هي ميزة وضع عنق الزجاجة في المشفر الذاتي؟
6. ما هي العوامل التي تلعب دوراً في تدريب المشفر الذاتي؟

7. ما الغرض من استخدام المشفر الذاتي المتغير؟
8. لماذا يستخدم خدعة إعادة بناء المعاملات في المشفر الذاتي المتغير؟
9. اشرح كيف تعمل شبكة الخصومة التوليدية؟
10. ما هي مشاكل نموذج مولد الخصومة؟
11. ما هو الغرض الرئيسي من نماذج التوليد القائمة على الطاقة؟
12. ما هي ميزة آلة بولتزمان المحدودة مقارنة بآلة بولتزمان؟
13. اذكر مزايا النماذج القائمة على التدفق؟

الفصل 4

التعلم المعزز العميق

الاهداف

- التعرف على التعلم المعزز واختلافه مع التعلم الآلي.
- كيف يعمل التعلم المعزز.
- الأساليب الكلاسيكية لحل مشاكل التعلم المعزز.
- التعرف على التعلم المعزز العميق.

المقدمة

ربما يكون التعلم من خلال التفاعل مع البيئة هو النهج الأول الذي يتبادر إلى الذهن عندما نفكر في طبيعة التعلم. هذه طريقة معروفة نعلم أن الطفل يتعلم من خلالها. هذه التفاعلات هي بلا شك المصدر الأساسي للمعرفة بين البيئة وبيننا ، وليس فقط الأطفال طوال الحياة. على سبيل المثال ، عندما نتعلم قيادة السيارة ، فإننا ندرك تمامًا كيف تستجيب البيئة لما نقوم به ، ونريد أيضًا التأثير على ما يحدث في البيئة من خلال أفعالنا. التعلم من خلال التفاعل هو مفهوم أساسي متضمن في جميع نظريات التعلم تقريبًا وهو أساس التعلم المعزز.

على الرغم من أن التعلم الخاضع للإشراف هو نوع مهم من التعلم ، إلا أنه لا يكفي للتعلم التفاعلي وحده. في القضايا التفاعلية ، غالبًا ما يكون من غير العملي الحصول على أمثلة للسلوك المرغوب فيه والتي تكون صحيحة وتمثل جميع المواقف التي يجب أن يتصرف فيها الوكيل. يستخدم التعلم المعزز لحل هذه الأنواع من المشاكل.

يركز نهج التعلم المعزز ، أكثر من أي نهج آخر للتعلم الآلي ، على التعلم الهادف من خلال التفاعل. في التعلم المعزز ، لا يتم إخبار مكون المتعلم بما يجب فعله مثل الأشكال الأخرى للتعلم الآلي ؛ بدلاً من ذلك ، يجب على الوكيل أن يكتشف ، عن طريق التجربة والخطأ ، ومن خلال تلقي المكافآت والعقوبات ، ما هي الأفعال الأكثر إفادة بجهوده. بمعنى آخر ، لا يتم تعريف التعلم المعزز من خلال وصف طرق التعلم ، ولكن من خلال تحديد مشكلة.

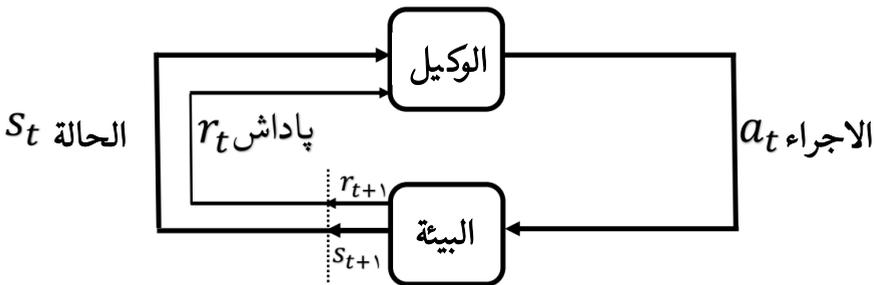
عند التعامل مع قضايا المجال عالي الأبعاد أو العوامل الأونلاين ، يعاني التعلم المعزز من مشكلة عرض الميزات غير الفعال. لذلك ، وقت التعلم بطيء ويجب تصميم التقنيات لتسريع عملية التعلم. ومن ثم ، ظهر مجال جديد يسمى التعلم المعزز العميق للمساعدة في حل التعلم المعزز في المشاكل عالية الأبعاد. أهم ميزة في التعلم العميق هي أن الشبكات العصبية العميقة يمكنها أن تجد تلقائيًا تمثيلات مضغوطة للبيانات عالية الأبعاد.

التعلم المعزز

صنع القرار في البشر هو تعلم قائم على الخبرة ، ويتم استخدام المكافآت أو العقوبات المتلقاة من البيئة لتعلم اتخاذ القرارات في المستقبل. بمعنى آخر ، يتم التعلم في الكائنات الذكية عن طريق التجربة والخطأ مدفوعين بالمكافأة. بالإضافة إلى ذلك ، يتم تشفير الكثير من الذكاء البشري والغريزة في علم الوراثة ، وهي عملية تطورت على مدى ملايين السنين إلى عملية قائمة على البيئة تُعرف بالتطور.

على الرغم من أن التعلم العميق لديه القدرة على تمثيل البيانات بقوة وأداء أفضل من العديد من الأساليب الأخرى في العديد من مجالات التصنيف ومعالجة الصور ، إلا أنه لا يكفي لبناء نظام ذكي للذكاء الاصطناعي. هذا لأن نظام الذكاء الاصطناعي يجب ألا يكون قادرًا على التعلم من البيانات فحسب ، بل يجب أن يتعلم أيضًا من التفاعلات البشرية مع بيئة العالم الحقيقي. يعد التعلم المعزز أحد مجالات التعلم الآلي ويركز على تمكين الجهاز من التفاعل مع بيئة العالم الحقيقي.

يحاول التعلم المعزز من خلال الوكيل حل المشكلة عن طريق التجربة والخطأ من خلال التفاعل مع بيئة غير معروفة للوكيل. يمكن للوكيل تغيير حالة البيئة من خلال أفعاله أثناء إجراء ردود فعل فورية من البيئة. غالبًا ما يشار إلى الاستجابة على أنها المكافأة في التعلم المعزز. يكتسب الوكيل القدرة على التعلم بشكل أفضل من خلال تلقي المزيد من المكافآت الإيجابية من البيئة. بشكل عام، هدف الوكيل هو إيجاد سلسلة الإجراءات المثلى لحل المشكلة. عادة ما يتم تصميم التعلم المعزز كعملية ماركوف لاتخاذ القرار ويمكن وصفه بالشكل 1-4.



الشكل 1-4 عرض التعلم المعزز

كما يتضح من الشكل 4-1، فإن وحدة التعلم، التي تسمى الوكيل، تغير بيئتها بنشاط عن طريق اختيار الإجراء أ من مجموعة من الإجراءات الممكنة. بعد العملية، تتغير البيئة وفقاً لذلك وتخبر الوكيل بالحالة الجديدة. بالإضافة إلى ذلك، ترسل البيئة إشارة مكافأة r إلى الوكيل، مما يوفر ملاحظات حول الإجراء المحدد وفقاً للسيناريوهات المحددة. يستمر الوكيل في العمل، والانتقال من حالة إلى أخرى، حتى يصل إلى حالة نهائية.

يمكن سرد مكونات نظام التعلم المعزز على النحو التالي:

- **الوكيل:** برنامج تم تدريبه للقيام بمهمة محددة.
- **البيئة:** العالم الحقيقي أو الافتراضي، حيث يتخذ الوكيل الإجراءات.
- **الإجراء:** حركة يقوم بها وكيل تؤدي إلى تغيير الحالة في البيئة.
- **المكافأة:** تحدد دالة المكافأة هدفاً في مشكلة التعلم المعزز وترسم كل حالة ملحوظة من البيئة إلى رقم واحد يشير إلى الرغبة الكامنة في تلك الحالة. الغرض من المكافأة في التعلم المعزز هو تقييم إجراء يمكن أن يكون إيجابياً أو سلبياً والاستجابات التي يتلقاها الوكيل من البيئة بعد كل إجراء. قد لا تكون المكافأة الحقيقية لفعل الشيء الصحيح في موقف معين فورية.
- **الحالة:** جميع المعلومات التي يمتلكها الوكيل في بيئته الحالية. في لعبة الشطرنج، على سبيل المثال، يكون الحالة هو مكان كل القطع على رقعة الشطرنج.
- **الملاحظات:** بالنظر إلى أنه في بعض الحالات، لا يتمكن الوكيل من الوصول إلى الحالة الكاملة للبيئة، فعادةً ما يكون ذلك جزءاً من الحالة الذي يمكن للعامل مراقبته. بمعنى آخر، الملاحظات هي المعلومات التي توفرها البيئة للوكيل وتوضح ما يحدث حول الوكيل. ومع ذلك، غالباً ما يتم استخدامها بالتبادل في الأدب والحالة والملاحظة.
- **السياسة:** تحدد ما سيفعله الوكيل وفقاً للوضع الحالي. في مجال التعلم العميق، يمكننا تدريب شبكة عصبية لاتخاذ هذه القرارات. خلال فترة التدريب، يحاول الوكيل تعديل سياسته لاتخاذ قرارات أفضل. تسمى مهمة العثور على السياسة المثلى تحسين السياسة (التحكم) وهي واحدة من القضايا الرئيسية في التعلم المعزز.
- **دالة القيمة:** تحدد ما هو جيد للوكيل على المدى الطويل. بمعنى آخر، عندما نطبق دالة القيمة على حالة معينة، إذا بدأنا من تلك الحالة، فإنها تعطينا العائد الإجمالي الذي يمكن توقعه في المستقبل.

ستساعدك الأمثلة البسيطة التالية على فهم آلية التعلم المعزز بشكل أفضل:

افتراض أن لديك قطة وتريد تدريبها على القيام بأشياء معينة. نظراً لأن القطة لا تفهم اللغة العربية أو أي لغة أخرى ، فلا يمكن إخبارها مباشرة بما يجب أن تفعله. بدلا من ذلك ، يمكن اتباع استراتيجية مختلفة. نقدم موقفاً وتحاول القطة الرد بطرق مختلفة. إذا كانت استجابة القطة هي الاستجابة الصحيحة ، فإننا نعطيها سمكة. الآن ، عندما تتعرض قطة لنفس الموقف ، تنتظر القطة بفارغ الصبر نفس المكافأة (الطعام). لأنه تعلم أنه إذا قامت بعمل معين ، فسوف تكافأ.

في هذا المثال:

- القطة هي التي تكشف البيئة المنزلية في هذه الحالة.
- يمكن أن يكون الموقف عبارة عن جلوس قطة ، ويمكنك استخدام قول كلمات معينة لجعل القطة تمشي.
- من خلال القيام بعمل ما ، يتفاعل الوكيل بالانتقال من حالة إلى أخرى. على سبيل المثال ، تنتقل القطة من الجلوس إلى المشي.

يمكن تقديم مثال آخر للأطفال. غالباً ما يرتكب الأطفال أخطاء. يحاول الكبار التأكد من أن الطفل قد تعلم من هذا الخطأ ومحاولة عدم تكراره مرة أخرى. في هذه الحالة ، يمكننا استخدام مفهوم التغذية الراجعة. إذا كان الآباء صارمين ، فإنهم يلومون أطفالهم على أي أخطاء ، وهي ردود فعل سلبية. من الآن فصاعداً ، سوف يخطئ الطفل في تذكر أنه فعل شيئاً خاطئاً ، لأنه سوف يلومه الوالدان. ثم هناك ردود فعل إيجابية ، حيث قد يمدحهم الآباء لفعالهم الشيء الصحيح. هنا ، نقوم أو نحاول القيام بعمل صحيح بطريقة معينة.

باختصار ، التعلم المعزز هو نوع من منهجية التعلم التي نقدم فيها ملاحظات للخوارزمية مع مكافآت للتعلم منها ، من أجل تحسين النتائج في المستقبل.

التعلم المعزز مقارنة بالتعلم الآلي

على الرغم من أن التعلم المعزز هو مجموعة فرعية من التعلم الآلي ، إلا أنه يختلف اختلافاً جوهرياً في نواح كثيرة عن أساليب التعلم الآلي الخاضعة للإشراف وغير الخاضعة

للاشراف. أولاً ، لا يعتمد التعلم المعزز على استخدام البيانات. في المقابل ، في التعلم المعزز ، يتعلم الوكيل من تجاربه من خلال التجربة والخطأ أثناء التفاعل مع البيئة ، وليس الأمر متروكاً للمشرف لاتخاذ الإجراءات. ثانياً ، يركز التعلم المعزز على إيجاد السياسة الصحيحة بدلاً من تحليل البيانات. أيضاً ، نظراً لأن الوكيل يتعلم مباشرة من البيئة ، فهو لا يحتاج إلى كميات كبيرة من بيانات التدريب الموجودة مسبقاً في مجال معين للتعلم. بدلاً من ذلك ، يقوم بإنشاء بيانات تعليمية عن طريق التفاعل ببساطة مع البيئة التي توجد فيها والتعلم من التجربة.

قرارات عملية ماركوف

قرارات عملية ماركوف هي نموذج رياضي عشوائي لسيناريو صنع القرار. في كل مرحلة، يختار صانع القرار ، أو بعبارة أخرى نفس الوكيل ، إجراءً. في هذا النموذج ، يكون جزء من النتيجة عشوائياً والجزء الآخر هو نتيجة فعل. تُستخدم قرارات عملية ماركوف لنمذجة مجموعة متنوعة من مشكلات التحسين ويمكن حلها من خلال البرمجة الديناميكية والتعلم المعزز.

تشبه عملية صنع القرار في ماركوف مخططاً انسيابياً به دوائر تمثل الحالات. ستظهر أسهم من كل دائرة، تشير إلى جميع الإجراءات الممكنة التي يمكن اتخاذها من هذا الحالة. على سبيل المثال، عملية صنع القرار في ماركوف في تمثيل لعبة الشطرنج لها حالات تشير إلى موقع القطع على رقعة الشطرنج والإجراءات التي تشير إلى الحركات المحتملة بناءً على القطع الموجودة على رقعة الشطرنج.

الميزة الرئيسية لعملية صنع القرار في ماركوف هي أن كل حالة يجب أن يحتوي على جميع المعلومات التي يحتاجها الوكيل لاتخاذ قرار مستنير، وهو مطلب يسمى "أصول ماركوف". في الأساس، تقول أصول ماركوف أنه لا يمكن للمرء أن يتوقع أن يكون للوكيل ذاكرة تاريخية خارج حالته. على سبيل المثال، توضح الحالة الحالية للرقعة كل الأشياء الأفضل للخطوة التالية، ولا داعي للحركات التي تم إجراؤها من قبل لتذكرها.

في الممارسة العملية، لا يتعين على التعلم المعزز محاكاة مشكلة العالم الحقيقي من أجل حل مشكلة ما. على سبيل المثال، قد تلعب ذاكرتي حول كيفية لعب خصم معين

الشطرنج دوراً في عملية اتخاذ القرار الخاصة بي في العالم الحقيقي، ولكن من الممكن الفوز بلعبة شطرنج من خلال التعليم المعزز دون الحاجة إلى هذه المعلومات.

يتم تحديد عمليات صنع القرار في ماركوف من خلال مجموعة من 5 عناصر $S >$ ، A ، P ، R ، $\gamma <$ ، حيث:

- **S**: مجموعة من الحالات التي تتضمن جميع التمثيلات الممكنة للبيئة.
- **A**: في كل حالة، توفر البيئة للوكيل مجموعة من الإجراءات في مساحة التشغيل للوكيل للاختيار من تلك الإجراءات. العامل يؤثر على البيئة من خلال الإجراءات.
- **P**: $P = (s, a, \acute{s}) = P_r(s_{t+1} = \acute{s} | s_t = s, a_t = a)$ مصفوفة الانتقال هي احتمال أن تؤدي الاجراء a في الحالة s في الوقت t إلى الحالة \acute{s} في الوقت $t + 1$.
- **R**: $R = (s, a, \acute{s})$ المكافأة المتوقعة التي يتلقاها الوكيل بعد الإجراء a في الحالة s والوصول إلى الحالة \acute{s} .
- **γ** : عامل الهبوط ويظهر الأهمية بين المكافآت قصيرة الأجل وطويلة الأجل. تتمثل إحدى القضايا الرئيسية في عمليات صنع القرار في ماركوف في إيجاد "سياسة" لصانع القرار؛ دالة P تحدد الحالات للإجراءات $(s) = \pi(a)$. يمكن أن تكون هذه السياسة محددة أو عشوائية. الهدف هو العثور على سياسة تزيد من إجمالي المكافأة إلى الحد الأقصى من حالة إلى أخرى:

$$G_t = \sum_{i=t}^{\infty} \gamma^i \cdot R(s_i, a_i, s_{t+1})$$

يسمى G_t الدخل أو العائد.

الوكيل

الوكيل هو شخص أو شيء يتفاعل مع هذه البيئة من خلال تنفيذ إجراءات وملاحظات معينة وتلقي المكافآت النهائية. العامل هو مكون يقرر بناءً على الثواب والعقاب، الإجراء الذي يجب اتخاذه. لاتخاذ قرار، يُسمح للوكيل باستخدام أي مراقبة للبيئة وأي قانون داخلي. يمكن أن تكون هذه القواعد الداخلية أي شيء، ولكن عادةً في التعليم المعزز

يتوقع المرء أن يتسم الوضع الحالي من بيئة الامداد إلى الحالة باتخاذ قرارات ماركوف، ثم يقرر، باستخدام دالة السياسة، ما هو القرار الذي يجب اتخاذه.

في معظم سيناريوهات التعلم المعزز العملية، من المفترض أن يحل وكيل البرمجيات لدينا بعض المشكلات بطريقة أكثر أو أقل كفاءة. الوكيل هو أحد أهم مكونات النظام القائم على التعلم المعزز. لأنه يتضمن ذكاءً لاتخاذ القرار والتوصية بالإجراءات (العمليات) المثلى في أي حالة. نظرًا لأن الوكيل يلعب دورًا مهمًا للغاية في التعلم المعزز، فقد تم إجراء الكثير من الأبحاث حول بنية التعلم والنماذج ذات الصلة. فيما يلي، نقسم الخوارزميات بناءً على الوكلاء إلى خوارزميات قائمة على القيمة، وقائمة على الخط، وقائمة على النموذج.

