


Sumérgete en el aprendizaje profundo



ton Zhang, Zachary C. Lipton, Mu Li, Alexander J. Smola · 20

Audiolecciones ilustradas

Lecturized

Sumérgete en el aprendizaje profundo

Audiolecciones ilustradas

Aston Zhang, Zachary C. Lipton, Mu Li, Alexander J. Smola · 2023

Contado como lecciones ilustradas por Lecturized
lecturized.com

Del original: Dive into Deep Learning (Cambridge University Press, 2023), d2l.ai

Índice

Una tienda que nunca aprende

Programar con ejemplos

Datos buenos, datos malos

Exámenes de práctica y el examen real

Adivinar cuánto

¿Cuál es?

Etiquetas, clasificaciones y su sección de recomendaciones

Cuando importa el orden

Aprender sin respuestas

Aprender haciendo

Raíces antiguas


La gran aceleración

En todas partes, casi sin verse

Qué lo hace profundo

Una tienda que nunca aprende

Abra una aplicación de compras, pulse «añadir a la cesta» en un par de calcetines y observe cómo el numerito de la cesta salta a uno. Hágalo otra vez mañana, o mil veces, y saltará exactamente igual. Alguien escribió hace mucho una regla para esa pulsación, y la regla no cambia porque usted la haya usado.



Una tienda hecha de reglas

La mayoría de los programas con los que se cruza en un día están hechos así, como reglas escritas por personas. El libro imagina a un equipo ante una pizarra planeando una tienda en línea. Los clientes la

verán en un navegador o en una aplicación del teléfono; una base de datos recordará a cada cliente y cada compra; y en medio está lo que los autores llaman la lógica de negocio, el cerebro de la tienda, un conjunto de reglas que dicen qué hacer en cada situación. Luego el equipo busca casos incómodos, como alguien que pulsa «comprar» con la cesta vacía, y escribe una regla para cada uno. Tras algunas pruebas funciona, y la tienda puede abrir antes de que llegue un solo cliente real. Los autores lo admiran, y añaden un consejo sin rodeos: si usted puede escribir reglas que acierten absolutamente siempre, no necesita aprendizaje automático.

Ahora dele al mismo equipo trabajos más difíciles. Predecir el tiempo de mañana a partir de imágenes de satélite y de las mediciones de las semanas pasadas. Responder a una pregunta escrita con palabras cotidianas. Encontrar a cada persona de una foto y trazar un contorno alrededor de cada una. Sugerir cosas que a un comprador le encantarán pero que nunca habría encontrado navegando. Ese último trabajo es lo que intenta su sección de recomendaciones cada vez que la abre. Incluso a los mejores programadores les costaría escribir las reglas para cualquiera de estas tareas.

BLANCO MÓVIL

ATRAPADO

WIN \$


REGLA

WIN \$\$

SE
ESCAPA

MUY ENREDADO

FOTO



¿CÓMO?


AMIGO

Dos razones por las que fallan las reglas

Hay dos razones. A veces la respuesta correcta no deja de moverse, así que las reglas fijas se quedan viejas y una buena solución tiene que adaptarse a medida que cambia el mundo. Un filtro de spam vive con esto: en cuanto atrapa un tipo de correo basura, los remitentes cambian la redacción. Otras veces la relación entre lo que entra y lo que debería salir es demasiado enredada para escribirla. Usted reconoce al instante la cara de un amigo entre la multitud, pero nunca podría enumerar los pasos que dio su cerebro para lograrlo.

El aprendizaje automático es el estudio de los métodos que aprenden de la experiencia, normalmente de muchos ejemplos registrados, y que mejoran cuantos más ven. Las reglas de la tienda siguen iguales por muchos clientes que pasen, hasta que un programador decide

reescribirlas. Un sistema que aprende mejora con los mismos ejemplos que ve. Cuando un asistente de voz entiende mejor cómo habla de verdad la gente, nadie escribió una regla para cada voz; aprendió de grandes cantidades de voz grabada. El libro trata de una potente familia de estos métodos, llamada aprendizaje profundo, que está detrás de gran parte del progreso reciente en visión por computadora, comprensión del lenguaje, medicina y estudio de los genes. El chatbot al que usted escribe es uno de sus resultados: nadie escribió sus respuestas como reglas; aprendió los patrones del lenguaje a partir de una enorme cantidad de texto.



Reglas fijas frente a aprendizaje

Para recordar

Los programas corrientes son reglas escritas por personas, y se comportan igual por mucho que se usen. Cuando las personas pueden prever cada caso y acertar siempre, las reglas bastan. Algunas tareas se resisten a las reglas, porque la respuesta no deja de cambiar o porque el camino hasta ella es demasiado enredado para escribirlo. El aprendizaje automático trata de métodos que mejoran con la experiencia, y el aprendizaje profundo es la familia de esos métodos que enseña este libro.

Preguntas

1. ¿Por qué el número de la cesta salta igual por muchas veces que lo pulse?
 - a. La aplicación todavía está reuniendo ejemplos de los que aprender
 - b. Sigue una regla escrita de antemano que no cambia con el uso
 - c. El teléfono olvida cada pulsación al instante
 - d. Los hábitos de compra cambian demasiado deprisa para aprenderlos
2. ¿Cuándo dice el libro que no necesita aprendizaje automático?
 - a. Cuando la tarea tiene que ver con una aplicación del teléfono
 - b. Cuando todavía no hay muchos datos

- c. Cuando puede escribir reglas que aciertan absolutamente siempre
 - d. Cuando todavía no han llegado los clientes
3. Un filtro de spam no deja de dejar pasar correo basura nuevo. ¿Cuál de las dos razones por las que fallan las reglas muestra esto?
- a. La respuesta correcta no deja de moverse porque los remitentes cambian la redacción
 - b. La relación entre el correo y la respuesta nunca se puede aprender
 - c. Los programadores olvidaron probar el caso de la cesta vacía
 - d. El filtro ha visto demasiados ejemplos
4. ¿Qué distingue a un sistema que aprende de las reglas de la tienda?
- a. Nunca se equivoca
 - b. Lo escriben mejores programadores
 - c. No necesita ningún ejemplo
 - d. Mejora con los ejemplos que ve

Respuestas

- 1. b)** Alguien escribió hace mucho una regla para esa pulsación, y la regla no cambia porque usted la haya usado.
- 2. c)** Si usted puede escribir reglas que acierten absolutamente siempre, no necesita aprendizaje automático.
- 3. a)** A veces la respuesta correcta no deja de moverse: en cuanto el filtro atrapa un tipo de correo basura, los remitentes cambian la redacción.