خوارزميات قائمة على القيمة

في الخوارزميات القائمة على القيمة، يتم تعيين دوال القيمة $V^\pi(s)$ للحالات ويتخذ صانع القرار قراراته بناءً على قيم الحالات. دالة القيمة هي دالة تقييم مدى استناد الحالة إلى التنبؤ بالمكافآت المستقبلية. هناك نوعان مختلفان من دوال القيمة:

- **دالة الحالة_القيمة**، التي يشار إليها عادةً باسم دالة القيمة، G_t هي العائد المتوقع بدءًا من الحالة s وتتبع السياسة π ، ويتم تعريفها بواسطة معادلة بلمان على النحو التالي:

$$V^\pi(s) = \mathbb{E}[G_t | S_t = s]$$

$$= \sum_{a \in A} \pi(a|s) \sum_{s' \in S} \pi(s'|s, a) [R = (s, a, s') + \gamma V^\pi(s')]$$

- **دالة الحالة_الاجراء**، يُشار إليها عادةً بقيمة Q ، العائد G_t المتوقع هو زوج من الحالة_الاجراء في الوقت t للسياسة π ، ويتم تعريفه بالمثل بواسطة معادلة بلمان على النحو التالي:

$$Q^\pi(s, a) = \mathbb{E}[G_t | S_t = s, A_t = a]$$

$$= \sum_{s' \in S} P(s'|s, a) [R = (s, a, s') + \gamma \sum_{a' \in A} \pi(a', s') + Q^\pi(s', a')]$$

معادلات بلمان

معادلات بلمان هي مجموعة من المعادلات التي تحلل دالة القيمة إلى مكافآت فورية بالإضافة إلى القيم المستقبلية المخصومة.

$$\begin{aligned} V^\pi(s) &= \mathbb{E}[G_t | S_t = s] \\ &= \mathbb{E}[R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots | S_t = s] \\ &= \mathbb{E}[R_{t+1} + \gamma(R_{t+2} + \gamma R_{t+3} + \dots) | S_t = s] \\ &= \mathbb{E}[R_{t+1} + \gamma G_{t+1} | S_t = s] \\ &= \mathbb{E}[R_{t+1} + \gamma V(S_{t+1}) | S_t = s] \end{aligned}$$

وبالمثل بالنسبة Q - قيمة:

$$\begin{aligned} Q^\pi(s, a) &= \mathbb{E}[R_{t+1} + \gamma V(S_{t+1}) | S_t = s, A_t = a] \\ &= \mathbb{E}[R_{t+1} + \gamma \mathbb{E}_{a \sim \pi} Q(S_{t+1}, a) | S_t = s, A_t = a] \end{aligned}$$

تم إنشاء المعادلة التالية بين دالات الحالة - القيمة و الحالة - الإجراء:

$$V^\pi(s) = \sum_a \pi(a|s) Q^\pi(s, a)$$

الهدف هو زيادة إجمالي المكافأة التراكمية على المدى الطويل. بمعنى آخر ، الهدف من التعلم المعزز هو إيجاد السياسة المثلى. يُطلق على السياسة الذي تزيد الحد الأقصى للمكافأة التراكمية السياسة المثلى ويُشار إليه بعلامة π^* . السياسة المثلى π^* هو أن قيمة كل حالة s تحت π^* أكبر من أو تساوي قيمة الحالة π^* تحت سياسة أخرى π' لجميع $s \in S$

$$V^{\pi^*}(s) = V^*(s) \geq V^{\pi'} \quad \forall s \in S, \pi'$$

إذا كانت دالة القيمة - الحالة هي الأمثل، يستخدم الوكيل السياسة المثلى، وقد يكون هناك العديد من السياسات المثلى التي تؤدي إلى نفس دالة القيمة - الحالة المثلى. يمكن تعريف دالة الحالة - القيمة المثلى V^* على النحو التالي:

$$V^*(s) = \max_{\pi} V^\pi(s) \quad \forall s \in S$$

بالإضافة إلى ذلك ، تؤدي السياسة المثلى إلى دالة الإجراء - الحالة المثلى Q^* :

$$Q^*(s, a) = \max_{\pi} Q^\pi(s, a) \quad \forall s \in S, a \in A$$

أخيراً ، يمكن اشتقاق معادلة تحسين بلمان من المعادلات التي تم تقديمها مسبقاً:

$$\begin{aligned}
 &= \mathbb{E}[R_{t+1} + \gamma V^*(\acute{s}) | S_t = s, A_t = a] \\
 V^*(s) &= \max_{a \in A(s)} Q^{\pi^*}(s, a) \\
 &= \max_a \mathbb{E}[R_{t+1} + \gamma V^*(\acute{s}) | S_t = s, A_t = a] \\
 &= \max_a \sum_{\acute{s} \in S} P(\acute{s} | s, a) [R(s, a, \acute{s}) + \gamma V^*(\acute{s})] \\
 &= \max_a \sum_{\acute{s} \in S} P(\acute{s} | s, a) [R(s, a, \acute{s}) + \gamma \max_{\acute{a}} Q^{\pi^*}(\acute{s}, \acute{a})]
 \end{aligned}$$

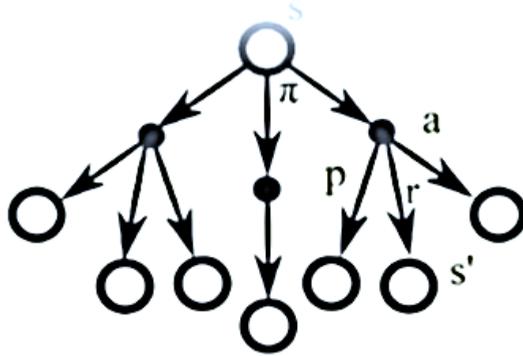
مخطط الدعم في التعلم المعزز

يمكن فهم معادلات بلمان بشكل أفضل باستخدام شجرة الحالات والاجراءات (مخطط الدعم). يُظهر مخطط الدعم تمثيلاً مرئياً للخوارزميات والنماذج المختلفة في التعليم المعزز.

عملية الدعم (عملية التحديث) هي تمثيل رسومي للخوارزمية، تشير إلى الحالة، والإجراء، وحالة التحويل، والمكافأة، وما إلى ذلك. يوضح هذا الرسم البياني قيمة الحالة بدائرة مجوفة بينما يتم عرض قيمة الإجراء مع دائرة صلبة. أيضاً، يتم عرض الإجراء بسهم يبدأ من الحالة.

الآن دعونا ننظر في كيفية عرض قيمة الحالة باستخدام مخططات الدعم (الشكل 4-2).

1. s هي حالة البداية والعقدة الرئيسية.
2. من الوضع s ، يمكن إجراء ثلاث عمليات. كما يتضح من السهم ويتصرف الوكيل وفقاً لسياسة π .
3. إذا كانت البيئة العشوائية لديها احتمالية معينة للإرسال، فيمكن أن ينتهي هذا العامل في حالات مختلفة. كما هو موضح في الشكل، هناك 3 حالات محتملة يمكن للوكيل إدخالها بعد تنفيذ الإجراء الصحيح.

شكل 4-2 مخطط الدعم للحالة-القيمة $V^\pi(s)$

الخوارزميات المستندة إلى السياسة

السياسة هي استراتيجية تمكن آية التعلم من تحديد الإجراء التالي الأفضل بناءً على الحالة الحالية. السياسة هي جوهر التعلم المعزز؛ أي أنه وحده يكفي لتحديد السلوك.

تتخذ الخوارزميات المستندة إلى السياسة نهجاً مباشراً أكثر من الخوارزميات المستندة إلى القيمة. في هذا النهج، بدلاً من العثور على قيمة كل موقف محتمل ثم الحصول على السياسة المثلى، يسعون للعثور على السياسة مباشرةً لتعظيم العائد المتوقع.

وبعبارة أخرى، فإن جوهر الأساليب المستندة إلى السياسة هو تحديث معاملات السياسة θ ؛ بحيث يزيد عائد G_t المتوقع. بعبارات أبسط، في النهج القائم على السياسة، يتم أولاً اختيار سياسة عشوائية وفي مرحلة التقييم يتم العثور على دالة القيمة لتلك السياسة. بعد ذلك، حساب السياسة الجديدة باستخدام دالة القيمة للتحسين في كل خطوة. يكرر هذه العملية حتى يتم العثور على النهج الأمثل. يتم وصف عملية التحسين على النحو التالي:

$$\theta_{i+1} = \theta_i + \Delta\theta_i$$

حيث θ_i هي مجموعة من معاملات السياسة التي تم تحديد معاملاتهما في سياسة π ، و $\Delta\theta_i$ هي تغيير معاملات السياسة.

الاستخراج¹ مقابل الاستكشاف²

يحاول البشر الحصول على أكبر قدر ممكن من المعلومات قبل القيام بأي شيء. على سبيل المثال، قبل تجربة مطعم جديد، حاول قراءة التعليقات أو أسأل الأصدقاء الذين جربوه بالفعل. من ناحية أخرى، في التعليم المعزز، هذا غير ممكن. ولكن هناك بعض الأساليب التي يمكن أن تساعدك في اكتشاف أفضل استراتيجية.

في التعليم المعزز، يمكن للوكيل تطبيق استراتيجيتين عند اتخاذ القرارات في البيئة:

- **الاستكشاف:** اختر إجراءً عشوائياً. باتباع هذه الطريقة، يمكن للوكيل زيارة الحالات الجديدة والعثور على سياسات جديدة وأفضل. والنتيجة هي المزيد من المعلومات التي قد تؤدي إلى قرارات أفضل في المستقبل.
- **الاستخراج:** كن طماعاً. اختيار أفضل الأعمال المعروفة حسب العلم المتاح، باستخدام المكافأة الإجمالية. بمعنى آخر، تعزز اتخاذ القرار الأفضل بناءً على المعلومات الحالية.

في التعلم المعزز، يتم استخراج هذا النوع من اتخاذ القرار: عندما تستمر في العمل السابق، يسمى الاستخراج، وعندما تحاول أشياء أخرى، يُطلق عليه الاستكشاف.

إحدى السمات الرئيسية للتعليم المعزز هي مشكلة الاستخراج مقابل الاستكشاف. إذا أراد الوكيل تعلم أفعال أفضل، أو بعبارة أخرى، أفعال ستؤدي في النهاية إلى المزيد من المكافآت المتراكمة، فعليه أن يجرب أفعالاً جديدة. أيضاً، إذا كان الوكيل قد استخراج من معرفته الحالية واتبع الإجراءات المعروفة سابقاً للحصول على تعليقات جيدة للمكافأة، فلا يمكن ضمان الحصول على عائد أعلى من المكافأة التي كان من الممكن أن يحصل عليها الوكيل. إذن فهذه معضلة يواجهها الوكيل عند اتخاذ قرار بشأن المزيد من الإجراءات: إما تجربة إجراءات عشوائية وتخمين أنه سيحصل على المزيد من المكافآت، ولكن يخاطر بتفاقم النتيجة. أو من خلال التصرف وفقاً لظروفه الحالية، فمن المحتمل أن يحصل على مكافأة أقل ولكن مؤكدة. بمعنى آخر، إذا كان الوكيل يقوم بالاستكشاف فقط، فقد لا يحقق درجات أعلى ويحسن أفعاله. من ناحية أخرى، إذا تم

¹ exploitation

² exploration

استخدام الاستخراج فقط، فقد يعلق في سياسته الحالية من خلال رؤية جميع المسارات الممكنة. وبالتالي، من المرجح أن يفوت الوكيل السياسة المثلى. لذلك، يجب أن يكون هناك توازن جيد بين الاستكشاف والاستخراج.

نشأ هذه المشكلة لأن عملية التعلم في التعليم المعزز تتم اونلاين. بمعنى آخر، لا تتم مراقبة التعليم المعزز بقدر ما يتم مراقبة التعليم. لذلك، يسعى الوكيل نفسه إلى جمع البيانات بطريقة ما ويؤثر على البيانات المرصودة من خلال الإجراءات التي يقوم بها. لذلك، من المفيد أحياناً القيام بإجراءات مختلفة للحصول على بيانات جديدة.

الاستخراج: يعني تحديد أداء الوكيل باستخدام المعرفة الموجودة، والتي يتم عادةً تقييم أدائها بالمكافأة المتوقعة. على سبيل المثال، أصبح لمنقب الذهب الآن خاماً يزوده بغرامين من الذهب يومياً، وهو يعلم أن أكبر خام الذهب يمكن أن يعطيه خمس غرامات من الذهب يومياً. ومع ذلك، فهو يعلم أيضاً أن العثور على خام جديد لن يجبره على التوقف عن تعدين الخام الحالي فحسب، بل سيتكبده أيضاً تكاليف إضافية لأنه يخاطر في النهاية بعدم العثور على أي شيء. مع وضع ذلك في الاعتبار، قرر التنقيب في الخام الحالي لتعظيم الحد الأقصى من المكافأة (في هذه الحالة الذهب) من خلال الاستخراج، ويتخلى عن الاستكشاف بسبب المخاطر الكبيرة للاستكشاف. السياسة التي تبناها هنا هي سياسة جشعة، مما يعني أن الوكيل يؤدي باستمرار الإجراء الذي ينتج عنه أعلى مكافأة متوقعة بناءً على المعلومات الحالية، بدلاً من إجراء تجارب محفوفة بالمخاطر تقلل من المكافآت المتوقعة.

الاستكشاف: يعني زيادة المعرفة الحالية بالأفعال والتفاعل مع البيئة. بالعودة إلى منقب الذهب، على سبيل المثال، فإنه يتمنى أن يقضي بعض الوقت في البحث عن خام جديد، وإذا وجد خاماً ذهبياً أكبر، فيمكنه الحصول على المزيد من المكافآت كل يوم. للحصول على عوائد طويلة الأجل، قد يتم التضحية بالعوائد قصيرة الأجل. يواجه منجم الذهب دائماً مشكلة الاستخراج والاستكشاف، لأنه يتعين عليه تحديد مقدار منجم الذهب الذي يجب أن يبقى فيه ومقدار منجم الذهب الذي يجب أن يستمر في العمل. يصف التفاعل بين الاستكشاف والاستخراج التوازن بين مقدار جهد العامل في الاستكشاف والاستخراج، على التوالي. يعتبر التفاعل بين الاستكشاف والاستخراج موضوعاً رئيسياً لبحوث التعليم المعزز وتطوير خوارزميات التعلم المعزز.

مشكلة الاستكشاف مقابل الاستخراج هي موضوع متكرر في التعليم المعزز والذكاء الاصطناعي بشكل عام. هل علينا أن نستخلص من المعرفة المكتسبة، أي هل علينا أن نتبع مساراً معروفاً بمكافآت كبيرة؟ أم ينبغي علينا استكشاف المواقف المجهولة بحثاً عن سياسة جديدة أفضل؟ التوازن بين كل من استراتيجيات صنع القرار يحسن بشكل كبير

أداء التعلم للوكيل. الإجابة المقبولة لحلها هي أن أحد العوامل يحتاج أولاً إلى اكتشاف معظم المواقع ثم الحصول على نتائج أفضل من خلال استخراج المعرفة المتراكمة. لكن يجب ألا ننسى أنه في البيئات الديناميكية، من الصعب للغاية الحصول على ما إذا كان قد تم الاستكشاف الكافي أم لا. ومع ذلك، هناك عدة طرق لاختيار الإجراءات الموضحة أدناه.

إستراتيجية اختيار الجشع - إيسيلون

طريقة ممكنة وبسيطة وشائعة لكنها فعالة لاختيار الإجراء في كل مرحلة كاستراتيجية اختيار. في هذه الطريقة، يتحكم المعامل إيسيلون ϵ بين 0 و 1 في العامل الذي يعمل أثناء قيامه بالاستخراج أو الاستكشاف. باستخدام هذه الطريقة، في أي وقت، من المحتمل أن يختار الوكيل بين الاستكشاف والاستخراج. يستكشف مع الاحتمال ϵ والاختيار العشوائي من جميع العمليات المتاحة ومع احتمال $1 - \epsilon$.

تؤدي القيم العالية لـ ϵ إلى قيام الوكيل بمزيد من البحث، ونتيجة لذلك، تقلل من احتمالية التطبيق الأمثل. حيث أنه يمنح الوكيل القدرة على الاستجابة بسرعة للتغيرات التي تحدث في البيئة. في المقابل، تؤدي القيم المنخفضة للعامل ϵ إلى إجراءات أكثر كفاءة.

استكشاف بولتزمان

طريقة أخرى لتحديد الإجراءات هي سياسة توزيع بولتزمان. توزيع بولتزمان هو سياسة تعليمية تقلل من الميل للاستكشاف بمرور الوقت. ومن المفترض أنه مع تقدم التعلم، يتحسن النموذج الحالي. يخصص توزيع بولتزمان احتمالية لكل عملية باستخدام معامل T .

توزيع بولتزمان، باستخدام المعادلة التالية، يخصص احتمالية إيجابية لكل إجراء محتمل $a \in A$:

$$P(a|s) = \frac{e^{\frac{Q(s,a)}{T}}}{\sum_{a \in A} e^{\frac{Q(s,a)}{T}}}$$

حيث:

$$T_{\text{الجديدة}} = e^{-dj} * T_{\text{الحد الاكثر}} + 1$$

يرتبط الاجراء مع المزيد من $Q(s, a)$ باحتمال أكبر لـ P . يتناقص T مع زيادة التكرار j بمرور الوقت. وهكذا، مع تقدم التعلم، يتناقص الميل للاستكشاف في الوكيل، ونتيجة لذلك، تميل سياسة التعلم لتوزيع بولتزمان إلى أن تكون مشتقة من الاجراءات ذات $Q(s, a)$ العالية. تُضبط المعاملات الحد الاكثر T ومعدل الهبوط dz أولاً.

بناءً على النموذج مقابل بدون نموذج

كما ذكرنا سابقاً ، فإن الهدف الرئيسي للوكيل في التعلم المعزز هو تجميع أكبر قدر من المكافأة على "المدى الطويل". للقيام بذلك ، يجب على الوكيل إيجاد السياسة المثلى للسلوك في البيئة. يمكن أن تكون البيئة محددة أو عشوائية (غير مؤكدة). بمعنى ، إذا قام الوكيل بإجراء ما في موقف معين ، فقد لا تكون الحالة التالية للبيئة هي نفسها دائماً. من المؤكد أن هذه الشكوك تجعل من الصعب العثور على السياسة المثلى.

التنبؤ مقابل المراجعة

تشير إمكانية التنبؤ والمراجعة إلى مسألتين أساسيتين يجب على وكيل التعلم المعزز معالجتهما. يتطلب التنبؤ القدرة على حساب أو تقدير عواقب الإجراء. عادة ما تعني المشاكل التنبؤية تقدير قيم الحالات أو قيم الاجراء لأزواج الحالة-الاجراء. في المقابل، تتطلب المراجعة القدرة على اتخاذ القرارات. بدون مراجعة، الوكيل لا يتخذ أي إجراء.

مشكلة التنبؤ: بالنظر إلى عملية صنع القرار لماركوف $\langle S, A, P, R, \gamma \rangle$ والسياسة π ، يجب إيجاد دالة القيمة $v(\pi)$. بعبارة أخرى، الهدف هو فهم مدى جودة السياسة.

مشكلة المراجعة: وفقاً لعملية صنع القرار الخاصة بماركوف $\langle S, A, P, R, \gamma \rangle$ ، يجب العثور على القيمة المثلى لـ $v(\pi)$ والسياسة المثلى π^* . بمعنى آخر، الهدف هو العثور على السياسة التي توفر أكبر قدر من المكافأة مع أفضل إجراء للاختيار من بينها.

كما نعلم ، في التعلم المعزز ، غالباً ما تتم المشكلة من وجهة نظر رياضية كعملية صنع قرار ماركوف. عملية صنع القرار في ماركوف هي طريقة لإظهار "ديناميكيات" البيئة ؛ أي كيف تتفاعل البيئة مع الإجراءات المحتملة للوكيل في موقف معين. بتعبير أدق ، تم تجهيز عملية صنع القرار في ماركوف بدالة التحويل (النقل) ، وهي دالة ، نظراً للحالة الحالية للبيئة والعلم الذي قد يؤديه الوكيل ، تجعل من الممكن التحويل إلى أي من المخرجات. ترتبط دالة المكافأة أيضاً بعملية صنع القرار في ماركوف.