4. d) Las reglas de la tienda siguen iguales hasta que un programador las reescribe, mientras que un sistema que aprende mejora con los mismos ejemplos que ve.

Ejercicios

1. Para cada uno de los cuatro trabajos difíciles (el tiempo de mañana, responder a una pregunta escrita, trazar un contorno alrededor de cada persona de una foto, sugerir cosas que un comprador nunca encontraría), diga qué razón dificulta las reglas: la respuesta no deja de cambiar, o el camino hasta ella es demasiado enredado para escribirlo.

Pista: Pregúntese si la respuesta correcta se desliza con el tiempo o si simplemente no podría enumerar los pasos.

Respuesta: El tiempo y los gustos de los compradores no dejan de cambiar, así que las reglas fijas se quedan viejas, y el tiempo además es enredado. Responder preguntas cotidianas y encontrar a las personas de una foto son del tipo enredado: lo hacemos con facilidad pero no sabemos enumerar los pasos. Varios trabajos tienen los dos problemas.


2. Explique con sus palabras por qué una regla sirve para un cliente que pulsa comprar con la cesta vacía.

Pista: ¿Puede el equipo ver venir este caso y escribir una vez la respuesta correcta?

Respuesta: El equipo puede prever este caso antes de que llegue ningún cliente y escribir una respuesta que acierte siempre, como un mensaje que diga que la cesta está vacía. Cuando las reglas pueden acertar siempre, no hace falta aprendizaje automático.

Programar con ejemplos

Diga «Hey Siri» u «OK Google» de un lado a otro de una habitación ruidosa y observe cómo se despierta su teléfono. Entre la televisión, el hervidor y toda la gente hablando, captó una frase. Ahora imagine que escribe usted mismo ese programa, con solo un ordenador y una pantalla en blanco. ¿Por dónde empezaría siquiera?




Entra sonido, sale sí o no

Los autores cuentan una pequeña escena, inventada para ilustrar la idea. De camino a comprar café, uno de ellos despierta un teléfono con «Hey Siri» y pregunta cómo llegar a una cafetería. El teléfono

escribe sus palabras, entiende que quiere indicaciones, abre los mapas y muestra varias rutas con el tiempo de viaje previsto junto a cada una. En unos pocos segundos trabajaron varios programas aprendidos distintos. Cuando le pide a un asistente de voz que ponga un temporizador, funciona la misma cadena: un programa escucha la frase de activación, otro escribe sus palabras, otro averigua qué quería decir.

Tomemos solo el primer trabajo, darse cuenta de la palabra de activación. El micrófono convierte el sonido en un largo flujo de números, decenas de miles por segundo. A partir de ese flujo, el programa debe responder solo sí o no: ¿se dijo la frase? Nadie conoce una regla que lo haga de forma fiable, y el libro admite que sus autores tampoco la conocen. Precisamente por eso se usa el aprendizaje automático.

El truco es este: no sabemos explicar cómo reconocer «Alexa», pero nosotros sí la reconocemos. Así que unas personas escuchan muchísimas grabaciones cortas y marcan cada una con sí o no. Esa colección se llama conjunto de datos, y las marcas son etiquetas. En lugar de escribir un reconocedor, escribimos un programa flexible con muchos ajustes regulables, llamados parámetros, y dejamos que el conjunto de datos decida dónde deben quedar. El libro imagina los parámetros como perillas de una máquina. Con las perillas fijadas y sin volver a tocarlas, el programa se llama modelo, y el programa que usa los datos para elegir la posición de las perillas es el algoritmo de aprendizaje.



Etiquetas, perillas y un aprendiz

Un mismo tipo de máquina, con las perillas giradas de un modo, dice sí a «Alexa»; giradas de otro, podría decir sí solo a «Apricot», porque los dos trabajos se parecen. Convertir fotos en pies de foto o traducir del inglés al chino es un trabajo muy distinto, y puede necesitar otro tipo de máquina.

Pruébelo

Pida a un amigo que diga una palabra susurrando, murmurando y gritando desde la habitación de al lado. Usted la reconocerá cada vez, pero no conseguirá escribir qué hace que sea esa palabra y no otra parecida. Esa distancia, entre poder hacer algo y poder enunciar la regla, es la razón por la que aprendemos de ejemplos.

Con las perillas puestas al azar, el modelo no reconoce nada. El entrenamiento es la forma de encontrar la posición correcta, y el libro lo dibuja como un ciclo. Se empieza con un modelo que no hace nada útil, se le muestran algunas grabaciones etiquetadas, se retocan las perillas para que lo haga un poco mejor con ellas y se repite con más ejemplos hasta que es muy bueno. Los autores lo llaman programar con datos. Un detector de gatos se puede «programar» del mismo modo, mostrándole muchas imágenes de gatos y perros, hasta que da un sí rotundo para los gatos, un no rotundo para los perros y algo intermedio cuando no está seguro. Su filtro de spam aprendió así: se le mostraron muchos mensajes marcados como spam o no, y sus perillas se asentaron donde separan los dos. El aprendizaje profundo, el tema del libro, es una de varias formas populares de hacerlo.

Para recordar

Unos pocos segundos con un teléfono pueden implicar varios programas aprendidos a la vez. Nadie puede escribir reglas para detectar una palabra de activación en el sonido en bruto, pero las personas sí la reconocen, así que etiquetan muchos ejemplos. Luego un programa flexible con perillas ajustables, sus parámetros, se entrena con esos ejemplos, vuelta tras vuelta, hasta que hace el trabajo. Esto es programar con datos, y el aprendizaje profundo es una forma de hacerlo.