تتم مكافأة دالة المكافأة وفقاً للحالة الحالية للبيئة وربما الإجراء الذي يقوم به الوكيل والحالة التالية للبيئة. غالباً ما تسمى دوال المكافأة والتحويل بأنماط البيئة. ومع ذلك ، في بعض الأحيان ليس لدينا دوال المكافأة والتحويل. ومن ثم لا يمكننا تقدير السياسة لأنها غير معروفة. في غياب هذه الدوال ، لتقدير السياسة المثلى ، من الضروري التفاعل مع البيئة ومراقبة استجاباتها ، والتي يشار إليها غالباً باسم "مشكلة التعلم المعزز". لأنه ، يجب على الوكيل تقدير السياسة من خلال تعزيز معتقداته حول ديناميكيات البيئة.

بمرور الوقت ، يبدأ الوكيل في فهم كيفية تفاعل البيئة مع أفعاله ويمكنه تقدير السياسة المثلى. لذلك ، في مشاكل التعليم المعزز ، يتم تقدير عامل السياسة الأمثل للسلوك في بيئة غير مألوفة من خلال التفاعل معها باستخدام طريقة "التجربة والخطأ". وفقاً لذلك ، يمكن تقسيم خوارزميات التعلم المعزز إلى خوارزميات قائمة على النموذج أو غير قائمة على النموذج.

في الخوارزميات القائمة على النموذج ، يمكن للوكيل الوصول إلى نموذج كامل للبيئة ، أو يحاول تعلمه من خلال التفاعل ، ويستخدم دالة النقل والمكافأة لتقدير السياسة المثلى بدقة. بمعنى آخر ، يحاول الوكيل أخذ عينات من النموذج الاحتمالي وتعلمه واستخدامه لتحديد أفضل الاجراءات. يجوز للوكيل فقط الوصول إلى دوال التحويل والمكافأة التقريبية التي تعلمها الوكيل. حيث أنه يتفاعل مع البيئة أو يمكن أن يعطى لوكيل واحد من خلال وكيل آخر ، على سبيل المثال.

بشكل عام ، في الخوارزمية القائمة على النموذج ، يمكن للوكيل توقع ديناميكيات البيئة أثناء أو بعد مرحلة التعلم. هذا لأنه يحتوي على تقدير لدوال التحويل ودالة المكافأة ، وإذا تم التعرف على احتمالية النقل بنجاح ، فإن الوكيل يعرف مدى احتمالية الدخول في حالة معينة بالنظر إلى الحالة الحالية والإجراء. وتصدر الإشارة ، مع ذلك ، إلى أن دوال التحويل والمكافأة التي يستخدمها الوكيل لتحسين تقدير سياسته المثلى قد تكون مجرد تقريب للدوال "الحقيقية". ومن ثم قد لا يتم العثور على السياسة المثلى بسبب هذه التقريبات.

على عكس الخوارزميات القائمة على النموذج ، لا تمتلك الخوارزميات غير النموذجية معرفة أساسية بدالة التحويل ويجب أن تتعلمها أثناء التعلم لإيجاد مسارات

فعالة. بعبارة أخرى، تقدر الخوارزمية غير المعدلة إما "دالة القيمة" أو "دالة السياسة" مباشرة من التجربة، أي من خلال التفاعل بين الوكيل والبيئة، دون استخدام دوال التحويل والمكافأة.

تتمثل إحدى طرق التمييز بين الأساليب القائمة على النموذج وغير القائمة على النموذج في: هل يمكن للوكيل التنبؤ بالحالة التالية والمكافأة قبل بدء أي نشاط ما بعد التعلم؟ بمعنى آخر، تتمثل طريقة التمييز بين الخوارزميات القائمة على النموذج أو غير القائمة على النموذج في فحص الخوارزميات ومعرفة ما إذا كانت تستخدم دوال التحويل والمكافأة. إذا تم استخدامها، فهي عبارة عن خوارزمية التعليم المعزز القائمة على النموذج.

كلتا الطريقتين لها نقاط قوة ونقاط ضعف. تتضمن الطرق غير النموذجية إلى حد ما أنها ستعثر في النهاية على السياسة المثلى ولديها وقت حساب ضئيل جداً لكل تجربة. ومع ذلك، فهم يستخدمون البيانات أثناء اختبار غير فعال للغاية، وبالتالي غالباً ما يتطلبون قدرًا كبيرًا من الخبرة لتحقيق أداء جيد. في المقابل، يمكن للخوارزميات القائمة على النموذج التغلب على هذه المشكلة، لكن الوكيل يتعلم فقط من أجل نموذج معين وأحياناً لا يكون مناسباً لبعض النماذج الأخرى. يستغرق الأمر أيضاً وقتاً لتعلم نموذج آخر.

من المزايا المهمة لامتلاك نموذج أنه يسمح للوكيل بالتخطيط للمستقبل ومعرفة ما سيحدث لمجموعة واسعة من الإجراءات المختلفة التي يمكنه القيام بها في حالته الحالية. ثم قارن هذه النتائج عندما تقرر التصرف. يمكن أن يؤدي هذا إلى تحسن كبير في الأداء مقارنة بالخوارزميات التي لا تستخدم النموذج. تعتمد الخوارزميات التي لا تعتمد على النموذج فقط على "التجربة والخطأ" لتحديث معارفهم. لذلك، لا يحتاجون إلى تخزين جميع مجموعات الحالات والإجراءات.

يمكن تصنيف النهج غير النموذجي على أنه داخل السياسة¹ وخارج السياسة². تستخدم الأساليب داخل السياسة الحالية لإنشاء الإجراءات واستخدامها

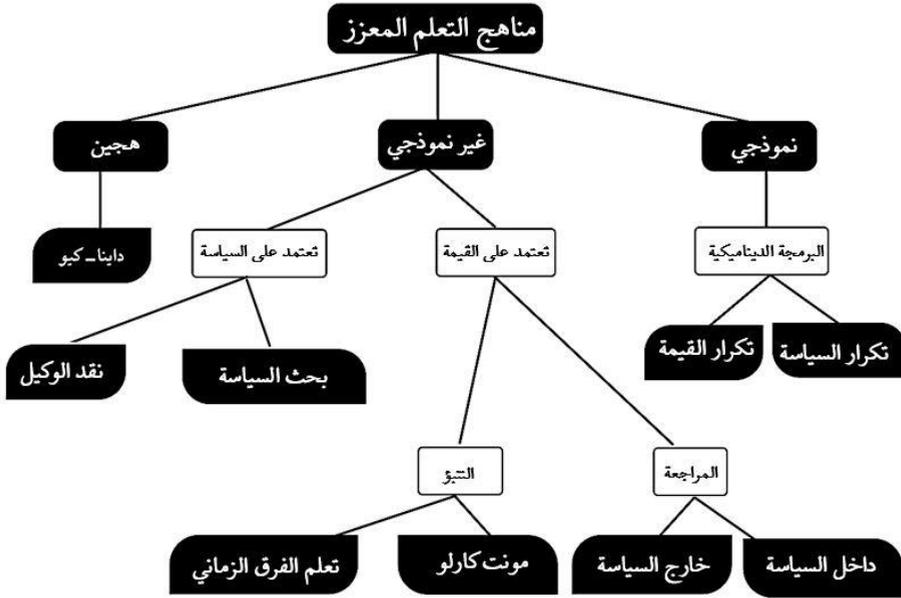
¹ on-policy

² off-policy

لتحديث السياسة الحالية. في حين أنه، في الأساليب الخارجة عن السياسة، يتم استخدام سياسة استكشافية مختلفة لإنشاء إجراءات مقارنة بالسياسة الناشئة.

المناهج الكلاسيكية للتعلم المعزز

الآن بعد أن أصبحت على دراية بالمفاهيم الأساسية للتعلم المعزز، سنقوم في هذا القسم بوصف المناهج الكلاسيكية للتعلم المعزز في حل المشكلات. يمكن تقسيم هذه المناهج إلى نموذجية، وغير نموذجية، ومجموعة من النهجين، كما هو موضح في الشكل 3-4. فيما يلي، سوف ندرس هذه المناهج.



الشكل 3-4 كيفية تقسيم مناهج التعليم المعزز.

البرمجة الديناميكية¹

يشير مصطلح البرمجة الديناميكية إلى مجموعة من الخوارزميات التي يمكن استخدامها لحساب السياسة المثلى وفقاً لنموذج كامل للبيئة كعملية ماركوف لاتخاذ القرار. الفكرة الرئيسية للبرمجة الديناميكية والتعليم المعزز بشكل عام هي استخدام دوال القيمة لتنظيم

¹ Dynamic programming

هيكل البحث عن سياسات جيدة. خوارزميات البرمجة الديناميكية الكلاسيكية لها تطبيق محدود في التعليم المعزز بسبب افتراض نموذج كامل وأيضاً بسبب التكلفة الحسابية العالية. ومع ذلك، لا تزال هذه الأساليب مهمة من الناحية النظرية.

تتضمن البرمجة الديناميكية نسختين مختلفتين من كيفية تنفيذها: تكرار السياسة وتكرار القيمة. فيما يلي، سوف نصف بإيجاز هذين النهجين.

تكرار السياسة

عندما يتم تحسين سياسة π باستخدام v_π للحصول على سياسة π' أفضل، يمكن حساب $v_{\pi'}$ وإعادة تحسينها للحصول على سياسة π'' أفضل. الحصول على قواعد موحدة ودوال القيمة:

$$\pi_0 \xrightarrow{E} v_{\pi_0} \xrightarrow{I} \pi_1 \xrightarrow{E} v_{\pi_1} \xrightarrow{I} \pi_2 \xrightarrow{E} \dots \xrightarrow{I} \pi_* \xrightarrow{E} v_*,$$

إنه مضمون أن كل سياسة سيتم تحسينها عن السياسة السابقة؛ ما لم يكن هو بالفعل الأمثل. نظراً لأن عملية صنع القرار في ماركوف المحدود لا تحتوي إلا على عدد محدود من السياسات، يجب أن تتقارب هذه العملية مع سياسة واحدة ودالة القيمة المثلى في عدد محدود من التكرارات.

تسمى هذه الطريقة للعثور على السياسة المثلى تكرار السياسة. وتجدر الإشارة إلى أن كل تقييم للسياسة، والذي يعد بحد ذاته حساباً تكرارياً، يبدأ بدالة قيمة للسياسة السابقة. وعادة ما يؤدي هذا إلى زيادة هائلة في سرعة تقارب تقييم السياسات؛ ربما لأن دالة القيمة تتغير قليلاً من سياسة إلى أخرى.

تكرار القيمة

تتمثل إحدى عيوب طريقة تكرار السياسة في أن كل تكرار يتضمن تقييماً للسياسة، والذي قد يتضمن في حد ذاته حساباً متكرراً طويلاً يتطلب تحولات متعددة في مجموعة الحالات. في حالة تكرار تقييم السياسة، يحدث التقارب تماماً مع v_π فقط ضمن النطاق المسموح به. نتيجة لذلك السؤال الذي يطرح نفسه، هل يجب أن نتظر تقارباً دقيقاً أم يمكننا التخلي عنه؟

يمكن تقصير خطوة تقييم السياسة، وتكرار السياسة بعدة طرق دون فقدان ضمان تقارب تكرار السياسة. تعتبر الحالة الخاصة مهمة عندما يتم إيقاف تقييم السياسة بعد خطوة واحدة فقط. تسمى هذه الخوارزمية تكرار القيمة، والتي يمكن كتابتها كعملية دعم بسيطة تجمع بين تحسين السياسة وخطوات تقييم السياسة:

$$\begin{aligned} v_{k+1}(s) &= \max_a \mathbb{E}[R_{t+1} + \gamma v_k(S_{t+1}) | S_t = s, A_t = a] \\ &= \max_a \sum_{\acute{s}, r} p(\acute{s}, r | s, a) [r + \gamma v_k(\acute{s})] \end{aligned}$$

لأي v_0 مرغوب فيه، يمكن إظهار أن التسلسل $\{v_k\}$ يمكن أن يتقارب مع v^* في ظل نفس الظروف التي تضمن وجود v^* .

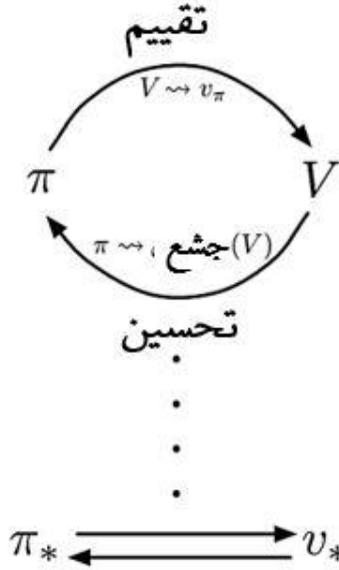
أخيراً، لتأمل كيف ينتهي تكرار القيمة. مثل تقييم السياسة، يتطلب تكرار القيمة رسمياً عدداً غير محدود من التكرارات لتتقارب تماماً من الناحية العملية، ونتوقف عندما تتغير دالة القيمة بمقدار صغير فقط في نوبة واحدة.

تكرار خط السياسة المعمم¹

يتضمن تكرار السياسة عمليتين متزامنتين ومتبادلتين، واحدة تجعل دالة القيمة متوافقة مع السياسة الحالية (تقييم السياسة)، والأخرى جشع للسياسة فيما يتعلق بدالة القيمة الحالية (تحسين السياسة). في تكرار السياسة، تكون هاتان العمليتان متناوبتين وتكتملان قبل أن تبدأ العملية الأخرى، لكن هذا ليس ضرورياً حقاً. على سبيل المثال، في عمليات تكرار القيمة، يتم إجراء تكرار واحد فقط لتقييم السياسة بين كل تحسين للسياسة.

يستخدم مصطلح تكرار السياسة المعمم للإشارة إلى الفكرة العامة للسماح بالتفاعل بين عمليات تقييم السياسة وتحسين السياسة، بغض النظر عن تفاصيل العمليتين. يظهر المخطط العام لتكرار السياسة المعمم في الشكل 4-4.

¹ generalized policy iteration (GPI)



شكل 4-4 تكرار السياسة المعمم. تتفاعل دوال القيمة والسياسة طالما أنها مثالية وبالتالي متوافقة.

من السهل أن نرى أنه في حالة استمرار كل من عملية التقييم وعملية التحسين، أي أنهما لم يعدا يتغيران، فيجب أن تكون دالة القيمة والسياسة هي الأمثل. تصبح دالة القيمة مستقرة فقط عندما تكون متوافقة مع السياسة الحالية، وتصبح السياسة مستقرة فقط عندما تكون جشعة فيما يتعلق بدالة القيمة الحالية. لذلك، يتم تثبيت كلتا العمليتين فقط عندما يتم العثور على سياسة جشعة لدالة التقييم الخاصة بها. يوضح هذا أن معادلة تحسين بلمان ثابتة، وبالتالي فإن السياسة والقيمة هما القيمتان الأمثلتان.

يمكن اعتبار عمليات التقييم والتحسين في تكرار السياسة العامة بمثابة منافسة وتعاون. على المدى الطويل، تتفاعل هاتان العمليتان لإيجاد حل مشترك: دالة القيمة المثلى والسياسة المثلى.

مونت كارلو

على عكس البرمجة الديناميكية، تتعلم طريقة مونت كارلو من التجربة فقط. من نواح كثيرة، يمكن اعتباره أبسط طريقة للتعلم المعزز. تحدد طريقة مونت كارلو قيمة الحالة بتمريرها عدة مرات ومتوسط إجمالي المكافأة المستلمة بعد الموافقة على الحالة. نظرًا لأن إجمالي المكافأة المستلمة قبل إكمال المرحلة غير معروف، فإن طريقة مونت كارلو

تنطبق فقط على مرحلة الاجراء. لا يتم التحديث إلا بعد انتهاء الحركة في مساحة الحالة، والتي تسمى التحديث غير المتصل (التحديث أثناء التنقل في مساحة الحالة يسمى التحديث الاونلاين). بالإضافة إلى ذلك، في طريقة مونت كارلو، تستند القيم إلى التجربة الفعلية، وليس على قيم الحالات البديلة.

تعتمد طرق مونت كارلو على فكرة تكرار السياسة المعمم. كما ذكرنا سابقاً، يعد تكرار السياسة المعمم مخططاً تكرارياً ويتكون من خطوتين. في الخطوة الأولى، نحاول إنشاء تقريب دالة القيمة بناءً على السياسة الحالية، والتي تُعرف باسم خطوة تقييم السياسة. في الخطوة الثانية، يتم تحسين السياسة وفقاً لدالة القيمة الحالية، والتي تُعرف بخطوة تحسين السياسة. في طريقة مونت كارلو، لتقدير دالة القيمة، يتم تنفيذ البرامج عن طريق تشغيل السياسة الحالية على النظام. يتم استخدام المكافأة التراكمية طوال المرحلة وتوزيع الحالات التي تمت مواجهتها لتشكيل تقدير لدالة القيمة. بعد ذلك، يتم تقدير السياسة الحالية بجشع وفقاً لدالة القيمة الحالية. باستخدام هاتين الخطوتين بشكل متكرر، يمكن إظهار أن الخوارزمية تتقارب مع القيمة المثلى ودالة السياسة. على الرغم من أن طرق مونت كارلو سهلة التنفيذ، إلا أنها تتطلب عدداً كبيراً من التكرارات لتتقارب وتعاني من تباين كبير في تقدير دالة القيمة.

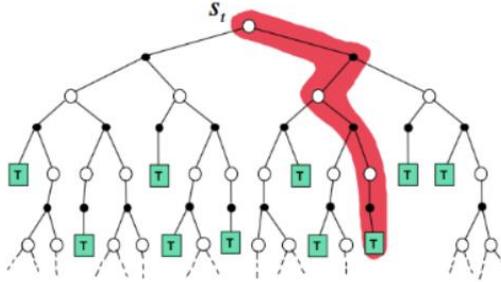
تعلم الفرق الزمني

يتضمن تعلم الفرق الزمني أفكار البرمجة الديناميكية ومونت كارلو. يقترب نهج الفرق الزمني من قيمة زوج الحالة-الإجراء من خلال مقارنة التقديرات عند نقطتين في الوقت المناسب، ومن هنا جاء اسم الفرق الزمني. مثل البرمجة الديناميكية، تتعلم خوارزميات تعلم فرق الوقت تقدير القيم بناءً على تقديرات أخرى (تسمى البوتسترايبينك¹). أيضاً، يمكن تعلم الفرق الزمني، مثل طريقة مونت كارلو، مباشرة من التجربة دون معرفة مسبقة بالبيئة. هذا يعني أن تعلم الفرق الزمني هو نهج تعليمي غير نموذجي (أو يمكن معادلتها بالتعلم غير الخاضع للإشراف).