Preguntas

1. ¿Por qué las personas pueden ayudar a un ordenador a aprender una palabra de activación para la que nunca podrían escribir reglas?
 - a. Porque ellas mismas reconocen la palabra y pueden marcar las grabaciones con sí o no
 - b. Porque pueden escribir cómo es el sonido en forma de números
 - c. Porque el teléfono ya conoce la palabra desde que se fabrica
 - d. Porque la palabra siempre se dice igual
2. ¿Qué representan las perillas del dibujo del libro?
 - a. Las etiquetas de las grabaciones
 - b. Los ajustes regulables, los parámetros, que deciden cómo se comporta el programa

- c. Los botones que el usuario pulsa en el teléfono
 - d. El número de grabaciones del conjunto de datos
3. ¿Por qué el mismo tipo de máquina podría hacer «Alexa» y «Apricot» pero no convertir fotos en pies de foto?
- a. Los pies de foto necesitan un conjunto de datos mayor del que cualquier máquina puede usar
 - b. Las fotos no se pueden etiquetar
 - c. Las dos palabras de activación son trabajos parecidos, mientras que poner pies de foto es un trabajo muy distinto
 - d. «Apricot» tiene más letras que «Alexa»
4. ¿Qué ocurre en cada vuelta del entrenamiento?
- a. Todas las perillas se vuelven a poner al azar
 - b. Un programador escribe una regla más
 - c. El conjunto de datos se tira y se vuelve a reunir
 - d. Las perillas se retocan para que el modelo lo haga un poco mejor con algunos ejemplos etiquetados

Respuestas

1. **a)** No sabemos explicar cómo reconocer la palabra, pero nosotros sí la reconocemos, así que marcamos muchas grabaciones para que el programa aprenda de ellas.
2. **b)** El libro imagina los parámetros, los ajustes regulables del programa, como perillas de una máquina.
3. **c)** Los dos trabajos de palabra de activación se parecen, así que basta otro giro de las mismas perillas; poner pies de foto es un trabajo muy distinto y puede necesitar otra máquina.

4. d) Se le muestran al modelo algunas grabaciones etiquetadas, se retocan las perillas para que lo haga un poco mejor con ellas y se repite.

Ejercicios

1. Ordene estos pasos del entrenamiento: repetir hasta que el modelo sea bueno; empezar con un modelo que no hace nada útil; retocar las perillas; mostrarle algunos ejemplos etiquetados. ¿Por qué es inútil el primer modelo?

Pista: ¿Qué ha aprendido un modelo antes de ver ningún ejemplo?

Respuesta: Empezar con un modelo que no hace nada útil, mostrarle algunos ejemplos etiquetados, retocar las perillas para que lo haga mejor con ellos y repetir hasta que sea bueno. El primer modelo es inútil porque sus perillas están al azar y todavía no ha aprendido nada.


2. Explique con sus palabras por qué los autores llaman al entrenamiento «programar con datos».

Pista: ¿Quién decide cómo se comporta el programa terminado?

Respuesta: Nadie escribe el comportamiento del programa regla a regla. Se fija mostrándole muchos ejemplos etiquetados y dejando que las perillas se asienten donde el programa funciona bien, así que los ejemplos hacen el trabajo que habrían hecho las reglas escritas a mano.

Datos buenos, datos malos

Amplíe al máximo una foto en su teléfono, y la imagen se rompe en diminutos cuadrados de colores. Cada cuadrado son solo tres lecturas de brillo, una para el rojo, una para el verde y una para el azul. Para un programa que aprende, su foto de vacaciones no es más que una larga lista de esos números. Esa es la materia prima con la que trabaja toda máquina que aprende.



Una foto no es más que números

El libro nombra cuatro piezas que tiene todo problema de aprendizaje automático, sea del tipo que sea. Primero, los datos de los que

aprende la máquina. Segundo, el modelo, el programa lleno de perillas que convierte esos datos en una respuesta. Tercero, una forma de puntuar lo bien o lo mal que lo está haciendo el modelo. Cuarto, un método para girar las perillas de modo que la puntuación mejore. Las partes siguientes tratan de las tres últimas; aquí el tema son los datos.

Los datos son un montón de ejemplos, y cada ejemplo tiene que convertirse en números antes de que una máquina pueda usarlo. Una foto se convierte en las lecturas de sus píxeles, y hasta una foto cuadrada pequeña se convierte ya en bastante más de cien mil números. Un historial de hospital se convierte en la edad del paciente, su pulso, otras enfermedades, medicamentos y operaciones recientes, todo escrito como números, y lo que hay que predecir podría ser si el paciente sobrevive el mes siguiente. Su filtro de spam ve cada mensaje del mismo modo, como un conjunto de números que lo describen, con «spam» o «no spam» como la respuesta que debe dar.

Lo más fácil es que cada ejemplo llegue con el mismo número de lecturas, como fotos tomadas todas con el mismo microscopio. La vida real es más desordenada. Las imágenes que se encuentran en internet vienen de todos los tamaños y formas; se pueden recortar todas a un mismo tamaño, pero lo que se corta se pierde. El texto es peor: una reseña de una tienda solo dice «¡es malísimo!», otra sigue durante páginas. El libro cuenta como uno de los grandes puntos fuertes del aprendizaje profundo que maneja ejemplos de distinta longitud con mucha más soltura que los métodos más antiguos. Por eso el chatbot al que usted escribe acepta una pregunta de tres palabras tan a gusto como una de tres páginas.

Más datos suelen facilitar todo. Con más ejemplos se puede entrenar un modelo más potente y hay que incorporar menos

suposiciones de antemano. El libro dice que el paso de pequeñas colecciones de ejemplos a otras enormes es una de las razones principales del despegue del aprendizaje profundo; muchos de sus mejores modelos sencillamente no funcionan sin enormes cantidades de datos.



Más datos, los datos adecuados

Pero una montaña de datos no sirve de nada si son los datos equivocados. Si los ejemplos están llenos de errores, o describen cosas que no tienen que ver con lo que queremos predecir, el aprendizaje fracasa: si entra basura, sale basura. Y donde las máquinas ayudan a decidir sobre personas, en la policía, la contratación o los préstamos, los datos malos hacen daño real. Un peligro es que algunas personas falten por completo en los ejemplos, como un detector de cáncer de

piel al que nunca se le mostró piel oscura. Otro es que los ejemplos arrastren viejos prejuicios: un programa entrenado con las decisiones de contratación pasadas de una empresa puede aprender a repetir su injusticia de forma automática. Los autores subrayan que esto puede ocurrir sin que nadie lo pretenda, ni siquiera lo note.

Para recordar

Todo problema de aprendizaje tiene cuatro piezas: datos, un modelo, una puntuación de lo bien que lo hace y un método para girar sus perillas. Los datos deben convertirse en números, y una sola foto pequeña ya se convierte en más de cien mil. Los ejemplos de distintos tamaños, como reseñas y fotos de internet, son incómodos, y el aprendizaje profundo los maneja relativamente bien. Más datos ayudan, pero solo los datos adecuados: los errores, los grupos ausentes o los viejos prejuicios en los ejemplos se convierten en fallos e injusticia en la máquina.