¹ bootstrapping

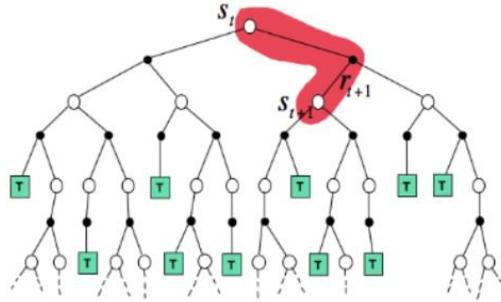
مونت كارلو

$$V(S_t) \leftarrow V(S_t) + \alpha (G_t - V(S_t))$$



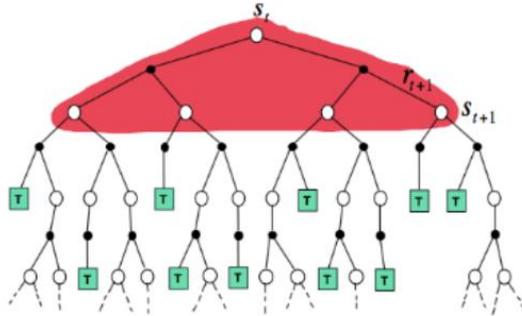
الفرق الزمني

$$V(S_t) \leftarrow V(S_t) + \alpha (R_{t+1} + \gamma V(S_{t+1}) - V(S_t))$$



البرمجة الديناميكية

$$V(S_t) \leftarrow \mathbb{E}_\pi [R_{t+1} + \gamma V(S_{t+1})]$$



الشكل 4-5 مقارنة بين مخططات دعم مونت كارلو وتعلم الفرق الزمني والبرمجة الديناميكية لدوال الحالة-القيمة

الفكرة الرئيسية لمنهج تعلم الفرق الزمني هي التعلم بناءً على الفرق بين تنبؤات الوقت المتتالية، ولا داعي للانتظار حتى نهاية المسار للتحديث. بمعنى آخر، الغرض من التعلم هو جعل التنبؤ الحالي للمتعلم لنمط الإدخال الحالي أكثر اتساقاً مع التنبؤ التالي في الخطوة التالية. تكمن فكرة هذه الطريقة في أنه بعد ملاحظة بعض المكافآت التي حصل عليها الوكيل بعد زيارة حالة ما وتنفيذ إجراء معين، فمن الممكن تقديم تقدير أفضل لمقدار زوج بين الحالة-الإجراء.

أساليب مونت كارلو والبرمجة الديناميكية لها نقاط ضعف خطيرة؛ مونت كارلو غير قادر على حل المشكلات المستمرة، وتتطلب البرمجة الديناميكية نموذجاً للبيئة. يستخدم تعلم الفرق الزمني عينة احتياطية في طريقة مونت كارلو والتمهيد في طريقة البرمجة الديناميكية في نفس الوقت. لذلك، يتم الجمع بين الأجزاء الجيدة فقط من الطرق السابقة.

تستخدم طريقة مونت كارلو المكافأة الإجمالية لتحديث دالة القيمة. حيث إن تعلم الفرق الزمني، بدلاً من تحديث القيم في نهاية المرحلة (باستخدام المكافأة الإجمالية)، تقوم بتحديث القيم أونلاين في كل مرحلة.

يمكن استخدام مخطط الدعم لمقارنة الأساليب الثلاثة ، مونت كارلو ، البرمجة الديناميكية ، وتعلم الفرق الزمني. يمكن رؤية مقارنة بين هذه الأساليب الثلاثة بناءً على مخطط الدعم للحالة والقيمة في الشكل 4-5.

غالبًا ما يشير تعلم الفرق الزمني إلى مشكلة تنبؤ بقاعدة تحديث لدالة قيمة معينة:

$$V(s) \leftarrow V(s) + \alpha(r + \gamma V(\acute{s}) - V(s))$$

حيث α هو معدل التعلم و γ هو عامل الهبوط. يُعرف الجزء الموجود بين قوسين باسم خطأ الفرق الزمني:

$$\delta_t = r + \gamma V(\acute{s}) - V(s)$$

تُستخدم طريقة اتعلم الفرق الزمني للتنبؤ بطريقتين مختلفتين للمراجعة. والفرق الرئيسي بين الطريقتين هو أن إحداها في السياسة والأخرى خارج السياسة.

الخوارزمتان المستخدمتان على نطاق واسع في التعليم المعزز هما Sarsa و Q-Learning. في ما يلي ، سوف نفحص هذين النوعين من خوارزميات الفرق الزمني.

Sarsa (في السياسة)

Sarsa هي طريقة تعليم معزز بالفرق الزمني تتعلم الإجراء بدلاً من دالة القيمة في محاولة لتقدير دالة القيمة. تمت تسمية هذا الميراث باسم: ("الحالة"، "الإجراء"، "المكافأة"، "الحالة التالية"، "الإجراء التالي"). هذا النهج يكون في السياسة، لأنه يقدر $Q_{\pi}(s, a)$ للسياسة الحالية. قاعدة تحديث الحالة-القيمة هي كما يلي:

$$Q(s, a) \leftarrow Q(s, a) + \alpha(r + \gamma Q(s', a) - Q(s, a))$$

يمكن إثبات أن Sarsa يتقارب مع السياسة المثلى عند زيارة جميع أزواج غير محددة من الاجراء-الحالة.

Q-Learning (خارج السياسة)

يُطلق على تعلم الفرق الزمني خارج سياسة ب Q-Learning، وهو أحد أكثر الأساليب الأساسية والأكثر شيوعاً لتقدير دوال قيمة Q بطريقة غير نموذجية. قاعدة تحديث هذه الطريقة هي كما يلي:

$$Q(s, a) \leftarrow Q(s, a) + \alpha(r + \gamma \max_{a'} Q(s', a') - Q(s, a))$$

تحاول Q-Learning بذل قصارى جهدها في الوضع الحالي. تعتبر هذه الخوارزمية خارج السياسة. وذلك لأن دالة Q-Learning تتعلم من الإجراءات خارج السياسة الحالية. بشكل عام، تسعى Q-Learning إلى تعلم السياسة من أجل تعظيم المكافأة الإجمالية. اليوم ، تعتمد العديد من خوارزميات التعلم العميق المعزز على Q-Learning.

Q-Learning غير مبال بالاستكشاف. وهذا يعني أنه بغض النظر عن السياسة الاستكشافية المتبعة ، فإنها تتقارب مع السياسة المرغوبة ؛ بافتراض أن كل زوج من إجراءات الحالة تمت زيارته عدداً غير محدود ويتم تقليل معامل التعلم α بشكل مناسب.

البحث في السياسة

لا تحتاج طرق البحث في السياسة إلى الحفاظ على نموذج دالة القيمة، ولكنها تبحث مباشرة عن السياسة المثلى π^* . من بين خوارزميات البحث عن السياسة في التعلم المعزز، تعد خوارزمية التدرج السياسي هي الأكثر شيوعاً.

الغرض من التعلم المعزز هو إيجاد استراتيجية سلوك مثالية للوكيل للحصول على المكافآت المثلى. تعمل طرق التدرج السياسي مباشرة على نمذجة السياسة وتحسينها. يتم تقييم هذه السياسة من خلال تنفيذ الإجراءات المنصوص عليها في السياسة الحالية وحساب المكافأة. ثم يتم تحديث معاملات السياسة لزيادة العائد المتوقع باستخدام التدرج التنازلي. يمكن كتابة قاعدة التحديث لمعاملات السياسة على النحو التالي وفقاً للعائد المتوقع J :

$$\theta_{i+1}^{\pi} = \theta_i^{\pi} + \alpha \nabla_{\theta} \pi_j, j = \mathbb{E}_{\pi} \left(\sum_{k=0}^{\infty} \gamma^k r_k \right)$$

البحث في السياسة لديه تقارب أفضل ويمكن أن يتعلم سياسات عشوائية غير ممكنة مع الأساليب القائمة على القيمة. العيب الرئيسي لخوارزميات السياسة هو مرحلة تقييم السياسة، والتي تعاني من تباين كبير وبالتالي يمكن أن تكون بطيئة في تعلم السياسات الجيدة.

نقد الوكيل

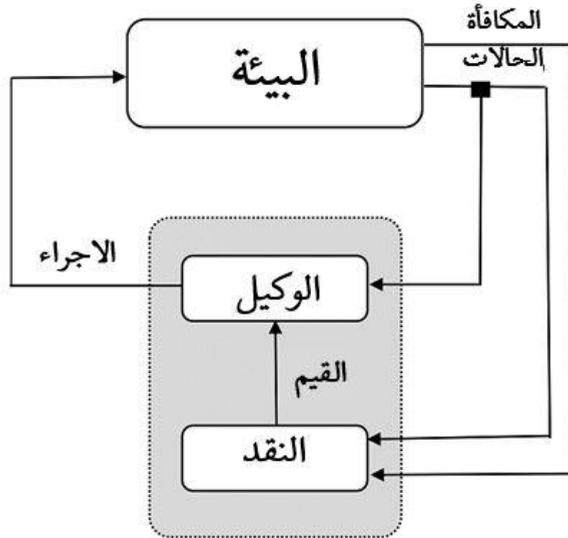
طرق التدرج السياسي النقي بطيئة التعلم بسبب تقديرات التباين العالية وغير مناسبة لأداء المشكلات الاونلاين. ومع ذلك، يمكن استخدام طرق الفرق الزمني للتعامل مع هذه المشاكل.

تتطلب مقاربات دالة القيمة نظرياً التغطية الكاملة لمساحة الحالة والقيم المضخمة المقابلة لجميع العمليات الممكنة في كل حالة. لذلك، عند العمل مع التطبيقات عالية

الأبعاد، فإنه يحتوي على الكثير من التعقيد الحسابي، وأيضاً، قد يتسبب تغيير بسيط في القيم المضخمة المحلية في حدوث تغيير كبير في السياسة.

على عكس طرق دالة القيمة، تراعي طرق بحث السياسة الحالية والسياسة التالية للسياسة الحالية، ثم تحسب التغييرات في معاملات السياسة، مما يؤدي إلى تعقيد حسابي أقل بكثير من أساليب دالة القيمة. ومع ذلك، قد تؤدي مناهج بحث السياسة إلى التحسين المحلي وتفشل في تحقيق التحسين العالمي.

من خلال الجمع بين هذين النهجين، تتعلم طرق نقد الوكيل في نفس الوقت سياسة ودالة الحالة-القيمة. يُعرف هذا النهج، الذي يتم تقديمه من خلال الجمع بين دالة القيمة ونهج البحث عن السياسة للاستفادة من كلتا الطريقتين، باسم هيكل نقد الوكيل. يمكن القول إن طريقة نقد الوكيل هي طريقة تعلم الفرق الزمني التي تخزن السياسة بشكل صريح. كما هو مبين في الشكل 4-6، يتم اختيار الإجراء بواسطة وكيل التحكم ويتم استخدام النقد لنقل القيم إلى الوكيل. لذلك، يعتمد قرار تحديث السياسة على هذا النقد.



الشكل 4-6 بُنية نقد الوكيل

الطريقة المشتركة (داينو-كيو¹)

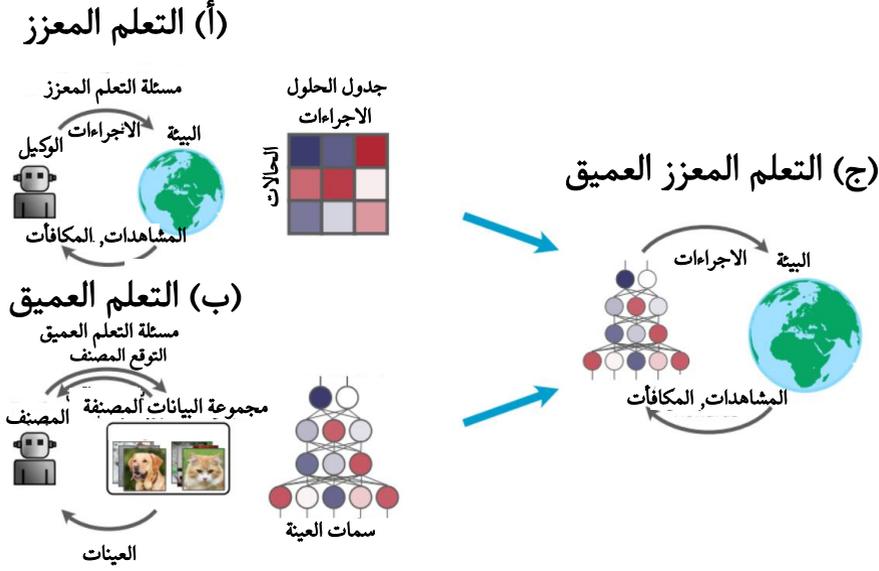
داينا-كيو هي إحدى البنى التي لديها القدرة على الجمع بين القدرة على التعلم بطريقة بدون نموذج والقدرة على البرمجة في الأساليب القائمة على النموذج. تتعلم الخوارزمية نموذجًا من خلال رؤية الحالات التي تتم زيارتها والمكافآت التي تتلقاها في حالة معينة، وتستخدم المعلومات لتحديث احتمالات النقل ودالة المكافأة.

التعلم المعزز العميق

عند التعامل مع قضايا المجال عالي الأبعاد أو العوامل الاونلاين، يعاني التعلم المعزز من مشكلة عرض الميزات غير الفعال. لذلك، وقت التعلم بطيء ويجب تصميم التقنيات لتسريع عملية التعلم. ومن ثم، ظهر مجال جديد يسمى التعلم المعزز العميق للمساعدة في حل التعلم المعزز في المشاكل عالية الأبعاد. أهم ميزة في التعلم العميق هي أن الشبكات العصبية العميقة يمكنها أن تجد تلقائيًا تمثيلات مضغوطة للبيانات عالية الأبعاد. يجمع التعلم المعزز العميق بين فوائد التعلم العميق والتعلم المعزز لبناء أنظمة ذكاء اصطناعي.

يستخدم التعلم المعزز العميق قوة تمثيل التعلم العميق للتعامل مع الصعوبات الموجودة في التعلم المعزز. يمكن تعريف نظام التعلم المعزز العميق على أنه نظام يزيد من المكافأة طويلة المدى في مشكلة التعلم المعزز باستخدام التمثيلات التي تعلمتها الشبكة العميقة نفسها (بدلاً من المصمم). يوضح الشكل 4-7 كيف يعمل التعلم المعزز العميق ويقارن بينها. كما هو موضح في الصورة، في التعلم المعزز، يتم استخدام الشبكات العصبية كعامل لحل مشكلة التعلم المعزز.

¹ Dina Q



الشكل 4-7 التعلم المعزز والتعلم العميق والتعلم المعزز العميق.

على مدار السنوات العديدة الماضية، حظي التعلم المعزز العميق باهتمام كبير في مجتمع الذكاء الاصطناعي. يشير التعلم المعزز العميق إلى استخدام الشبكات العصبية العميقة كتقريب للدوال في القيمة أو دالة السياسة في إطار التعلم المعزز، وقد تم تطبيقه بنجاح في التدرج السياسي، وتعلم-كيو، وطرق نقد الوكيل. في الجزء المتبقي من هذا القسم، نصف خوارزميات التعلم المعزز العميق للتعلم المعتمد على Q.

شبكة كيو العميقة¹ (DQN)

تعلم كيو (Q-learning) هي خوارزمية بسيطة لكنها قوية جداً لإنشاء صفحة قائمة فهرس للوكيل. يساعد هذا الوكيل في تحديد الإجراء الذي يجب اتخاذه بالضبط، ولكن ماذا لو كانت صفحة القائمة طويلة جداً؟ تخيل بيئة بها 10000 حالة و 1000 إجراء في كل حالة. يؤدي هذا إلى إنشاء جدول يضم 10 ملايين خلية وكل شيء يخرج عن نطاق السيطرة بسرعة! من الواضح أنه لا يمكننا استنتاج قيمة Q للحالات الجديدة من الحالات التي تم فحصها مسبقاً. يشير هذا إلى مشكلتين: أولاً، يزداد حجم الذاكرة المطلوبة لتخزين الجدول وتحديثه مع زيادة عدد الحالات. ثانياً، مقدار الوقت المستغرق لاستكشاف كل موقف لإنشاء جدول Q غير عملي. هذا هو المكان الذي تبرز فيه الفكرة:

¹ Deep Q Learning

ماذا يحدث إذا قدرنا قيم Q هذه بنماذج الشبكة العصبية؟ حسنًا ، هذه هي الفكرة من وراء خوارزمية DeepMind ، والتي أدت إلى شرائها Google مقابل 500 مليون دولار!

شبكة كيو العميقة ، أو DQN باختصار ، عبارة عن خوارزمية قائمة على القيمة تستخدم شبكة عصبية $Q(s, a|\theta)$ لتحسين الإجراء - القيمة Q^* لكل عملية في حالة معينة على النحو الأمثل. سنستبدل الشبكة العصبية التي تحاول تقريب قيم Q . يتم إعطاء الحالة كمدخلات ويتم إنشاء قيمة Q لجميع الإجراءات الممكنة كمخرجات. يتم حساب أهداف التدريب لـ Q باستخدام معادلة بلمان:

$$Q(s, a, \theta) = r + \gamma \max_{\hat{a}} Q(\hat{s}, \hat{a}, \hat{\theta})$$

لتدريب الشبكة العصبية ، نحتاج إلى دالة الخسارة ، والتي تستخدم في شبكة كيو العميقة متوسط الخطأ التربيعي في معادلة بلمان:

$$\begin{aligned} c(\theta|\theta') &= \frac{1}{m} \sum_j \left(r_j + \gamma \underbrace{Q(s_{j+1}, \pi(s_{j+1}|\theta'))}_{y_j} - Q(s_j, \pi(s_j|\theta)) \right)^2 \\ &= \frac{1}{m} \sum_j \left(r_j + \gamma \underbrace{\max_a Q(s_{j+1}, a|\theta')}_{y_j} - \max_a Q(s_j, a|\theta) \right)^2. \end{aligned}$$

ومع ذلك، فإن اعتماد أهداف Q على نفسها يمكن أن يؤدي إلى عدم الاستقرار أو حتى الاختلاف في التعلم. وجود مجموعة ثانية من معاملات الشبكة $\theta' = LP(\theta)$ ، حيث LP هو فلتر تمرير منخفض (على سبيل المثال، المتوسط المتحرك الأسّي) ، يعمل على استقرار التعلم.

يمكن أن ينتج عدم الاستقرار الإضافي عن التدريب المباشر على الحالة والمكافآت المستلمة. لأنه، على عكس التعلم الخاضع للإشراف، فإن بيانات الإدخال (زوج الحالة - الاجراء) مرتبطة بشكل كبير وتشكل جزءاً من المسار. نتيجة لذلك، سوف تتسع الشبكة بشكل زائد ولن تكون الشبكة قادرة على التعلم بشكل فعال. بالإضافة إلى ذلك، قد تتغير السياسة وبالتالي توزيع البيانات بسرعة مع تطور Q . يحل DQN كلتا المشكلتين عن طريق تخزين جميع الانتقالات s_t, a_t, r_t, s_{t+1} في مجموعة بيانات الذاكرة ثم التعلم في مجموعات فرعية تتكون من عمليات نقل عشوائية من تلك المجموعة. بمعنى آخر، في أي وقت، يتم استخراج عدد معين من العينات عشوائياً من الذاكرة واستخدامها للتدريب

على الشبكة، مما يؤدي إلى تعلم أفضل عبر الشبكة. تكسر هذه الحيلة ارتباط بيانات الإدخال وتسهل التغييرات في توزيع المدخلات.

الفرق الوحيد بين Q-Learning و شبكة Q العميقة هو الدماغ العامل. يعمل الدماغ في جدول Q في Q-Learning، ولكن في DQN يقوم الدماغ بتشغيل شبكة عصبية عميقة. سيكون الإدخال إلى الشبكة العصبية عبارة عن حالات، وسيكون عدد الخلايا العصبية الناتجة هو عدد الإجراءات التي يمكن للوكيل تنفيذها.