Preguntas

1. ¿Por qué hay que convertir una foto en números antes de que una máquina pueda aprender de ella?
 - a. Porque una máquina que aprende solo trabaja con números, como las lecturas de brillo de cada cuadradito
 - b. Porque los números ocupan menos espacio que las imágenes
 - c. Porque las etiquetas solo se pueden unir a números
 - d. Porque si no, la foto sería demasiado grande para recortarla

2. ¿Por qué las reseñas de tiendas son datos incómodos?
 - a. Las escribe muy poca gente
 - b. Tienen longitudes muy distintas, de dos palabras a varias páginas
 - c. No contienen información útil
 - d. No se pueden guardar en un ordenador
3. Un programa entrenado con las decisiones de contratación pasadas de una empresa trata injustamente a algunos candidatos. ¿Cuál es la causa probable?
 - a. Se le dieron demasiados datos
 - b. Nunca se giraron sus perillas
 - c. Los ejemplos arrastraban viejos prejuicios, que aprendió a repetir
 - d. Las solicitudes eran demasiado cortas
4. ¿Por qué importó tanto el paso a colecciones enormes de ejemplos?
 - a. Porque los datos grandes no necesitan puntuación
 - b. Porque los métodos antiguos no sabían leer texto
 - c. Porque los datos grandes eliminan todo prejuicio
 - d. Porque muchos de los mejores modelos de aprendizaje profundo sencillamente no funcionan sin enormes cantidades de datos

Respuestas

1. a) Para un programa que aprende, una foto no es más que una larga lista de lecturas de brillo; cada ejemplo tiene que convertirse en números.

- 2. b)** Una reseña solo dice «¡es malísimo!», otra sigue durante páginas, así que no llegan con el mismo número de lecturas.
- 3. c)** Si los ejemplos arrastran viejos prejuicios, un programa entrenado con ellos puede aprender a repetir esa injusticia de forma automática.
- 4. d)** El paso de pequeñas colecciones a otras enormes es una de las razones principales del despegue del aprendizaje profundo; muchos de sus mejores modelos necesitan enormes cantidades de datos.

Ejercicios

1. Un detector de cáncer de piel funciona muy bien en las pruebas de sus creadores, pero falla a menudo en una clínica que atiende a muchos pacientes de piel oscura. Explique qué salió mal probablemente y cómo podría evitarse.

Pista: Piense en quién aparecía en los ejemplos de los que aprendió el detector.

Respuesta: Las personas de piel oscura probablemente faltaban, o casi faltaban, en los ejemplos de entrenamiento, así que el detector nunca aprendió cómo se ve la enfermedad en la piel oscura. La solución es reunir ejemplos que cubran a todas las personas con las que se usará el detector.


2. Nombre las cuatro piezas que tiene todo problema de aprendizaje y diga con sus palabras para qué sirve cada una.

Pista: De qué aprende, qué da respuestas, qué puntúa, qué ajusta.

Respuesta: Los datos son de lo que aprende la máquina; el modelo es el programa con perillas que da las respuestas; la puntuación dice lo bien o lo mal que lo hace; y el método para girar las perillas las cambia para que la puntuación mejore.

Exámenes de práctica y el examen real

Una estudiante repasa con los exámenes de práctica del año pasado hasta que acierta todas las preguntas. Luego llega el examen real, con preguntas que nunca ha visto, y le cuesta. Había memorizado esos exámenes en lugar de aprender la asignatura. Las máquinas que aprenden pueden caer exactamente en la misma trampa, y esta parte trata de cómo darnos cuenta.




Profundo significa muchos pasos

Empecemos por el modelo. Recibe datos de un tipo y da una predicción, a menudo de otro tipo: entra una foto y sale cuánto sonrío

la persona, o entra un conjunto de lecturas de sensores y sale lo raras que parecen. Los modelos simples sirven para trabajos simples, pero los trabajos de este libro necesitan algo más fuerte. Lo que hace distinto al aprendizaje profundo son sus modelos potentes, contruidos como muchos pasos que transforman un poco los datos y los pasan al siguiente, apilados uno encima de otro. De esa alta pila de pasos viene la palabra «profundo».

Después, ¿cómo sabemos que el modelo ha mejorado? La gente puede discutir si un cambio es una mejora, así que las máquinas que aprenden necesitan una puntuación firme. Esa puntuación se llama función objetivo, y por costumbre se plantea de modo que menos sea mejor, por eso también se llama pérdida. Para predecir un número, la pérdida habitual crece rápido cuanto más lejos está la estimación de la verdad; para clasificar cosas en tipos, lo que cuenta al final es con qué frecuencia se equivoca el modelo. Esa segunda puntuación es incómoda de mejorar directamente, así que en la práctica a menudo se usa durante el entrenamiento una puntuación sustituta más suave. A un filtro de spam se le juzga al final por cuánto correo clasifica mal, aunque por el camino aprenda de una puntuación más suave.




Bajar por la pérdida

Luego necesitamos una forma de girar las perillas para que la pérdida baje, y casi todo el aprendizaje profundo usa un método, llamado descenso de gradiente. En cada paso comprueba, para cada perilla, si girarla un poquito haría subir o bajar la pérdida en los ejemplos de entrenamiento. Luego gira cada perilla un poco en la dirección que baja la pérdida, y repite. Imagine que baja por una ladera en medio de una niebla espesa: no ve el valle, pero nota hacia dónde se inclina el suelo bajo sus pies, da un pequeño paso cuesta abajo y vuelve a tantear.

Aquí vuelve la estudiante. Las perillas se ajustan con un montón de ejemplos, el conjunto de entrenamiento, y se comprueban con otro montón guardado aparte y nunca usado para ajustar, el conjunto de

prueba. Una buena puntuación en el conjunto de entrenamiento es como una buena nota en los exámenes de práctica: alentadora, pero no una promesa. Hacerlo bien con ejemplos nuevos, no vistos, se llama generalización, y de un modelo que brilla con sus ejemplos de entrenamiento pero falla con los nuevos se dice que está sobreajustado. Una sección de recomendaciones que encaja a la perfección con lo que usted pulsó el mes pasado pero no le sugiere nada que quiera después es el tipo de fallo que un conjunto de prueba debe detectar.