شبكة كية العميقة المزدوجة¹

تتمثل إحدى مشكلات خوارزمية DQN في أنها تتبالغ في تقدير المكافأة الفعلية. تفترض قيم Q أن الوكيل ينوي تحقيق عائد أعلى مما سيتم تحقيقه بالفعل. شبكة كيو العميقة المزدوجة هي امتداد لشبكة كيو العميقة لتقليل المبالغة في التقدير بحيلة بسيطة لفصل اختيار الإجراءات عن تقييم الإجراءات. في هذا النوع من الشبكات، يتم تغيير معادلة بلمان في DQN على النحو التالي:

$$Q(s, a, \theta) = rQ(s, \operatorname{argmax}_{\hat{a}} Q(s, \hat{a}, \theta); \hat{\theta})$$

أولاً، تقرر الشبكة العصبية الرئيسية θ أيًا من أفضل الإجراءات التالية \hat{a} موجود بين جميع الإجراءات اللاحقة، ثم تقوم الشبكة العصبية بتقييم هدف هذا الإجراء لمعرفة قيمته Q. لقد ثبت أن هذه الحيلة البسيطة تقلل من المبالغة في التقدير، مما يؤدي إلى سياسات نهائية أفضل.

تستخدم شبكة كيو العميقة المزدوجة نموذجين متطابقين للشبكة العصبية. يتعلم المرء تمامًا مثل شبكة كيو العميقة أثناء تجربة إعادة التشغيل والآخر هو نسخة من الجزء الأخير من النموذج الأول. يتم احتساب قيمة Q بالفعل مع هذا النموذج الثاني، لماذا؟ في DQN، يتم حساب قيمة Q مع إضافة المكافأة إلى الحد الأقصى لقيمة Q في الحالة التالية. من الواضح، إذا كانت قيمة Q في كل مرة تحسب فيها عددًا كبيرًا لحالة معينة، فإن القيمة التي تم الحصول عليها من ناتج الشبكة العصبية لهذا الموقف المعين ستزداد في كل مرة. يصبح كل خلية عصبية ناتجة أكبر وأكبر طالما أن الفرق بين كل قيمة ناتجة كبير. الآن، إذا افترضنا أنه بالنسبة للحالات، يكون للإجراء a قيمة أعلى من الإجراء b ،

¹ Double

لذلك يتم تحديد الإجراءات أ للحالات في كل مرة. بعد ذلك، نظرًا لأن الشبكة العصبية يتم تدريبها بطريقة توفر قيمة أعلى بكثير للإجراء، يصعب على التدريب الشبكي معرفة أن الإجراء (b) هو إجراء أفضل في بعض الحالات.

لذلك، لتقليل الاختلاف بين قيم الإخراج (الإجراءات)، يتم استخدام نموذج ثانوي يمثل نسخة من النموذج الأصلي من الجزء الأخير. من الواضح، بما أن الفرق بين قيم النموذج الثاني أقل من النموذج الأصلي، فإننا نستخدم النموذج الثاني لتحقيق قيمة Q.

شبكة كيو العميقة معاً

بالنسبة لبعض الحالات، لا ترتبط الإجراءات المختلفة بالقيمة المتوقعة، ولا نحتاج إلى معرفة تأثير كل إجراء لمثل هذه الحالات. على سبيل المثال، تخيل الوقوف على جبل ومشاهدة شروق الشمس. المنظر الجميل يخلق إحساساً بالراحة لك ويمنحك مكافأة عالية. يمكنك البقاء هنا ولا تهتم قيم Q للإجراءات المختلفة. لذلك، قد يؤدي فصل القيمة المستقلة للإجراء عن الحالة وقيمة Q إلى تعلم أقوى. تقترح شبكة كيو العميقة بنية شبكة جديدة لتحقيق هذه الفكرة. بتعبير أدق، يمكن تقسيم قيمة Q إلى قيمة الحالة ودالة الربح:

$$Q(s, a) = V(s) + A(s, a)$$

تخبرنا دالة القيمة $V(s)$ عن مقدار المكافأة التي سنحصل عليها من الحالات، وتخبرنا دالة الميزة $A(s, a)$ عن مدى أفضل مقارنة الإجراء بالإجراءات الأخرى. وبناءً عليه، فإن قيمة الحالة مستقلة عن الاجراء. لكن ما هي الميزة؟ قد يكون الوكيل في حالة يكون فيها لكل من القيم المطبقة نفس قيمة Q. لذلك، لا يوجد اجراء جيدي في هذه الحالة. ماذا يحدث إذا قسمنا قيمة Q على قيمة الحالة وربح كل إجراء؟ إذا كان لكل إجراء نفس النتيجة، فستكون فائدة كل إجراء لها نفس القيمة. الآن، إذا طرحنا متوسط جميع الأرباح من كل ربح، فنحصل على صفر (أو نقترب من الصفر)، وقيمة Q هي في الحقيقة نفس الحالة:

$$Q(s, a) = V(s) + A(s, a) - \frac{1}{n} \sum_a A(s, \acute{a})$$

بالطبع ، تجدر الإشارة إلى أن ناتج النموذج سيكون مقدار الحالة بالإضافة إلى الربح المطبق. ومع ذلك ، لتعليم النموذج ، نستخدم قيمة Q لأغراض مماثلة:

$$Q(s_t, a_t) = R_t + \gamma \max Q(s_{t+1}, \hat{a})$$

خلاصة الفصل الرابع

- ◆ على الرغم من أن التعلم الخاضع للإشراف هو نوع مهم من التعلم، إلا أنه لا يكفي للتعلم التفاعلي وحده.
- ◆ يركز نهج التعلم المعزز، أكثر من أي نهج آخر للتعلم الآلي، على التعلم الهادف من خلال التفاعل.
- ◆ يحاول التعلم المعزز من خلال الوكيل حل المشكلة عن طريق التجربة والخطأ من خلال التفاعل مع بيئة غير معروفة للوكيل.
- ◆ عادة ما يتم تصميم التعلم المعزز كعملية ماركوف لاتخاذ القرار.
- ◆ الوكيل هو أحد أهم مكونات النظام القائم على التعلم المعزز. لأنه يتضمن الذكاء لاتخاذ القرارات والتوصية بالإجراءات المثلى في أي حالة.
- ◆ الهدف الرئيسي للوكيل في التعلم المعزز هو جمع أكبر قدر من المكافأة في "المدى الطويل". للقيام بذلك، يجب على الوكيل إيجاد السياسة المثلى للسلوك في البيئة.
- ◆ السياسة هي جوهر التعلم المعزز. لأنه وحده يكفي لتحديد السلوك.
- ◆ إحدى السمات الرئيسية للتعلم المعزز هي مشكلة الاستخراج مقابل الاستكشاف. تنشأ هذه المشكلة لأن عملية التعلم في التعلم المعزز تتم اونلاين.
- ◆ تتمثل طريقة التمييز بين الخوارزميات القائمة على النموذج أو غير القائمة على النموذج في فحص الخوارزميات ومعرفة ما إذا كانت تستخدم دوال التحويل والمكافأة.

- ◆ خوارزميات البرمجة الديناميكية الكلاسيكية لها تطبيق محدود في التعلم المعزز بسبب افتراض نموذج كامل وأيضاً بسبب التكلفة الحسابية العالية.
- ◆ على عكس البرمجة الديناميكية، تتعلم طرق مونت كارلو من التجربة فقط. من نواح كثيرة، يمكن اعتباره أبسط طريقة للتعلم المعزز.
- ◆ تعمل طرق مونت كارلو على أساس فكرة تكرار السياسة المعمم.
- ◆ طرق مونت كارلو قابلة للتطبيق فقط للعمل خطوة بخطوة.
- ◆ يتضمن تعلم فرق التوقيت أفكار البرمجة الديناميكية ومونت كارلو.
- ◆ يُطلق على تعلم فرق التوقيت خارج سياسة Q-Learning أحد أكثر الطرق الأساسية والشائعة لتقدير دوال قيمة Q بطريقة غير نموذجية.
- ◆ عند التعامل مع قضايا المجال عالي الأبعاد أو العوامل الاونلاين، يعاني التعلم المعزز من مشكلة عرض الميزات غير الفعال.
- ◆ يستخدم التعلم المعزز العميق قوة تمثيل التعلم العميق للتعامل مع مشاكل التعلم المعزز.



أسئلة للمراجعة

1. هل التعلم الخاضع للإشراف وحده قادر على حل التعلم التفاعلي؟
2. ما التعلم المعزز المناسب لحل المسائل؟ اشرح كيف يعمل؟
3. ما هو الغرض من الوكيل في التعلم المعزز؟
4. ما هي مكونات نظام التعلم المعزز؟
5. اشرح دور دالة القيمة ودالة المكافأة؟

6. قارن بين التعلم المعزز والتعلم الآلي؟
7. ما هي القضية الرئيسية في عملية التعلم المعزز؟
8. ما فائدة السياسة في التعلم المعزز؟
9. ما هو الفرق بين الخوارزميات المستندة إلى السياسة والخوارزميات المستندة إلى القيمة؟
10. اشرح مشكلة الاستخراج مقابل الاستكشاف في التعلم المعزز؟
11. قارن بين الأساليب القائمة على النموذج مع الأساليب غير النموذجية؟
12. لماذا تعتبر خوارزميات البرمجة الديناميكية محدودة الاستخدام في التعلم المعزز؟
13. ما هي أسهل طريقة للتعلم المعزز وكيف يعمل؟
14. قارن بين طرق مونت كارلو والبرمجة الديناميكية؟
15. ما هي ميزة خوارزمية تعلم فرق التوقيت على طرق مونت كارلو والبرمجة الديناميكية؟
16. ما هي الفكرة الرئيسية لتعلم فرق التوقيت؟
17. ما هي مزايا وعيوب طريقة التدرج السياسي على طريقة دالة القيمة؟
18. سمي بعض خوارزميات تعزيز التعلم العميق القائمة على Q؟

الفصل 5

التعلم الانتقالي العميق

الاهداف

- التعرف على التعلم الانتقالي والهدف من استخدامه.
- التعرف على التعلم الانتقالي العميق وطرقه واستراتيجياته.

المقدمة

مثل الذكاء الاصطناعي والتعلم الآلي، تطور مفهوم التعلم الانتقالي على مدى عقود. منذ السنوات الأولى للذكاء الاصطناعي، اعتبر الباحثون القدرة على نقل المعرفة كأحد الركائز الأساسية للذكاء. بصرف النظر عن الذكاء الاصطناعي وعلوم الكمبيوتر، فقد تمت صياغة مفهوم التعلم الانتقالي أيضاً بمصطلحات مختلفة. على سبيل المثال، في مجال علم نفس التعلم، يعتبر مفهوم التعلم الانتقالي قضية مهمة في نمذجة ما يشكل التعلم الفعال وتعليم المعلمين. من المعتقد أن التدريب الأفضل يمكن الطالب من "تعلّم الكيفية" وتكييف المتعلم مع المواقف المستقبلية. على الرغم من اختلاف الاسماء، إلا أن هيكلها الأساسي وموضوعها متماثل: القدرة على استخدام خبراتهم السابقة والمساعدة في اتخاذ قرارات أكثر فاعلية في المستقبل.

يعتمد التعلم العميق بشكل كبير على كميات كبيرة من البيانات للتدريب مقارنة بأساليب التعلم الآلي التقليدية. لأنهم يتعلمون الميزات أو الأنماط المخفية من بيانات التدريب تلقائياً، وهذا يتطلب كمية كبيرة من البيانات. بالإضافة إلى ذلك، فإن معظم نماذج التعلم العميق متخصصة في مجال معين أو حتى وظيفة معينة.

على الرغم من أن هذه النماذج قد تكون متقدمة ودقيقة للغاية، إلا أن هذه الدقة ستكون فقط في مجموعات بيانات محددة للغاية، وإذا تم استخدامها في مهمة جديدة قد تكون متشابهة، فسوف تفقد أدائها بشكل كبير. لذلك، من أجل حل هذه المشكلات، فإنه يحفز استخدام التعلم الانتقالي في التعلم العميق لمحاولة تجاوز مهام ومجالات محددة لمعرفة كيف يمكن استخدام المعرفة من النماذج المدربة مسبقاً واستخدامها لحل المشكلات الجديدة.

التعلم الانتقالي

يمتلك البشر قدرة فطرية على نقل المعرفة بين المهام. يستخدمون ما يكتسبونه عندما يتعلمون مهمة كمعرفة بنفس الطريقة لحل المهام ذات الصلة. على سبيل المثال، الشخص الذي يعرف كيف يقود سيارة يتعلم قيادة الحافلة أسرع من غيره. والمثال الأكثر

واقعية هو أن طالبًا في الصف الأول يتعلم القراءة والكتابة، وفي الصفوف العليا يستخدم هذه القراءة والكتابة لتكون مفيدة في تعلم الدروس.

باختصار، لا يتعلم البشر كل شيء من الألف إلى الياء وينقلون معارفهم من المجالات التي تعلموها سابقًا إلى المجالات والمهام الجديدة. الآن، كلما زادت ترابط هذه المهام، أصبح من الأسهل نقل المعرفة أو استخدامها. تسمى هذه القدرة على نقل المعرفة في التعلم الآلي بالتعلم الانتقالي، أي القدرة على إعادة استخدام النمط الذي تم إنشاؤه وتدريبه لمهمة ما كنقطة انطلاق لمهمة ثانوية، توفر المصادر المختلفة تعريفات مختلفة للتعلم الانتقالي. في هذا الكتاب، نحدد التعلم الانتقالي على النحو التالي:

استخدام نموذج مدرب مسبقًا لنقل المعرفة من هذا النموذج إلى مهمة مماثلة، من أجل تحسين أداء هذه المهمة الجديدة.

لفهم التعريف الرسمي للتعلم الانتقالي، من الضروري أولاً تحديد المجال والمهمة. المجال عبارة عن مجموعة من البيانات التي يتم استخدامها لتعليم الاستخدام ويتم تمثيل المجال على أنه $D = \{\mathcal{X}, P(X)\}$ والذي يتكون من مكونين: \mathcal{X} مساحة الميزة و $P(X)$ توزيع احتمالي في هذا التعريف $X = \{x_1, \dots, x_n\} \in \mathcal{X}$. يمكن تمثيل المهمة بمساحة التسمية \mathcal{Y} ودالة النموذج المستهدف $f(x)$. يمكن أيضًا كتابة $f(x)$ كدالة احتمالية مشروطة $P(y|x)$. يمكن الآن تعريف التعلم الانتقالي رسميًا على النحو التالي:

بالنظر إلى المجال المصدر D_S ومهمة التعلم المصدر T_S ، والمجال الهدف D_T ، ومهمة التعلم الهدف T_T ، حيث يكون حجم D_S أكبر من حجم D_T ، يعد التعلم الانتقالي طريقة لتحسين أداء النموذج الهدف $f_T(\cdot)$ لمهمة التعلم الهدف T_T باكتساب معرفة ضمنية من D_S و T_S ، حيث $D_S \neq D_T$ و $T_S \neq T_T$.

يعالج التعلم الانتقالي كيف يمكن للأنظمة التكيف بسرعة مع الظروف الجديدة والمهام الجديدة والبيئات الجديدة. يسمح هذا النظام للأنظمة التعلم الآلي باستخدام البيانات والنماذج المساعدة للمساعدة في حل المشكلات حيث لا يتوفر سوى كمية صغيرة من البيانات في المجال الهدف. هذا يجعل هذه الأنظمة أكثر موثوقية.

يعد التعلم الانتقالي مجالاً مهمًا في التعلم الآلي على وجه الخصوص يمكننا النظر إليه من زوايا مختلفة. أولاً، يبدو أن القدرة على التعلم من البيانات الصغيرة هي جانب قوي جداً من جوانب الذكاء البشري. على سبيل المثال، نلاحظ أن الأطفال يتعلمون من أمثلة قليلة فقط ويمكنهم بسرعة وفعالية تعميم المفاهيم من بعض الأمثلة. يمكن تفسير هذه القدرة على التعلم من البيانات الصغيرة جزئياً من خلال قدرة الإنسان على استخدام الخبرة السابقة والنماذج المدربة للمساعدة في حل مشاكل الهدف المستقبلية. التكيف هو قدرة فطرية للكائنات الذكية، وبالتأكيد يجب أن يكون لدى عملاء الذكاء الاصطناعي القدرة على التعلم بشكل انتقالي.

ثانياً، من الناحية العملية، غالباً ما يكون التعلم الآلي محاطاً بمجموعات بيانات صغيرة. العديد من المنظمات غير قادرة على جمع كميات كبيرة من البيانات بسبب قيود مختلفة، من قيود الموارد إلى مصالحي المنظمات وقوانين ولوائح خصوصية المستخدم. هذا التحدي مع البيانات الصغيرة هو مشكلة خطيرة تواجه العديد من المنظمات في استخدام تكنولوجيا الذكاء الاصطناعي في مشاكلهم. التعلم الانتقالي هو حل جيد لهذا التحدي. لأنه يمكن استخدام الكثير من البيانات المساعدة والنماذج الخارجية وتكييفها لحل المشكلات المستهدفة.

بالإضافة إلى ذلك، عند مواجهة تغييرات غير متوقعة وعبور نموذج تم تعلمه عبر حدود المجال، يضمن التعلم الانتقالي أن أداء النموذج لا ينحرف كثيراً عن الأداء المتوقع. بهذه الطريقة، يتيح التعلم الانتقالي إعادة استخدام المعرفة. وهكذا، بمجرد اكتساب الخبرة، يمكن تطبيقها بشكل متكرر في العالم الحقيقي. من منظور نظام برمجي، إذا كان النظام قادراً على التكيف مع التعلم الانتقالي في مجالات جديدة، فيقال إنه أكثر مرونة وموثوقية عندما تتغير البيئة الخارجية. غالباً ما تكون مثل هذه الأنظمة مفضلة في الممارسة.

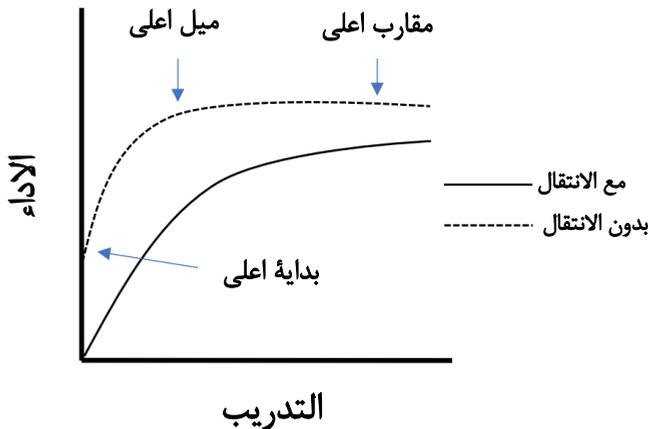
يركز التعلم الانتقالي على استخراج البيانات من مجال مشابه لزيادة القدرة على التعلم أو تقليل عدد العينات ذات العلامات المطلوبة في المجال المستهدف. في التعلم الانتقالي، يستخدم أحد النماذج المعرفة المكتسبة من العمل السابق لتحسين التعميم

على نموذج آخر. الغرض من التعلم الانتقالي هو تحسين عملية تعلم المهام الجديدة باستخدام الخبرة المكتسبة من حل المشكلات السابقة المتشابهة إلى حد ما.

يعد التعلم الانتقالي مفيداً بشكل خاص في النماذج التي يتم تدريبها تدريجياً، ويمكن استخدام نموذج موجود كنقطة انطلاق لمزيد من التدريب، مثل شبكات التعلم العميق. من المهم ملاحظة أن مخرجات نماذج التعلم الانتقالي تتأثر بالعلاقة بين المصدر والمجالات المستهدفة. إذا كان للمجال المصدر والمجال الهدف معرفة أقل شيوعاً، فسيؤثر هذا النموذج سلباً على التعلم والدقة الهدف، وهو ما يسمى **الانتقال السلبي**.