Conjunto de entrenamiento y de prueba

Para recordar

Un modelo convierte datos en predicciones, y los modelos del aprendizaje profundo son altas pilas de pasos, por eso se llaman profundos. La pérdida es una puntuación firme de lo mal que lo está haciendo un modelo, y menos es mejor. El descenso de gradiente baja la pérdida tanteando, perilla a perilla, hacia dónde es cuesta abajo y dando un pequeño paso en esa dirección, una y otra vez. El éxito se comprueba en un conjunto de prueba con el que el modelo nunca se entrenó, porque un modelo que solo memorizó sus ejemplos de entrenamiento está sobreajustado.

Preguntas

1. ¿De dónde viene la palabra «profundo» en aprendizaje profundo?
 - a. De las enormes cantidades de datos que necesita
 - b. De que sus modelos son altas pilas de pasos, cada uno de los cuales transforma los datos y los pasa adelante
 - c. De lo difíciles que son de entender sus ideas
 - d. De lo bajo que puede llegar su pérdida
2. ¿Qué hace el descenso de gradiente en cada paso?
 - a. Pone todas las perillas en nuevos valores al azar
 - b. Comprueba el conjunto de prueba y se detiene si va bien

- c. Tantea, para cada perilla, qué sentido baja la pérdida, y gira cada perilla un poco en ese sentido
 - d. Añade más ejemplos al conjunto de entrenamiento
3. ¿Por qué se comprueba un modelo con un conjunto de prueba con el que nunca se entrenó?
- a. Porque una buena puntuación con ejemplos conocidos no demuestra que vaya a hacerlo bien con los nuevos
 - b. Porque el conjunto de entrenamiento siempre es demasiado pequeño
 - c. Porque el conjunto de prueba tiene una pérdida menor
 - d. Porque el descenso de gradiente solo funciona con el conjunto de prueba

Respuestas

1. **b)** Los modelos del aprendizaje profundo se construyen como muchos pasos apilados uno encima de otro, y de esa alta pila viene la palabra.
2. **c)** Comprueba para cada perilla si un giro minúsculo subiría o bajaría la pérdida, y luego gira cada una un poco en la dirección que la baja.
3. **a)** Una buena puntuación en el conjunto de entrenamiento es como una buena nota en los exámenes de práctica: alentadora, pero no una promesa para preguntas nuevas.

Ejercicios

1. Explique en qué se parece bajar por una ladera con niebla al descenso de gradiente. ¿Qué representa la altura del terreno y qué su posición?

Pista: ¿Qué intenta hacer pequeño el descenso de gradiente?

Respuesta: La altura del terreno representa la pérdida, y su posición representa las posiciones de las perillas. No ve el fondo, pero nota hacia dónde es cuesta abajo donde está y da un pequeño paso en esa dirección, igual que el descenso de gradiente comprueba hacia dónde cada perilla baja la pérdida y la gira un poco, una y otra vez.


2. Un modelo acierta 99 de 100 ejemplos de entrenamiento pero solo 60 de 100 ejemplos de prueba. ¿Qué ha pasado, y qué dice de ello la historia de la estudiante?

Pista: Compare los exámenes de práctica y el examen real.

Respuesta: El modelo está sobreajustado: en la práctica ha memorizado sus ejemplos de entrenamiento y no generaliza a los nuevos, como la estudiante que memorizó los exámenes de práctica y luego tuvo problemas con las preguntas nuevas del examen real.

Adivinar cuánto

Un fontanero pasa tres horas desatascando sus desagües y le manda una factura de trescientos cincuenta dólares. Un amigo suyo llama al mismo fontanero para dos horas y paga doscientos cincuenta. Ahora un vecino pregunta cuánto costaría un trabajo de cuatro horas. Seguramente puede responder sin ninguna clase de matemáticas, y la forma en que lo hace es el corazón de esta parte.




Dos facturas del fontanero

Primero, una mirada más amplia. El detector de palabra de activación es solo uno de muchos problemas que puede abordar el aprendizaje

automático, y el libro recorre ahora los tipos principales, empezando por el más común. En el aprendizaje supervisado se nos dan ejemplos en los que conocemos tanto lo que entra, las características, como la respuesta correcta, la etiqueta. El trabajo es construir un modelo que, al ver las características de un caso nuevo, prediga su etiqueta. Se llama supervisado porque hacemos de supervisores y le damos al modelo ejemplos etiquetados de los que aprender la posición de sus perillas. Más exactamente, el modelo estima cuán probable es cada respuesta, dado lo que puede ver.

La mayor parte del aprendizaje automático que funciona bien en los negocios es de este tipo, porque muchísimas tareas encajan en el esquema: adivinar algo desconocido a partir de lo conocido. ¿Hay cáncer en esta imagen o no? ¿Cómo se dice en francés esta frase inglesa? ¿Cuánto valdrán las acciones de esta empresa el mes que viene, a juzgar por las cuentas de este mes? Su filtro de spam encaja en el mismo molde: se le muestra un mensaje y adivina spam o no spam. El esquema es sencillo, pero adopta muchas formas; los textos de cualquier longitud, por ejemplo, necesitan modelos distintos de las entradas que siempre llegan con un mismo tamaño.

El libro esboza el proceso y lo dibuja con flechas. Se reúne un gran montón de ejemplos, se eligen algunos al azar y se obtiene la respuesta correcta de cada uno. A veces las respuestas ya están registradas, como si un paciente sobrevivió al año siguiente; otras veces hay que contratar a personas para etiquetar cosas a mano, como clasificar fotos en categorías. Esos ejemplos etiquetados son el conjunto de entrenamiento. Entran en un método de aprendizaje y sale un modelo entrenado; luego los casos nuevos, nunca vistos, entran en el modelo, y sus salidas se toman como sus predicciones.




De ejemplos etiquetados a predicciones

El tipo de aprendizaje supervisado más fácil de entender es la regresión. Imagine una tabla de ventas de casas, con una fila por casa y una columna por cada dato sobre ella: superficie, dormitorios, baños y minutos a pie hasta el centro. Cada fila es un ejemplo, una lista fija de datos sobre una casa. Un piso pequeño en Nueva York podría ser una superficie diminuta, un dormitorio, un baño y una hora a pie del centro; una casa familiar en Pittsburgh, una superficie mucho mayor, cuatro dormitorios, tres baños y diez minutos a pie. La mayoría de los métodos de aprendizaje clásicos necesitan que cada ejemplo llegue como una lista así de la misma longitud.