يمكن تحديد ثلاثة معايير مشتركة توضح أن التعلم الانتقالي يمكن أن يحسن فعالية التعلم (الشكل 5-1).

- **بداية أعلى:** الأداء الأولي الذي يمكن تحقيقه في المهمة المستهدفة باستخدام المعرفة المنقولة من المصدر فقط، قبل القيام بأي تعلم إضافي، أفضل بكثير من الأداء الأولي لعامل جاهل.
- **ميل أعلى:** يشير هذا المعيار إلى مقدار الوقت المطلوب لتعلم المهمة بشكل كامل وفقاً للمعرفة المنقولة مقارنة بمدة التعلم من البداية.
- **مقارب أعلى:** مستوى الأداء النهائي القابل للتحقيق بالنسبة للمهمة المستهدفة مقارنة بالمستوى النهائي بدون نقل.



الشكل 5-1 ثلاثة معايير يمكن من خلالها الانتقال يحسن التعلم.

أثناء عملية التعلم الانتقالي، تبرز ثلاثة أسئلة مهمة تحتاج إلى إجابة:

1. **ما يجب نقله:** الخطوة الأولى والأكثر أهمية في جميع عمليات التعلم الانتقالي، وهي تشير إلى المعرفة التي يمكن نقلها. نحتاج إلى العثور على الإجابة التي يمكن نقل جزء المعرفة إليها من المصدر إلى الهدف لتحسين أداء العمل. يجب أن نحاول فهم أي جزء من المعرفة يتطلبه المصدر وما هو مشترك بين المصدر والهدف.
2. **وقت النقل:** لا يؤدي نقل المعرفة دائماً إلى تحسين النتائج بل قد يؤدي أحياناً إلى جعل النتائج أسوأ. يُعرف هذا بالانتقال السلبي. هدفنا من التعلم الانتقالي هو تحسين النتائج وليس تقليدها. لذلك، يجب أن نكون حذرين ونعرف متى نستخدم التعلم الانتقالي ومتى لا نستخدمه.
3. **كيفية النقل:** بعد الإجابة على السؤالين السابقين، حان الوقت الآن لاختيار طريقة نقل المعرفة في المجال المطلوب.

متى نستخدم التعلم الانتقالي؟

أكبر ميزة للتعلم الانتقالي هي عندما تكون مجموعة البيانات المستهدفة صغيرة نسبياً. في العديد من هذه الحالات، قد يكون النموذج عرضة للضبط الزائد، وقد لا تؤدي زيادة البيانات إلى حل المشكلة دائماً. لذلك، يتم استخدام التعلم الانتقالي بشكل أفضل عندما يكون نموذج عمل المصدر في مجموعة تدريب أكبر بكثير من ذلك الذي تم تحقيقه للعمل المستهدف. ومع ذلك، في التعلم الآلي، لا توجد قاعدة واحدة تناسب الجميع. ومع ذلك، باختصار، يمكننا استخدام التعلم الانتقالي عندما نواجه ما يلي:

- لا توجد بيانات تدريب مصنفة كافية لتدريب الشبكة.
- في الوقت الحالي، توجد شبكة بها كمية كبيرة من البيانات تم تدريبها بالفعل لنفس المهمة.

التعلم الانتقالي العميق

تم تصميم التعلم الآلي التقليدي وخوارزميات التعلم العميق تقليدياً لمهمة واحدة بشكل منفصل. يجب إعادة تصميم هذه النماذج وإعادة بنائها بمجرد أن يتغير توزيع المساحة

المميزة. التعلم الانتقالي هو فكرة التغلب على التعلم المنفصل واستخدام المعرفة المكتسبة لمهمة لحل مهمة ذات صلة. يختلف التعلم الانتقالي عن التعلم الآلي التقليدي. لأنه يتضمن استخدام نموذج مدرب مسبقاً كنقطة انطلاق لبدء مهمة ثانوية.

ضع في اعتبارك نموذجاً قادراً على التمييز بين التفاح الناضج والتفاح الفاسد. حتى لو كان الكمثرى مختلفاً في الشكل، فإن الخصائص التي تسبب تعفن الفاكهة يمكن أن تكون شائعة. ضع في اعتبارك أن لدى المنظمة نموذجاً للتفاح يمكنه التمييز بين التفاح الطازج والفاسد، لكن المنظمة نفسها تفتقر إلى بيانات كافية للكمثرى. في هذه الحالة، يمكن تدريب نموذج التعلم العميق باستخدام مجموعة بيانات التفاح ثم تحديثه باستخدام مجموعة البيانات الصغرى للكمثرى. يحظى استخدام التعلم الانتقالي في التعلم العميق بشعبية كبيرة حالياً. لأنه يمكنه تدريب الشبكات العميقة ببيانات قليلة نسبياً.

يمكن تعريف التعلم الانتقالي العميق رسمياً على النحو التالي:

وفقاً لتعريف مهمة نقل التعلم بواسطة $(D_S, T_S, D_T, T_T, f_T(\cdot))$ هذه مهمة تعلم نقل عميق حيث $f_T(\cdot)$ هي دالة غير خطية تعكس الشبكة العصبية العميقة.

الدافع لاستخدام التعلم الانتقالي العميق

على الرغم من أن الشبكات العميقة تعمل على حل المشكلات التي كانت مستحيلة لعقود من الزمن، إلا أن هذه الشبكات تواجه تحديات في حل المشكلات المعقدة. الاعتماد على البيانات هو أحد أخطر هذه المشاكل. يعتمد التعلم العميق بشكل كبير على كميات كبيرة من البيانات للتدريب مقارنة بأساليب التعلم الآلي التقليدية. لأنهم يتعلمون الميزات أو الأنماط المخفية من بيانات التدريب تلقائياً، وهذا يتطلب كمية كبيرة من البيانات. ومع ذلك، فإن البيانات التعليمية غير الكافية في مناطق معينة (على سبيل المثال، تشخيص الأمراض النادرة) هي مشكلة لا مفر منها. بالإضافة إلى ذلك، تخصص معظم نماذج التعلم العميق في مجال معين أو حتى وظيفة معينة.

على الرغم من أن هذه النماذج قد تكون متقدمة ودقيقة للغاية، إلا أن هذه الدقة ستكون فقط في مجموعات بيانات محددة للغاية، وإذا تم استخدامها في مهمة جديدة

قد تكون متشابهة ، فسوف تفقد أدائها بشكل كبير. هذا يحفز استخدام التعلم الانتقالي الذي يتجاوز المهام والمجالات المحددة ، ويسعى لمعرفة كيف يمكن استخدام المعرفة من النماذج المدربة مسبقاً واستخدامها لحل المشكلات الجديدة.

في التعلم الانتقالي ، لا يجب أن تكون البيانات التدريبية وبيانات الاختبار من نفس المجال. أيضاً ، لا يتطلب نموذج المجال الهدف تدريباً من البداية. تحل الشبكات العصبية العميقة ذات الملايين من الأوزان القابلة للتعديل مشكلة في عملية التدريب. تتمثل الفكرة الأساسية للتعلم الانتقالي في بدء عملية التعلم بشبكة تعلم عميق تم تدريبها بالفعل على مشكلة مماثلة. هذا يمكن أن يقلل بشكل كبير من الحاجة إلى بيانات التدريب ووقت التدريب في المجال الهدف.

فوائد التعلم الانتقالي

هناك العديد من الفوائد لاستخدام النماذج التي تم تدريبها بالفعل في مجال ما وإعادة استخدامها في مجال آخر. بعض الفوائد الرئيسية المذكورة أدناه.

- **التدريب ببيانات أقل:** البدء في تدريب نموذج من البداية مكلف ويتطلب الكثير من البيانات. على سبيل المثال ، إذا أردنا إنشاء خوارزمية جديدة يمكنها اكتشاف الوجه العابس ، فنحن بحاجة إلى الكثير من بيانات التدريب. يجب أن يتعلم نموذجنا أولاً كيفية التعرف على الوجوه ، وعندها فقط يمكن أن نتعلم كيفية التعرف على تعابير الوجه مثل الوجه العابس. بدلاً من ذلك ، إذا استخدمنا نموذجاً تعلم بالفعل كيفية التعرف على الوجوه وأعدنا تدريب هذا النموذج لاكتشاف الوجه العابس ، فيمكننا تحقيق نفس النتيجة باستخدام بيانات أقل بكثير.
- **تعميم أفضل للنموذج:** يؤدي استخدام التعلم الانتقالي في النموذج إلى إعداد النموذج للأداء المناسب مع البيانات غير المدربة. يمكن تعميم النماذج المدربة على نقل التعلم بشكل أفضل من مهمة إلى أخرى. لأنهم مدربون على تحديد الميزات التي يمكن استخدامها في سياقات جديدة.
- **يزيد من الوصول إلى التعلم العميق:** العمل مع التعلم الانتقالي يجعل التعلم العميق أسهل في الاستخدام. يمكن أن يؤدي استخدام نموذج تم إنشاؤه بواسطة

خبير التعلم العميق وتطبيقه على مشكلة جديدة إلى تحقيق نتائج جيدة دون امتلاك مهارات التعلم العميق.

استراتيجيات التعلم الانتقالي العميق

يمكن تطبيق التعلم الانتقالي من خلال عدة استراتيجيات مختلفة في فضاء التعلم العميق والآلي. في هذا القسم ، ندرس تقنيات التعلم العميق فقط. هناك ثلاث استراتيجيات رئيسية لاستخدام التعلم الانتقالي العميق:

- **نقل الميزة:** من أسهل الطرق لتعلم النقل هو نقل الميزات. كما نعلم جميعاً ، تتكون شبكة التعلم العميق من عدة طبقات. هذه الطبقات مهمة. لأن التعلم العميق عبارة عن بنية ذات طبقات تتعلم ميزات مختلفة في طبقات مختلفة. أولاً هناك طبقة الإدخال التي تحدد الإدخال إلى الطبقة التالية. ثم طبقة استخراج المعالم او الميزات ، والتي تحتوي على عدة طبقات داخلية. استخراج ميزات طبقة الإخراج هي "ميزات" يمكن أن تمثل ، على سبيل المثال ، ملامح وجه الشخص ، مثل العينين أو الأنف أو الفم ، ويمكن بعد ذلك استخدامها بشكل هرمي للترجمة إلى ميزات ذات مستوى أعلى. تخلط طبقة التصنيف النهائية وتصنف الميزات الموجودة في طبقة استخراج المعالم. على سبيل المثال ، هل تمثل الصورة المدخلة وجهاً بشرياً؟ يتم تحويل كل ميزة من الميزات المختلفة التي تم إنشاؤها إلى مخرجات في طبقة التصنيف. تتمثل الفكرة وراء نقل الميزات في تعليم طبقة تصنيف جديدة لنطاق المشكلة من طبقات الإدخال واستخراج الميزات المدربة في مجموعة بيانات معينة. وهكذا ، على سبيل المثال ، يمكن أن تحتوي شبكة التعلم العميق المستخدمة لاكتشاف سيارة في صورة ما على طبقة تصنيف مُدرّبة للتعرف على الدراجة. هذه الطريقة مثالية إذا كانت منطقتا المشاكل متماثلتين.
- **الضبط-الدقيق:** يمكن أن يعني الضبط-الدقيق أننا نعلم الطبقات التالية من شبكة التعلم العميق مع الحفاظ على الطبقات السابقة ثابتة. بهذه الطريقة ، نقوم بضبط الطبقات الخاصة بخصائص التصنيف مقارنةً بالطبقات السابقة ، والتي تكون أكثر عمومية. هذه الطريقة مثالية عندما تكون مجالات المشكلة متباعدة وتتطلب ميزات جديدة ليتم تصنيفها.

- نهج نموذج مدرب مسبقاً: تهدف أبسط استراتيجية لحل المشكلات إلى استخدام نموذج مدرب مسبقاً مباشرةً في مهمة المصدر. عادةً ما تكون هذه النماذج عبارة عن شبكات عصبية كبيرة بها ملايين المعاملات التي تم تدريبها لأيام أو حتى أسابيع على أجهزة متقدمة.

ما هو النموذج المدرب؟

أحد المتطلبات الأساسية للتعلم الانتقالي هو وجود نماذج تؤدي أداءً جيداً في مهام المصدر. لحسن الحظ ، يؤمن عالم التعلم العميق بالمشاركة. تمت مشاركة العديد من أبنية التعلم العميق الأكثر تقدماً من قبل فرق في مجموعة متنوعة من المجالات، مثل رؤية الكمبيوتر ومعالجة اللغة الطبيعية ، وهما مجالان شائعان للتعلم العميق.

النموذج عبارة عن شبكة مخزنة مُدرّبة مسبقاً تم تدريبها بالفعل ومشاركتها على مجموعة بيانات كبيرة تحتوي على ملايين المعاملات في حالة مستقرة. لحل مشكلة ما ، يجب أن يكون لدينا نموذج مدرب مسبقاً لمشكلة مماثلة. بدلاً من بناء نموذج من الصفر لحل مشكلة مماثلة ، نستخدم النماذج المدربة مسبقاً على مشكلة أخرى كنقطة بداية. يمكنك استخدام النموذج المدرب مسبقاً كما هو أو استخدام التعلم الانتقالي لتخصيص هذا النموذج لمهمة محددة.

تجدر الإشارة إلى أنه يجب توخي الحذر عند اختيار نموذج مدرب مسبقاً. إذا كان بيان المشكلة المطروحة مختلفاً تماماً عن الاقتراح الذي يتم فيه تدريب النموذج على المشكلة ، فإن التنبؤ الذي نتخذه سيكون غير دقيق للغاية.

اعتماداً على حجم مجموعة البيانات الجديدة والتشابه بين مجموعة البيانات الجديدة ومجموعة البيانات الأصلية ، ستكون طريقة استخدام التعلم الانتقالي مختلفة. ستساعدك السيناريوهات الأربعة التالية على تحديد كيفية استخدام النموذج المدرب مسبقاً:

1. حجم مجموعة البيانات صغير ، في حين أن أوجه التشابه في البيانات كبيرة جداً. في هذه الحالة بالذات ، ليست هناك حاجة للحفاظ على النموذج.

لأن أوجه التشابه في البيانات عالية جداً. ومع ذلك ، بناءً على المشكلة ، نحتاج إلى تخصيص طبقات الإخراج وتعديلها. في هذه الحالة ، استخدمنا النموذج المدرب مسبقاً كمستخرج للميزات.

2. **حجم مجموعة البيانات صغير والتشابه في البيانات صغير جداً.** في هذه الحالة ، يجب علينا أولاً تثبيت الطبقات الأولية للنموذج المدرب مسبقاً في مكانها. ثم قم بإعادة تعليم الطبقات المتبقية. من الجدير بالذكر أن الطبقات العليا يتم تخصيصها وفقاً لمجموعة البيانات الجديدة. أيضاً ، تظل الطبقات الأولية مدربة مسبقاً نظراً لصغر حجمها والحفاظ على ثبات أوزانها.

3. **حجم مجموعة البيانات كبير ولكن تشابه البيانات صغير جداً.** في هذه الحالة ، سيكون تدريب الشبكة العصبية أكثر فعالية. نظراً لأن لدينا مجموعة بيانات كبيرة ، وبما أن البيانات التي نستخدمها تختلف عن بيانات التدريب، فمن الأفضل تدريب الشبكة العصبية بناءً على بياناتنا من البداية.

4. **حجم مجموعة البيانات كبير وأيضاً أوجه التشابه في البيانات كبيرة جداً.** يمكن القول أن هذا هو الوضع النهائي والمثالي. تعتبر النماذج المدربة مسبقاً أكثر فعالية في هذا الصدد.

مناهج التعلم الانتقالي العميق

يفحص التعلم الانتقالي العميق كيفية استخدام المعرفة بالمجالات الأخرى من قبل الشبكات العصبية العميقة. استناداً إلى التقنيات المستخدمة في التعلم الانتقالي العميق، يمكن تصنيف التعلم الانتقالي العميق إلى أربع فئات: **التعلم العميق القائم على العينة، التعلم العميق القائم على الخصومة، التعلم العميق القائم على التخصيص، والتعلم الانتقالي العميق القائم على الشبكة.**

التعلم الانتقالي العميق القائم على العينة

مناهج التعلم الانتقالي القائمة على العينات هي إعادة استخدام البيانات المصنفة من المجال المصدر لتعليم نموذج أكثر دقة لمهمة التعلم المستهدفة. إذا كان المجال المصدر

والمجال الهدف متطابقين تمامًا ، فيمكننا دمج بيانات المجال المصدر مباشرةً في المجال الهدف.

الدافع الشائع وراء مناهج التعلم الانتقالي القائم على العينة هو أن بعض البيانات التي تحمل اسم المجال المصدر ليست مفيدة بعد لتعلم نموذج دقيق للمجال المستهدف، وبعضها قد لا يكون قابلاً للاستخدام أو إذا تم استخدامه ، يمكن أن يضعف أداء النموذج المستهدف. لفهم أفضل يمكننا استخدام تحليل التباين والتحيز.

عندما تكون مجموعة بيانات المجال الهدف صغيرة ، فقد يكون للنموذج مستوى عالٍ من التباين. لذلك ، خطأ تعميم النموذج كبير. من خلال إضافة جزء من بيانات المجال المصدر كمجموعة بيانات مساعدة ، يمكن تقليل تباين النموذج. ومع ذلك ، إذا كان توزيع البيانات في المجالين مختلفاً تمامًا ، فقد يكون لنموذج التعلم الجديد تباين كبير. لذلك ، إذا تمكنا من عزل العينات من المجال المصدر الذي يتبع نفس التوزيع مثل المجال الهدف ، فيمكننا إعادة استخدامها وتقليل كل من التباين والتحيز في نموذج التعلم المستهدف.

يشير التعلم الانتقالي العميق القائم على العينة إلى استخدام إستراتيجية محددة لتعديل الوزن لاختيار عينات صغيرة من المجال المصدر كمكمل لمجموعة التدريب في المجال المستهدف ، ويستند إلى افتراض أنه على الرغم من وجود اختلافات بين المجالين ، يمكن استخدام عينات ثانوية في مجال المصدر مع النطاق المستهدف بأوزان مناسبة.

التعلم الانتقالي العميق القائم على الخصومة

تتمثل إحدى طرق استخدام التعلم الانتقالي في استخدام النمذجة الإنتاجية في التعلم العميق ، مما يؤدي إلى نماذج معادية. استخدام نماذج توليد غير خاضعة للإشراف لتقليل الاعتماد على البيانات المصنفة. في المجال الهدف ، تكون البيانات المصنفة محدودة ، ولكن قد يكون هناك الكثير من البيانات غير المسماة في مجال المصدر. يمكن استخدام التعلم غير الخاضع للإشراف لتمثيل البيانات غير المسماة ، ويمكن استخدام النماذج الإنتاجية لنقل المعرفة إلى المجال المستهدف.

يشير التعلم الانتقالي العميق القائم على الخصومة إلى التكنولوجيا العداية المستوحاة من شبكات الخصومة التوليدية للعثور على تمثيلات قابلة للتحويل يمكن استخدامها لكل من المجال المصدر والمجال الهدف. التعلم العدائي يعمل بشكل طبيعي مع التعلم الانتقالي. كنموذج إنتاج ، يمكن لنماذج الخصومة التوليدية أن تولد بيانات المجال المستهدف وتعزز البيانات في نوع جديد من التعلم الانتقالي يُعرف باسم "زيادة البيانات". يمكن استخدام التعلم العدائي "لترجمة" عينة المجال المصدر المصنف إلى عينة المجال الهدف مع الاحتفاظ بعلامته ، ويمكنه التواصل بين عينات المجال المصدر والهدف غير المراقب تمامًا.