Lo que hace que un problema sea de regresión es el tipo de respuesta buscada: un número, como el precio al que se vendió una casa. Si

usted va a comprar una vivienda, un modelo entrenado con ventas pasadas podría estimar un precio justo a partir de los datos de una casa. Una regla práctica es que cualquier pregunta del tipo «¿cuánto?» o «¿cuántos?» es probablemente de regresión. ¿Cuánto durará esta operación, cuánta lluvia caerá aquí en las próximas seis horas, cuántos días pasará este paciente en el hospital? Cuando un servicio de streaming adivina cuántas estrellas le daría usted a una película, eso también es regresión, y en 2009 un equipo que lo hizo lo bastante bien ganó un premio de un millón de dólares de Netflix.

Ahora volvamos al fontanero. Usted probablemente supuso que más horas cuestan más, y que hay un cargo fijo por desplazamiento más una tarifa por cada hora. Con esa suposición, las dos facturas dan la respuesta enseguida: la hora extra costó cien dólares, así que la tarifa es de cien la hora, y cincuenta dólares son solo por presentarse. Si lo ha seguido, ya entiende la idea de la regresión lineal, el tipo más sencillo.



Un cargo fijo más una tarifa

Aquí las dos facturas encajan exactamente con la regla. En los datos reales eso rara vez ocurre, porque cosas que no se han medido también mueven las respuestas: un atasco más difícil, un trayecto más largo, un mal día. Entonces el modelo no puede coincidir con todos los ejemplos, así que intenta que sus estimaciones queden en conjunto lo más cerca posible de las respuestas reales. La forma habitual de medir «cerca» castiga los fallos grandes mucho más que los pequeños, y el libro la usará casi siempre. Los autores añaden que esta elección es la natural cuando las variaciones sueltas se comportan como un ruido aleatorio corriente.

Para recordar

Aprendizaje supervisado significa aprender a predecir una etiqueta a partir de características, usando ejemplos en los que se da la respuesta correcta. La mayor parte del aprendizaje automático exitoso en el mundo real funciona así, desde las imágenes médicas hasta la traducción. La regresión es aprendizaje supervisado en el que la respuesta es un número: cualquier pregunta del tipo «¿cuánto?» o «¿cuántos?». Las dos facturas del fontanero revelan un cargo por desplazamiento más una tarifa por hora, que es la idea de la regresión lineal. Cuando los datos reales no encajan exactamente, el modelo mantiene sus estimaciones lo más cerca que puede, castigando sobre todo los fallos grandes.

Preguntas

1. ¿Cuál de estas preguntas es un problema de regresión?
 - a. ¿Este mensaje es spam o no?
 - b. ¿Hay cáncer en esta imagen?
 - c. ¿Cuántos días pasará este paciente en el hospital?
 - d. ¿Cómo se dice en francés esta frase?
2. ¿Por qué este tipo de aprendizaje se llama supervisado?
 - a. Porque le damos al modelo ejemplos etiquetados de los que aprender la posición de sus perillas
 - b. Porque alguien comprueba cada predicción a mano

- c. Porque se usa sobre todo en los negocios
 - d. Porque el modelo solo puede funcionar mientras alguien lo vigila
3. ¿Por qué un modelo entrenado con precios reales de casas no suele coincidir exactamente con cada venta?
- a. Porque las casas tienen muy pocas características
 - b. Porque cosas que no están en la tabla, como las prisas de un comprador, también mueven los precios
 - c. Porque la regresión solo sirve para fontaneros
 - d. Porque el conjunto de entrenamiento nunca está etiquetado
4. ¿Cómo trata la medida habitual de cercanía un fallo grande comparado con uno pequeño?
- a. Ignora los fallos grandes
 - b. Cuenta todos los fallos igual
 - c. Solo cuenta el fallo más grande
 - d. Castiga el fallo grande mucho más

Respuestas

1. **c)** La regresión es aprendizaje supervisado en el que la respuesta es un número; cualquier pregunta del tipo «¿cuánto?» o «¿cuántos?» es probablemente de regresión.
2. **a)** Hacemos de supervisores y le damos al modelo ejemplos etiquetados de los que aprender la posición de sus perillas.
3. **b)** En los datos reales, cosas que no se han medido también mueven las respuestas, así que el modelo mantiene sus estimaciones lo más cerca que puede en conjunto.

4. d) La forma habitual de medir la cercanía castiga los fallos grandes mucho más que los pequeños.

Ejemplos resueltos

Los precios del fontanero Un fontanero cobró 350 dólares por un trabajo de 3 horas y 250 dólares por uno de 2 horas. Suponiendo un cargo fijo por presentarse más una tarifa por cada hora, ¿cuáles son el cargo y la tarifa, y cuánto costaría un trabajo de 4 horas?

Los dos trabajos difieren en una hora y en 100 dólares, así que cada hora cuesta 100 dólares.

Tres horas suponen 300 de los 350 dólares, así que 50 dólares son el cargo fijo por presentarse.

Compruébelo con la otra factura: 50 más 2 horas a 100 son 250, lo cobrado.

Un trabajo de 4 horas serían 50 más 4 horas a 100.

Respuesta: 100 dólares la hora más 50 dólares por presentarse; un trabajo de 4 horas cuesta 450 dólares

Ejercicios

1. Clasifique en regresión o no: cuánta lluvia caerá en las próximas seis horas; si esta foto es un gato o un perro; cuántas horas durará esta operación; a qué precio se venderá esta casa.

Pista: ¿La respuesta es un número, un cuánto o un cuántos?

Respuesta: La lluvia, la duración de la operación y el precio de la casa piden números, así que son regresión. Gato o perro pide una categoría, así que no es regresión.

2. Un segundo fontanero cobró 200 dólares por 1 hora y 400 dólares por 3 horas. Suponiendo el mismo tipo de precios, ¿cuáles son su



cargo fijo y su tarifa por hora?

Pista: Dos horas más añadieron 200 dólares.

Respuesta: Dos horas añadieron 200 dólares, así que la tarifa es de 100 dólares la hora; quitando los 100 de una hora a la primera factura quedan 100 dólares, así que el cargo fijo es de 100 dólares.

¿Cuál es?

Imagine una seta pálida y hermosa que crece en su jardín. La fotografía con una aplicación que dice estar segura al ochenta por ciento de que la seta es inofensiva. ¿La freiría para cenar? Guarde su respuesta; el libro vuelve a esta seta.