نظرًا لظهور شبكات الخصومة التوليدية بالإضافة إلى التعلم العدائي كإطار عمل جديد وقوي ، سعى الباحثون إلى تطوير نماذج تعلم انتقالية تعتمد على إطار عمل تعليمي معادي.

التعلم الانتقالي العميق القائم على التخصيص

يشير التعلم الانتقالي العميق المستند إلى التخصيص (التطبيق) إلى سحب عينات من المجال المصدر والمجال الهدف إلى مساحة بيانات جديدة. في مساحة البيانات الجديدة هذه، تكون العينات من مجالين متشابهة ومناسبة في شبكة عصبية مركزية. يعتمد هذا النهج على افتراض أنه على الرغم من وجود اختلافات بين المجالين الرئيسيين، إلا أنهما يمكن أن يكونا متشابهين في مساحة بيانات جديدة.

التعلم الانتقالي العميق القائم على الشبكة

يشير التعلم الانتقالي العميق القائم على الشبكة إلى إعادة استخدام شبكة جزئية تم تدريبها بالفعل في مجال الموارد (بما في ذلك بنية الشبكة ومعاملات الاتصال الخاصة بها) ونقلها إلى جزء من الشبكة العصبية العميقة المستخدمة في المجال المستهدف. يفترض هذا النهج أن الشبكة العصبية تشبه آلية معالجة الدماغ البشري وهي عملية تجريدية متكررة ومستمرة. يمكن أن تعمل الطبقات الأمامية للشبكة كمستخرج مميزة ، وتكون الميزات المستخرجة متعددة الاستخدامات.

خلاصة الفصل الخامس

- ◆ يعتمد التعلم العميق بشكل كبير على كميات كبيرة من البيانات للتدريب مقارنة بأساليب التعلم الآلي التقليدية.
- ◆ معظم نماذج التعلم العميق متخصصة في مجال معين أو حتى مهمة محددة. لذلك، من أجل حل هذه المشكلات، فإنه يحفز استخدام التعلم الانتقالي في التعلم العميق لتجاوز مهام ومجالات محددة.
- ◆ يعالج التعلم الانتقالي كيف يمكن للأنظمة التكيف بسرعة مع الظروف الجديدة والمهام الجديدة والبيئات الجديدة.
- ◆ يتأثر مخرجات نماذج التعلم الانتقالي بالعلاقة بين المصدر والمناطق المستهدفة.
- ◆ أكبر ميزة للتعلم الانتقالي هي عندما تكون مجموعة البيانات المستهدفة صغيرة نسبياً.
- ◆ هناك العديد من الفوائد لاستخدام النماذج التي تم تدريبها بالفعل في منطقة ما وإعادة استخدامها في منطقة أخرى.



أسئلة للمراجعة

1. ما هو التعلم الانتقالي؟
2. كيف يساعد التعلم الانتقالي في التعلم الآلي؟
3. ما هي المعايير التي تبين أن التعلم الانتقالي كان فعالاً؟
4. ما هي الأسئلة الثلاثة التي تدخل في عملية التعلم الانتقالي؟
5. متى يكون من المناسب استخدام التعلم الانتقالي؟
6. لماذا يتم استخدام التعلم الانتقالي في التعلم العميق؟ عدد فوائده؟

7. ما هو النموذج المدرب مسبقاً وما فوائده؟

5 الفصل

التعلم العميق الهندسي: التعلم التمثيلي بالرسم البياني

الاهداف

- التعرف على التعلم العميق الهندسي وسبب استخدامه.
- كيف تعمل شبكات الرسم البياني العصبية.
- التعرف على شبكات الرسم البياني الالتفافية.

المقدمة

يستخدم هيكل الرسم البياني للبيانات على نطاق واسع في مجالات مختلفة مثل الكيمياء الحيوية ومعالجة الصور وأنظمة التوصية وتحليل الشبكة الاجتماعية وما إلى ذلك. هناك طرق مختلفة لتعليم نماذج التعلم الآلي على البيانات المهيكلة بالرسم البياني باستخدام تقنيات المعالجة المسبقة. ومع ذلك، لا يتمتعون بالمرونة للتكيف الكامل مع مجموعة البيانات والمهمة الحالية، وقد ثبت أنه من الصعب استخدام هذه البيانات في نموذج التعلم الآلي بسبب الحجم الكبير والطبيعة غير الإقليدية لبيانات الرسم البياني. بشكل عام، يمكن القول إن هذه الأساليب التقليدية تستخدم كخطوة معالجة مسبقة، وليست جزءاً من عملية التدريب.

حققت الشبكات العصبية العميقة نجاحاً ملحوظاً خلال العقد الماضي. ومع ذلك، لا يمكن تنفيذ الأنواع البدائية للشبكات العصبية إلا باستخدام البيانات العادية أو الإقليدية. ومع ذلك، فإن معظم بيانات العالم الحقيقي لها هيكل رسم بياني غير إقليدي. أدى عدم انتظام بنية البيانات إلى تطورات حديثة في الشبكات العصبية للرسم البياني.

تسمح الشبكات العصبية للرسم البياني بإنشاء نموذج تعلم آلي شامل يتم تدريبه بشكل متزامن لتعلم تمثيل البيانات المهيكلة بالرسومات البيانية. يمكن تطبيق الشبكات العصبية للرسم البياني على البيانات المهيكلة بيانياً لمجموعة متنوعة من المهام، من التجميع إلى التصنيف أو الانحدار، ويمكنها أيضاً تعلم التمثيلات على مستوى العقدة أو الحافة أو الرسم البياني.

التعلم العميق الهندسي

بينما نجحت نماذج التعلم العميق في العقد الماضي في التعامل مع المدخلات مثل الصور أو الكلام أو الفيديو بناءً على البنية الإقليدية، أصبح الباحثون مؤخراً أكثر اهتماماً باستخدام التعلم على البيانات غير الإقليدية. التعلم العميق الهندسي هو مجال بحثي ناشئ يسعى إلى تعميم بنية التعلم العميق للعمل مع البيانات غير الإقليدية لسد هذه الفجوة.

يمكن أن تمثل البيانات غير الإقليدية مفاهيم أكثر تعقيداً بشكل أكثر دقة من التمثيلات أحادية البعد وثنائية الأبعاد. يعد الرسم البياني أحد الهياكل غير الإقليدية المهمة. الرسوم البيانية هي نوع خاص من بنية البيانات، تتكون من رؤوس متصلة بواسطة حواف. يمكن استخدام بنية البيانات المجردة هذه لنمذجة أي شيء تقريباً. على سبيل المثال، في الشبكات الاجتماعية، يمكن نمذجة سمات المستخدم كإشارات على رؤوس الرسم البياني الاجتماعي. في علم الأعصاب، تُستخدم نمذجة الرسم البياني لإظهار الهياكل الوصفية والوظيفية للدماغ.

الرسم البياني

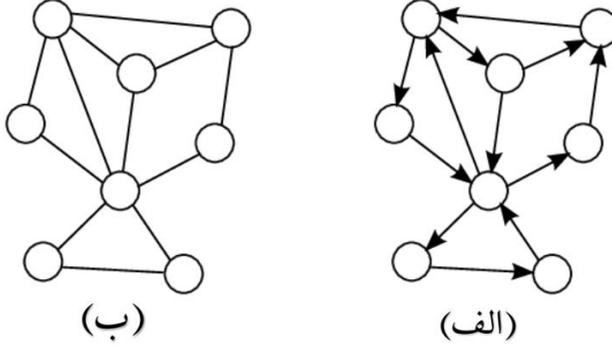
في علوم الكمبيوتر، الرسم البياني (الكراف) هو بنية بيانات ذات رأسين* وحافة. يمكن وصف الرسم البياني G على أنه $G = (V, E)$ ؛ حيث V عبارة عن مجموعة من الرؤوس و E هي مجموعة من الحواف التي تربط هذه العقد. اعتماداً على العلاقات بين هذه الرؤوس، يمكن أن تكون الحواف موجهة أو غير موجهة (الشكل 6-1).

طريقة مناسبة لعرض الرسوم البيانية هي من خلال مصفوفة الجوار $A \in \mathbb{R}^{|V| \times |V|}$. لتمثيل رسم بياني بمصفوفة الجوار، نقوم بترتيب العقد في الرسم البياني بحيث تقوم كل عقدة بفهرسة صف وعمود معين في مصفوفة الجوار.

البيانات ذات هيكل الرسم البياني وفيرة في العالم الحقيقي ويمكن رؤيتها في كل مكان. على سبيل المثال، الشبكات الاجتماعية والشبكات البيولوجية والتركيبات الجزيئية والرسوم البيانية المعرفية وما إلى ذلك. بشكل عام، أي مجموعة بيانات تتضمن العقد والحواف هي رسم بياني. هناك أيضاً مجموعة واسعة من مشكلات التعلم المتعلقة بالرسوم البيانية، مثل تصنيف العقدة شبه المهيكلة، وتصنيف الرسم البياني، وتنبؤ الارتباط، تشخيص المجتمع، وتجميع الرسوم البيانية، والمزيد. نظراً لوفرة البيانات مع بنية الرسم البياني ومشكلات تعلم الرسم البياني، من المهم جداً دراسة كيفية التعلم من الرسوم البيانية. بالإضافة إلى ذلك، يعد الرسم البياني موضوعاً مهماً في التعلم الآلي.

* غالباً ما يشار إلى الرؤوس على أنها عقدة. في هذا الكتاب، نستخدم كلا المصطلحين.

هذا لأن العديد من نماذج التعلم الآلي ، مثل الشبكات العصبية وشبكات بايزي ، تتحقق من خلال الحسابات على الرسوم البيانية.



الشكل 6-1 (الف) الرسم البياني الموجه (ب) الرسم البياني غير الموجه

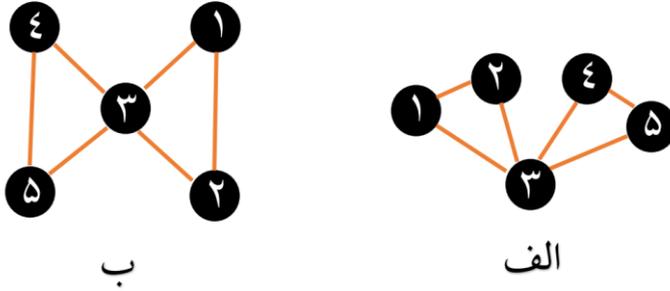
ومع ذلك ، فإن البيانات التي تحتوي على بُنية الرسم البياني معقدة للغاية لدرجة أنها تفرض العديد من التحديات على خوارزميات التعلم الآلي الحالية. تنشأ هذه المشكلة لأن أدوات التعلم الآلي التقليدية والتعلم العميق تتخصص في أنواع البيانات البسيطة ؛ مثل الصور التي لها نفس الهيكل والحجم ، والتي يمكن أن نفكر فيها على أنها رسوم بيانية ذات حجم ثابت ، أو نص وكلام يحتويان على بيانات متسلسلة يمكننا اعتبارها رسوم بيانية خطية. ومع ذلك ، هناك رسوم بيانية أكثر تعقيداً ؛ لا يوجد شكل ثابت وحجم متغير للعقد غير المهيكلة ، حيث يمكن أن يكون للعقد جيران مختلفة.

لماذا يصعب تحليل الرسوم البيانية؟

الرسوم البيانية لها خصائص غير إقليدية. هذا يعني أنه لا يمكننا تمثيلهم بأي نظام إحداثيات نعرفه. وهذا يجعل تفسير بيانات الرسم البياني أكثر صعوبة من تفسير البيانات في شكل صور وموجات وسلسلة زمنية. بالإضافة إلى ذلك ، لا تحتوي الرسوم البيانية على شكل ثابت. انظر الشكل 6-2 للحصول على مثال. الرسم البياني (أ) والرسم البياني (ب) مختلفان تماماً من الناحية الهيكلية والمرئية. ولكن عندما نحولهم إلى مصفوفات متجاورة ، فإن رسمين بيانيين للمصفوفات المتجاورة لهما نفس الشيء (على افتراض

أننا لا نأخذ في الاعتبار وزن الحواف). إذن ، هل يجب اعتبار هذين الشكلين مختلفين أم متشابهين؟

أخيراً ، من الصعب عموماً تصور رسم بياني للتفسير البشري. لا نعني الرسوم البيانية الصغيرة مثل الأمثلة أعلاه. هناك رسوم بيانية ضخمة تحتوي على مئات أو آلاف العقد. يتم تجميع الرسوم البيانية ذات الأبعاد والعقد العالية بشكل مكثف ويصعب فهم الرسم البياني حتى بالنسبة للإنسان. لذلك ، يعد تدريب آلة على هذه المهمة أمراً صعباً.



الشكل 2-6 رسم بياني يتمثل هيكلي ومرئي مختلف

شبكات الرسم البياني العصبية

على عكس الصور ، لا تحتوي البيانات المهيكلة على الرسم البياني على تمثيل موثر يمكن قراءته بسهولة بواسطة الشبكات العصبية العادية. هذا يحد من استخدام التعلم العميق للعمل مع الرسوم البيانية.

تتطلب معماريات الشبكات العصبية التقليدية ، مثل الشبكات العصبية امامية التغذية، والشبكات العصبية الالتفافية ، والشبكات العصبية المتكررة ، إشارات إدخال يتم عرضها بأشكال ذات أحجام. وفقاً لذلك ، تكون طبقات الشبكة العصبية قادرة على استخراج الميزات بشكل هرمي وتعلم الأنماط من البيانات. على الرغم من أن هذه الشبكات العصبية قد حققت نجاحاً كبيراً في أنواع مختلفة من البيانات ، إلا أنه لا يمكن تطبيق هذه الشبكات العصبية العادية مباشرة على الرسوم البيانية. في الوقت نفسه ، يعتقد

الباحثون أن التعلم العميق للعمل مع الرسوم البيانية هو مجال رائع يمكن من خلاله اختبار أساليب الشبكة العصبية الجديدة.

شبكات الرسم البياني العصبية هي مجموعة من طرق التعلم العميق المصممة خصيصاً لاستنتاج البيانات الموصوفة بالرسوم البيانية. من المستحسن إنشاء نماذج تعمل مباشرة على الرسوم البيانية. لأنه يمكننا الحصول على مزيد من المعلومات حول هيكلها وخصائصها.

يتم تطبيق شبكات الرسم البياني العصبية مباشرة على الرسوم البيانية وتوفر طريقة سهلة لأداء المهام مثل التنبؤ بمستوى العقد والحواف والرسوم البيانية. قبل تطوير شبكات الرسم البياني العصبية، لم يكن لأساليب التعلم العميق القدرة على تطبيقها على الحواف لاستخراج المعرفة والتنبؤ. بدلاً من ذلك، تصرفوا فقط بناءً على خصائص العقدة.

تمثل كل عقدة في الرسم البياني مجموعة من السمات التي يتم تحديدها بواسطة العقدة والمرتبطة بمجموعة من العلامات. ثم تُستخدم شبكة الرسم البياني العصبية لتدريب الأوزان التي يمكن استخدامها للتنبؤ بالعلامات للعقد الجديدة. تعمل شبكات الرسم البياني العصبية عن طريق تمثيل حالة العقد بشكل متكرر واستخدام الشبكات العصبية أمامية التغذية ونقل الرسائل.

الشبكات العصبية لنقل الرسائل¹

شبكات الرسم البياني العصبية لها العديد من الصيغ المستقلة. ومع ذلك، يمكن دمجها في إطار عمل نقل الرسائل². الشبكة العصبية لنقل الرسائل هي نوع من نماذج الشبكة العصبية المصممة خصيصاً للعمل على الرسوم البيانية. بالنظر إلى الرسم البياني غير الموجه G مع خصائص العقدة x_v ، عادةً ما يتكون الإرسال الأمامي لشبكة الرسم البياني العصبية من مرحلتين: مرحلة إرسال الرسائل، والتي تُستخدم لاستخراج خصائص البنية

¹ Message Passing Neural Networks (MPNN)

² message passing framework

التحتية المحلية حول العقد، ومرحلة الاسترجاع¹ وهي مرحلة تجميع لتلخيص الخصائص الفردية للعقدة في متجه لسمات سطح الرسم البياني.

يتم تنفيذ مرحلة نقل الرسالة (الرسم البياني الالتفافي) في عدد تكرارات T وتتضمن دوال رسالة M_t ودوال تحديث U_t . في كل مرحلة من مراحل نقل الرسائل، يتم تحديث الحالات المخفية لرؤوس h_v^t بناءً على رسائل m_v^t :

$$m_v^{t+1} = \sum_{u \in \Gamma(v)} M_t(h_v^t, z_u^t)$$

$$h_v^{t+1} = U_t(h_v^t, m_v^{t+1})$$

حيث تُظهر $\Gamma(v)$ مجموعة الجيران v في الرسم البياني. M_t و U_t كلاهما دالات مشتقة مع معاملات قابلة للتعلم.

في مرحلة الاسترجاع، يتم تطبيق دالة الاسترجاع R على مجموعة الحالات الكامنة النهائية h_v^T لإجراء التنبؤ على النحو التالي:

$$\hat{y} = R(\{h_v^T | v \in G\})$$

تعمل دالة الاسترجاع عادةً عن طريق إنشاء تمثيل واحد للرسم البياني بأكمله مع مراعاة الحالات المخفية النهائية h :

$$h = \sum_{v \in G} h_v^T$$

بعد ذلك، يتم تطبيق الشبكة العصبية امامية التغذية f إلى h على الإخراج:

$$\hat{y} = f(h)$$

¹ readout phase

يمكن النظر إلى نقل الرسائل على أنه عامل تشغيل التفافى يستخدم لاستخراج الخصائص المحلية على العقد. على غرار ما تفعله الشبكة العصبية التقليدية للمزامنة لكل بكسل. يمكن تضمين معظم الشبكات العصبية الموجودة في الرسم البياني في هذا الإطار. تكمن الاختلافات في التصميم الفريد لـ M_t و U_t في الأعمال الكامنة المختلفة. على سبيل المثال ، يمكن أن تكون M_t عبارة عن مجموع أو متوسط ، أو يمكن أن تكون من بُنى الشبكات العصبية المعقدة مثل آلية الانتباه و RNN. يمكن أيضاً تقييد دالة التحديث U_t من طبقة خطية أحادية الطبقة إلى بيرسيبترون متعدد الطبقات لـ GRU.

تعلم تمثيل الرسم البياني

يُعرف التعلم العميق للعمل مع البيانات في شكل رسوم بيانية أيضاً بالتعلم العميق الهندسي¹ أو تعلم تمثيل الرسم البياني² أو تضمين الرسم البياني³ الذي يسعى إلى تعلم تمثيل المعلومات الهيكلية حول الرسم البياني. الغرض من تعلم تمثيل الرسم البياني هو بناء مجموعة من الميزات التي تمثل هيكل الرسم البياني والبيانات الواردة فيه. تكمن الفكرة وراء هذه الطريقة في تعلم التخصيص الذي يدمج العقد أو الرسوم البيانية كنقاط في مساحة متجهية صغيرة، بحيث يتم تحسين التخصيص التي يعكس العلاقات الهندسية المكتسبة في فضاء بُنية الرسم البياني الأصلي. بعد تحسين المساحة المضمنة، يمكن استخدام هذا التضمين الذي تم تعلمه لتلقي ميزات الإدخال الخاصة بالتعلم الآلي.