¿Qué clase es?

La regresión responde a «¿cuánto?», pero muchas preguntas son del tipo «¿cuál?». Pensemos en una aplicación bancaria que lee un cheque a partir de una foto. Una vez cortada la imagen en pequeños trozos, uno por cada carácter escrito a mano, lo que queda es decidir

qué carácter, de un conjunto conocido, muestra cada trozo. Los problemas así se llaman clasificación, y necesitan herramientas algo distintas de las de la regresión, aunque mucho se aprovecha.

En la clasificación, el modelo mira las características de un ejemplo, como los píxeles de una imagen, y dice a qué categoría, o clase, pertenece, dentro de un conjunto fijo de opciones. Para los dígitos escritos a mano hay diez clases, del cero al nueve. El caso más sencillo tiene solo dos clases, como gato o perro, y se llama clasificación binaria. Su filtro de spam es clasificación binaria: cada mensaje es spam o no lo es. Donde la regresión produce un número, la clasificación produce una elección de clase. Cuando hay más de dos clases, como con todos los dígitos y letras de la escritura a mano, se llama clasificación multiclase.





Una probabilidad para cada clase

Un modelo que solo puede decir un rotundo «gato» o «perro» resulta difícil de entrenar, así que en su lugar suele dar una probabilidad para cada clase. Al ver una imagen, podría decir noventa por ciento gato, lo que podemos leer como «seguro al noventa por ciento». El tamaño de esa probabilidad da una idea de lo inseguro que está el modelo. Igual que la regresión suele entrenarse manteniendo pequeños los fallos al cuadrado, la clasificación tiene su propia puntuación habitual de lo equivocado que está el modelo, con el curioso nombre de entropía cruzada, que el libro explicará mucho más adelante.

Volvamos ahora a la seta. Supongamos que la aplicación dice que hay un veinte por ciento de probabilidad de que sea una oronja verde, y por tanto un ochenta por ciento de que no lo sea. La respuesta más

probable es «segura», y sin embargo solo un insensato se la comería. El placer de una buena cena no vale una probabilidad de uno entre cinco de morir. Para decidir qué hacer no basta con saber qué respuesta es la más probable; hay que sopesar cada opción según lo probable que sea cada resultado y lo bueno o terrible que sería. Comérsela arriesga una catástrofe; tirar la seta cuesta como mucho una cena perdida. Y la cautela era acertada: la seta de la imagen del libro es de verdad una oronja verde.




Probable no es lo mismo que seguro

Pruébalo

La próxima vez que una aplicación o una web le dé una cifra de confianza, pregúntese cuánto le costaría que la respuesta menos probable fuera la verdadera. Descubrirá que un «sí» al noventa por ciento puede bastar de sobra para elegir una canción, y quedarse muy corto para cruzar una calle o tomar un medicamento.

La clasificación puede ser aún más sutil, porque no todos los errores son iguales. A veces las clases forman un árbol genealógico, como el naturalista Linneo ordenó a los animales en grupos anidados, y entonces confundir parientes cercanos es un error menor que confundir parientes lejanos. Confundir un caniche con un schnauzer es perdonable; confundir un caniche con un dinosaurio es absurdo. Esto se llama clasificación jerárquica. Pero qué árbol importa depende de para qué sea el modelo. Una serpiente de cascabel y una inofensiva culebra rayada son parientes cercanas, y sin embargo confundirlas podría ser mortal.



Algunos errores son peores

Para recordar

La clasificación responde a «¿cuál?»: coloca cada ejemplo en una de un conjunto fijo de clases. Dos clases dan clasificación binaria; más de dos, clasificación multiclase. Los modelos suelen dar una probabilidad para cada clase, lo que además muestra lo seguros que están. La clase más probable no siempre es la que hay que seguir: un veinte por ciento de probabilidad de oronja verde es razón suficiente para no comerse la seta. Cuando las clases forman un árbol genealógico, algunos errores son peores que otros, y cuáles importan más depende del uso, como con las serpientes de cascabel y las culebras rayadas.

Preguntas

1. ¿Cuál de estos es un problema de clasificación y no de regresión?
 - a. ¿Por cuánto se venderá esta casa?
 - b. ¿Qué dígito está escrito en este trozo de un cheque?
 - c. ¿Cuántas horas durará esta reparación?
 - d. ¿Cuánta lluvia caerá mañana?
2. Una aplicación está segura al ochenta por ciento de que una seta no es una oronja verde. ¿Por qué no debería comérsela aun así?
 - a. Porque el ochenta por ciento es la respuesta menos probable
 - b. Porque la aplicación se entrenó con muy pocas setas
 - c. Porque un veinte por ciento de probabilidad de un resultado mortal pesa más que una buena cena
 - d. Porque las setas no se pueden clasificar a partir de fotos
3. ¿Por qué confundir una serpiente de cascabel con una culebra rayada es peor de lo que sugiere su cercanía en el árbol genealógico?
 - a. Porque lo grave de un error lo deciden sus consecuencias, no solo la cercanía de las clases
 - b. Porque las serpientes no se pueden clasificar jerárquicamente
 - c. Porque el modelo dio a las dos la misma probabilidad
 - d. Porque las serpientes de cascabel son más raras en los datos

4. ¿Por qué los clasificadores suelen dar una probabilidad para cada clase en lugar de una respuesta firme?
- a. Porque las respuestas firmes tardan más en imprimirse
 - b. Porque las probabilidades siempre son correctas
 - c. Porque los usuarios prefieren los números
 - d. Porque un modelo que solo da una respuesta rotunda es difícil de entrenar, y las probabilidades además muestran lo seguro que está

Respuestas

1. **b)** La clasificación responde a «¿cuál?»: decidir qué carácter de un conjunto conocido muestra un trozo.
2. **c)** Para decidir, se sopesa cada opción según lo probable que sea cada resultado y lo bueno o terrible que sería; una probabilidad de uno entre cinco de morir no vale una cena.
3. **a)** Qué árbol importa depende de para qué sea el modelo; las dos serpientes son parientes cercanas, y sin embargo confundirlas podría ser mortal.
4. **d)** Un modelo que solo puede decir un rotundo gato o perro es difícil de entrenar, así que da una probabilidad para cada clase, lo que además da una idea de lo inseguro que está.