الفرق الرئيسي بين مناهج التعلم التمثيلي والأعمال السابق هو كيفية تعاملهم مع مشكلة تسجيل المعلومات الهيكلية حول الرسوم البيانية. في الماضي ، تم اعتبار هذه المشكلة كخطوة معالجة مسبقة ، باستخدام الهندسة الإحصائية اليدوية لاستخراج المعلومات الهيكلية. في المقابل ، تترك مناهج التعلم التمثيلي هذه المشكلة للتعلم العميق، باستخدام نهج قائم على البيانات لتعلم التضمين الذي يشفر بُنية الرسم البياني.

¹ geometric deep learning

² graph representation learning

³ graph embedding

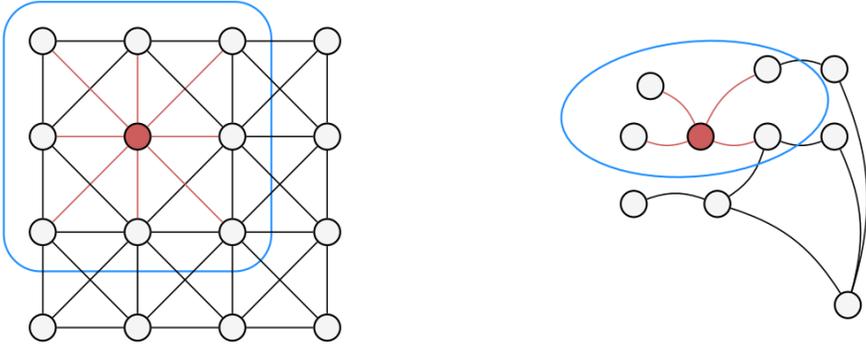
شبكة الرسم البياني الالتفافية

مثل إدخال شبكات العصبية الالتفافية التي تساعد على تسريع التعلم وزيادة الدقة من خلال معالجة البيانات الهرمية ، فإن شبكات الرسم البياني تفعل الشيء نفسه ولكن في بيانات الرسم البياني. شبكات الرسم البياني الالتفافية عبارة عن مجموعة من الشبكات العصبية القوية جداً التي تستخدم عمليات الالتفاف ، وهي المشغل الرئيسي في نماذج الشبكة العصبية الالتفافية ، لاستخراج أنماط ذات دلالة إحصائية من بيانات الرسم البياني الهيكلية ، ويتم تنفيذها بشكل جيد للغاية بأقل قدر من التدريب.

في الواقع، إنها قوية جداً لدرجة أنه حتى شبكة الرسم البياني الالتفافية المكونة من طبقتين والتي تمت تهيئتها بشكل عشوائي يمكن أن تمثل خصائص مفيدة للعقد. بشكل عام، تجد شبكات الرسم البياني الالتفافية تمثيلاً جديداً لكل رأس من الرسم البياني من خلال تجميع خصائص جيرانها. يمكن تعميم الالتفاف ثنائي الأبعاد على التفاف الرسم البياني.

كما هو مبين في الشكل 6-3، يمكن اعتبار الصورة كحالة خاصة للرسم البياني حيث يتم توصيل وحدات البكسل بوحدات البكسل المجاورة. يعتبر تسلسل الرسم البياني أن كل رأس هو بكسل ويجمع خصائص رأس الهدف وجيران رأس الهدف.

شبكات الرسم البياني العصبية هي بلا شك أهم موضوع في التعلم العميق القائم على الرسم البياني. تتعلم هذه الشبكات الحديثة، عن طريق محاكاة الشبكات العصبية الالتفافية، الأنماط الهيكلية المحلية والعالمية للرسوم البيانية من خلال دوال الالتفاف والاسترجاع المصممة. يتمثل الاختلاف الرئيسي بين شبكات الارتباط العصبية وشبكات الرسم البياني الالتفافية في أن الشبكات العصبية الالتفافية مصممة خصيصاً للعمل على البيانات ذات البنية العادية (الإقليدية). من ناحية أخرى، فإن شبكات الرسم البياني الالتفافية هي إصدارات معممة من الشبكات العصبية الالتفافية التي تحتوي البيانات فيها على بنية غير مهيكلية.



الشكل 3-6 الالتفاف ثنائي الأبعاد (الشكل الأيسر) مقابل التفاف الرسم البياني (الشكل الأيمن).

يمكن تصنيف شبكات الرسم البياني الالتفافية إلى مجموعتين رئيسيتين: شبكات الرسم البياني الالتفافية الطيفية¹ وشبكات الرسم البياني الالتفافية المكانية². يتم تفسير المناهج الطيفية من خلال إدخال فلاتر من منظور معالجة إشارة الرسم البياني بناءً على النظرية الطيفية للرسم البياني، حيث تُستخدم عملية الاقتران لإزالة الضوضاء من إشارات الرسم البياني. تقوم الالتفافات المكانية، من خلال جمع المعلومات من العقد المجاورة، بصياغة التفاف الرسم البياني مباشرة. يلتقط الالتفاف المكاني العقدة وجيرانها للحصول على تمثيل جديد لها. تتمثل الطريقة الشائعة للقيام بذلك في تكديس عدة طبقات من تداخل الرسم البياني.

من حيث قابلية التوسع والتوازي، تزيد الطرق الطيفية ذات حجم الرسم البياني بشكل كبير وتتطلب الرسم البياني بأكمله في الذاكرة. لذلك، هذه الأساليب ليست مناسبة للبيانات واسعة النطاق مع مليارات العقد (على سبيل المثال، الرسوم البيانية للشبكة الاجتماعية) أو البنى الموازية. في المقابل، لا تعاني الطرق المكانية من هذه المشكلة. هذا لأنها تتكامل مباشرة في حقل الرسم البياني من خلال دمج خصائص الجوار حتى يتمكنوا من التعامل مع الرسوم البيانية الكبيرة.

¹ Spectral

² Spatial

من وجهة نظر تعميم النماذج ، تنظر النماذج القائمة على الطيف في الرسم البياني الثابت وليست بارعة في تعميم الرسوم البيانية غير المرئية. لا تحتوي الطرق المكانية على هذا القيد لأن مزامنتها تتم محليًا. لذلك ، يمكن بسهولة مشاركة الأوزان المستخدمة في التقارب في أماكن وهياكل مختلفة.

أخيرًا، تقتصر الطرق الطيفية على العمل على الرسوم البيانية بلا اتجاه. من ناحية أخرى، يمكن للطرق المكانية التعامل مع المدخلات متعددة المصادر والرسوم البيانية الاتجاهية عن طريق تغيير دالة التجميع. بسبب العوامل المذكورة، اجتذبت النماذج المكانية اهتمامًا عامًا أكبر من النماذج الطيفية.

خلاصة الفصل السادس

- ◆ التعلم العميق الهندسي هو مجال بحثي ناشئ يسعى إلى تعميم بُنية التعلم العميق للعمل مع البيانات غير الإقليدية.
- ◆ يعد الرسم البياني أحد الهياكل غير الإقليدية المهمة.
- ◆ البيانات ذات هيكل الرسم البياني وفيرة في العالم الحقيقي ويمكن رؤيتها في كل مكان.
- ◆ يتم تطبيق شبكات الرسم البياني العميقة مباشرة على الرسوم البيانية وتوفر طريقة سهلة لأداء المهام مثل التنبؤ بمستوى العقد والحواف والرسوم البيانية.
- ◆ الشبكة العصبية لنقل الرسائل هي نوع من نماذج الشبكة العصبية المصممة خصيصًا للعمل على الرسوم البيانية.
- ◆ الغرض من تعلم تمثيل الرسم البياني هو بناء مجموعة من الميزات التي تمثل هيكل الرسم البياني والبيانات الواردة فيه.



أسئلة للمراجعة

1. لماذا من المهم دراسة البيانات بهيكل الرسم البياني؟
2. وصف تحديات العمل مع الرسوم البيانية؟
3. كم عدد المراحل التي تتكون منها الشبكة العصبية لنقل الرسائل؟ اشرح كيف تعمل كل مرحلة من هذه المراحل؟
4. ما هو الغرض من تعلم تمثيل الرسم البياني؟
5. ما هو الفرق بين مناهج التعلم التمثيلي والعمل الماضي؟
6. قم بتسمية ومقارنة مجموعتين رئيسيتين من شبكات الرسم البياني الالتفافية؟

المصادر

- Aggarwal, Charu C. *Neural Networks and Deep Learning a Textbook*. Cham Springer, 2018.
- Alexander Alexander Zai. *Deep Reinforcement Learning in Action*. Manning Publications Company, 2020.
- Alom, Md Zahangir, Tarek M. Taha, Chris Yakopcic, Stefan Westberg, Paheding Sidike, Mst Shamima Nasrin, Mahmudul Hasan, Brian C. Van Essen, Abdul A. S. Awwal, and Vijayan K. Asari. "A State-of-the-Art Survey on Deep Learning Theory and Architectures." *Electronics* 8, no. 3 (March 5, 2019): 292. <https://doi.org/10.3390/electronics8030292>.
- Andriy Burkov. *The Hundred-Page Machine Learning Book*. Quebec, Canada] Andriy Burkov, 2019.
- Arbones, Marc. "Deep Learning: Creating Bridges between DMPs in Auto Encoders and Recurrent Neural Networks," 2017.
- ARMACKI, Aleksandar. "Application of Autoencoders on Single-Cell Data," 2018.
- Aurélien Géron. *Hands-on Machine Learning with Scikit-Learn and TensorFlow Concepts, Tools, and Techniques to Build Intelligent Systems*, 2019.
- Barto, Andrew G, and Richard S Sutton. *Reinforcement Learning: An Introduction (Adaptive Computation and Machine Learning)*. Mit Press, 2018.
- Bertsekas, Dimitri P. *Reinforcement Learning and Optimal Control*. Belmont, Massachusetts: Athena Scientific, 2019.
- BÜTEPAGE, JUDITH. "Generative Models for Action Generation and Action Understanding," 2019.

- Charniak, Eugene. *Introduction to Deep Learning*. Cambridge, Ma: Mit Press, 2018.
- Chen, Gang. "A Gentle Tutorial of Recurrent Neural Network with Error Backpropagation." *ArXiv:1610.02583 [Cs]*, January 14, 2018. <https://arxiv.org/abs/1610.02583>.
- Chollet, François. *Deep Learning with Python*. Shelter Island (New York, Estados Unidos): Manning, Cop, 2018.
- Di, Wei, Anurag Bhardwaj, and Jianing Wei. *Deep Learning Essentials : Your Hands-on Guide to the Fundamentals of Deep Learning and Neural Network Modeling*. Birmingham: Packt, 2018.
- Dong, Hao, Zihan Ding, and Shanghang Zhang. *Deep Reinforcement Learning : Fundamentals, Research and Applications*. Singapore: Springer, 2020.
- Faradonbeh, Soroor Malekmohammadi, and Faramarz Safi-Esfahani. "A Review on Neural Turing Machine." *ArXiv:1904.05061 [Cs]*, November 15, 2020. <https://arxiv.org/abs/1904.05061>.
- Foster, David. *Generative Deep Learning : Teaching Machines to Paint, Write, Compose, and Play*. Beijing ; Boston ; Farnham ; Sebastopol ; Tokyo O'reilly, 2019.
- Ghosh, Tomojit. "SUPERVISED AND UNSUPERVISED TRAINING OF DEEP AUTOENCODER," 2017.
- Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep Learning*. Cambridge, Massachusetts: The Mit Press, 2017.
- Graesser, Laura, and Wah Loon Keng. *Foundations of Deep Reinforcement Learning : Theory and Practice in Python*. Boston: Addison-Wesley, 2020.
- Gravelines, Céline. "Deep Learning via Stacked Sparse Autoencoders for Automated Voxel-Wise Brain Parcellation Based on Functional Connectivity," 2014.

- Greve, Rasmus Boll, Emil Juul Jacobsen, and Sebastian Risi. “Evolving Neural Turing Machines for Reward-Based Learning.” *Proceedings of the Genetic and Evolutionary Computation Conference 2016*, July 20, 2016. <https://doi.org/10.1145/2908812.2908930>.
- Gulli, Antonio, and Sujit Pal,. *Deep Learning with Keras : Implement Neural Networks with Keras on Theano and TensorFlow*. Birmingham, Uk ; Mumbai: Packt Publishing, 2017.
- Hamilton, William L. *Graph Representation Learning*. S.L.: Morgan & Claypool Publish, 2020.
- Ho, Jonathan, Xi Chen, Aravind Srinivas, Yan Duan, and Pieter Abbeel. “Flow++: Improving Flow-Based Generative Models with Variational Dequantization and Architecture Design.” *ArXiv:1902.00275 [Cs, Stat]*, May 15, 2019. <https://arxiv.org/abs/1902.00275>.
- Hope, Tom, Yehezkel S Resheff, and Itay Lieder. *Learning TensorFlow: A Guide to Building Deep Learning Systems*. Sebastopol, Ca: O’reilly Media, 2017.
- Kazak, Veronica. “UNSUPERVISED FEATURE EXTRACTION WITH AUTOENCODER FOR THE REPRESENTATION OF PARKINSON’S DISEASE PATIENTS,” 2018.
- Kobyzev, Ivan, Simon J. D. Prince, and Marcus A. Brubaker. “Normalizing Flows: An Introduction and Review of Current Methods.” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 1–1. <https://doi.org/10.1109/TPAMI.2020.2992934>.
- Lupo, Francesco. “Variational Autoencoder for Unsupervised Anomaly Detection,” 2019.
- Makhzani, Alireza. “Unsupervised Representation Learning with Autoencoders,” 2018.

- MANELA, Binyamin. "Deep Reinforcement Learning for Complex Manipulation Tasks with Sparse Feedback," 2020.
- Marcus, Gary. "Deep Learning: A Critical Appraisal." arXiv.org, 2018. <https://arxiv.org/abs/1801.00631>.
- Marsland, Stephen. *Machine Learning: An Algorithmic Perspective*. Boca Raton, Fl: Crc Press, 2015.
- Maxim Lapan. *Deep Reinforcement Learning Hands-on: Apply Modern RL Methods to Practical Problems of Chatbots, Robotics, Discrete Optimization, Web Automation, and More*. Birmingham ; Mumbai Packt January, 2020.
- Mohit Sewak, and Springerlink (Online Service. *Deep Reinforcement Learning: Frontiers of Artificial Intelligence*. Singapore: Springer Singapore, 2019.
- Nielsen, Michael A. *Neural Networks and Deep Learning*. Determination Press, 2015.
- Nikhil Buduma. *Fundamentals of Deep Learning: Designing Next-Generation Artificial Intelligence Algorithms*. Beijing, Boston, Farnham, Sebastopol, Tokyo: O'reilly, 2017.
- Osinga, Douwe. *Deep Learning Cookbook: Practical Recipes to Get Started Quickly*. Sebastopol, Ca: O'reilly Media, 2018.
- Oussidi, Achraf, and Azeddine Elhassouny. "Deep Generative Models: Survey." *2018 International Conference on Intelligent Systems and Computer Vision (ISCV)*, April 2018. <https://doi.org/10.1109/isacv.2018.8354080>.
- Patterson, Josh, and Adam Gibson. *Deep Learning: A Practitioner's Approach*. Beijing ; Sebastopol: O'reilly Media, 2017.
- Pong, Vitchyr, Shixiang Gu, Murtaza Dalal, and Sergey Levine. "Temporal Difference Models: Model-Free Deep RL for Model-Based Control." *ArXiv:1802.09081 [Cs]*, February 24, 2020. <https://arxiv.org/abs/1802.09081>.

- Ragav Venkatesan, and Baoxin Li. *Convolutional Neural Networks in Visual Computing: A Concise Guide*. Boca Raton, Fl: Crc Press, 2018.
- Ramsundar, Bharath, and Reza Bosagh Zadeh. *TensorFlow for Deep Learning: From Linear Regression to Reinforcement Learning*. Beijing: O'reilly Media, 2018.
- Rodríguez Esmerats, Pau. "Graph Neural Networks and Its Applications," 2019.
- Rosebrock, Adrian. *Deep Learning for Computer Vision with Python: Starter Bundle*. United States: Pyimagesearch, 2017.
- Ruder, Sebastian. "An Overview of Gradient Descent Optimization Algorithms." arXiv.org, 2016. <https://arxiv.org/abs/1609.04747>.
- Rungta, Krishna. *TensorFlow in 1 Day: Make Your Own Neural Network*. United States?, 2018.
- Sandro Skansi. *Guide to Deep Learning Basics: Logical, Historical and Philosophical Perspectives*. Cham, Switzerland: Springer, 2020.
- SEXTON, Conor. "Advancing Neural Turing Machines: Learning a Solution to the Shortest Path Problem," 2017.
- Soetens, Robin. "Reinforcement Learning Applied to Keepaway, a RoboCup-Soccer Subtask," 2010.
- Tan, Chuanqi, Fuchun Sun, Tao Kong, Wenchang Zhang, Chao Yang, and Chunfang Liu. "A Survey on Deep Transfer Learning." arXiv.org, 2018. <https://arxiv.org/abs/1808.01974>.
- Uday Kamath, Zhanjiang Liu, and James Whitaker. *Deep Learning for NLP and Speech Recognition*. Cham, Switzerland Springer, 2019.
- Vasilev, Ivan, Daniel Slater, Gianmario Spacagna, Peter Roelants, and Valentino Zocca. *Python Deep Learning: Exploring Deep*

- Learning Techniques and Neural Network Architectures with PyTorch, Keras and TensorFlow*. Birmingham ; Mumbai Packt January, 2019.
- Vath, Dirk. “Deep Reinforcement Learning in Dialog Systems,” 2018.
- Ven, van de. “A Deep Graph Convolutional Neural Network Aiding in Finding Feasible Shunt Plans,” 2018.
- Wani, M A, Farooq Ahmad Bhat, Saduf Afzal, and Asif Iqbal Khan. *Advances in Deep Learning*. Singapore: Springer, 2020.
- Wu, Zonghan, Shirui Pan, Fengwen Chen, Guodong Long, Chengqi Zhang, and Philip S. Yu. “A Comprehensive Survey on Graph Neural Networks.” *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 1–21. <https://doi.org/10.1109/TNNLS.2020.2978386>.
- Yang, Qiang. *Transfer Learning*. Cambridge Cambridge University Press, 2020.
- Yu, Chao, Jiming Liu, and Shamim Nemati. “Reinforcement Learning in Healthcare: A Survey.” *ArXiv:1908.08796 [Cs]*, April 24, 2020. <https://arxiv.org/abs/1908.08796>.
- Zhang, Ziwei, Peng Cui, and Wenwu Zhu. “Deep Learning on Graphs: A Survey.” *ArXiv:1812.04202 [Cs, Stat]*, March 13, 2020. <https://arxiv.org/abs/1812.04202>.

ماذا تقرأ في هذا الكتاب:

- مبادئ ومفاهيم التعلم العميق
- التعلم الخاضع للإشراف: الشبكة العصبية أمامية التغذية، المتكررة، الالتفافية
- التعلم التمثيلي غير الخاضع للإشراف العميق: المشفرات الذاتية ونماذج التوليد
- التعلم المعزز العميق
- التعلم الانتقالي العميق
- التعلم العميق الهندسي