Ejercicios

1. Clasifique en binaria, multiclase o regresión: spam o no spam; cuál de los diez dígitos aparece en un trozo de cheque; cuánto tiempo pasa un paciente en el hospital; qué letra o dígito es un carácter escrito a mano.

Pista: ¿La respuesta es un número, una de dos clases o una de muchas?

Respuesta: Spam o no spam es clasificación binaria. Los diez dígitos, y las letras más los dígitos, son clasificación multiclase. La duración de la estancia en el hospital es un número, así que es regresión.

2. Una aplicación del tiempo dice que hay un noventa por ciento de probabilidad de que no llueva. Explique por qué podría dejar tranquilamente el paraguas en casa para dar un paseo, pero no dejaría un cuadro valioso en el jardín toda la noche con la misma previsión.


Pista: Compare en cada caso lo probable que es el mal resultado con lo malo que sería.

Respuesta: La probabilidad de lluvia es la misma, una entre diez, pero el daño no. Mojarse un poco en un paseo es un coste pequeño, así que el riesgo está bien; un cuadro estropeado es una gran pérdida, así que ni siquiera una probabilidad de una entre diez merece la pena. Como con la seta, la decisión depende tanto de la probabilidad como de las consecuencias.

Etiquetas, clasificaciones y su sección de recomendaciones

Imagine el viejo cuento alemán de los músicos de Bremen: un burro, con un perro de pie sobre su lomo, un gato sobre el perro y un gallo en lo alto. Muestre esa imagen a un programa entrenado para responder «¿gato o perro?» y se quedará atascado. Tiene que elegir uno, pero están los dos, y además un burro y un gallo. Por bueno que sea el programa, la pregunta para la que se construyó es la equivocada para esta imagen.

MULTIETIQUETA




Una imagen, varias etiquetas

Cuando un ejemplo puede pertenecer a varias clases a la vez, el trabajo se llama clasificación multietiqueta. En lugar de elegir una respuesta, el modelo puede decir: un gato, y un perro, y un burro, y un gallo. Así funciona el etiquetado automático. Una entrada de un blog de tecnología podría llevar entre cinco y diez etiquetas, como «aprendizaje automático», «lenguajes de programación», «computación en la nube». Las etiquetas suelen ir acompañadas: las entradas sobre computación en la nube mencionan a menudo el servicio en la nube de Amazon, y las de aprendizaje automático mencionan a menudo los chips gráficos con los que se entrena.

A veces el conjunto de etiquetas posibles es enorme. En la Biblioteca Nacional de Medicina de Estados Unidos, personal formado etiqueta cada artículo que se añade a su gran índice médico con términos de una lista de unos veintiocho mil encabezamientos temáticos. Las etiquetas permiten a los investigadores encontrar todo lo escrito sobre una cuestión, pero el trabajo es lento, y un artículo puede esperar alrededor de un año para recibirlas. El aprendizaje automático puede aportar etiquetas provisionales mientras tanto, hasta que una persona las revise, y desde hace años hay competiciones sobre cómo hacerlo bien.

La búsqueda es un problema emparentado, pero la pregunta cambia. En una búsqueda en la web suele haber muchas páginas relevantes; lo que importa es cuáles mostrar arriba. Una forma es dar a cada página una puntuación y mostrar primero las puntuaciones más altas. El ingrediente secreto original de Google, PageRank, era una puntuación así, y curiosamente no dependía en absoluto de lo que usted había escrito. Un filtro sencillo seleccionaba las páginas que coincidían con sus palabras, y PageRank ponía luego delante las páginas con más autoridad. Hoy los buscadores usan aprendizaje automático y


modelos del comportamiento de las personas para puntuar cada página para cada búsqueda concreta.



La búsqueda ordena por puntuación

La recomendación es prima hermana de la búsqueda, con una gran diferencia: es personal. Un fan de la ciencia ficción y un amante de las comedias antiguas deberían ver sugerencias de películas muy distintas, y lo mismo vale para las compras, la música y las noticias. A veces la gente le dice al sistema lo que piensa, con estrellas y reseñas. Más a menudo se lo dice solo con lo que hace, como saltarse una canción, lo que puede significar que no le gusta, o simplemente que no encajaba con el momento. Cuando su sección de recomendaciones se reorganiza después de que usted se salte unos cuantos vídeos, está aprendiendo exactamente de este tipo de señal silenciosa. En su

forma más sencilla, el sistema aprende una puntuación para cada artículo, como las estrellas esperadas o la probabilidad de que usted lo compre, y le muestra los artículos con las puntuaciones más altas. El libro incluso muestra una página de libros de aprendizaje profundo que una gran tienda en línea le sugirió a uno de sus autores.



Valoraciones desequilibradas, bucles que se alimentan solos

Construidos de forma ingenua, estos sistemas tienen fallos profundos. Primero, la retroalimentación está desequilibrada: la gente valora sobre todo lo que le encantó o lo que odió, así que las valoraciones se amontonan en una estrella y en cinco, con extrañamente pocas en medio. Segundo, lo que la gente compra hoy es en parte resultado de lo que el sistema recomendó ayer, y puede que el método de aprendizaje no lo tenga en cuenta. Así puede formarse un bucle: el

sistema promociona un artículo, más gente lo compra, las compras lo hacen parecer mejor, y el sistema lo promociona todavía más. Por eso una sección de recomendaciones puede parecer que le muestra cada vez más de lo mismo en cuanto ha pulsado en ello unas cuantas veces. Cómo tratar la retroalimentación desequilibrada, los incentivos de las personas y estos bucles son todavía cuestiones de investigación abiertas.

Para recordar

La clasificación multietiqueta permite que un ejemplo pertenezca a varias clases a la vez, como los cuatro animales de una imagen, y así funciona el etiquetado automático. Los conjuntos de etiquetas pueden ser enormes, como los veintiocho mil encabezamientos médicos, donde el aprendizaje automático ofrece etiquetas provisionales. La búsqueda ordena los resultados relevantes por una puntuación y muestra primero los mejores; PageRank fue una puntuación temprana que ignoraba lo que usted escribía. La recomendación es una ordenación personal, aprendida de las valoraciones y de lo que hace la gente. Las valoraciones desequilibradas y los bucles en que las recomendaciones alimentan su propio éxito hacen la recomendación más difícil de lo que parece.

Preguntas

1. ¿Por qué falla un programa de gato o perro con la imagen de los músicos de Bremen?

- a. Porque la imagen es un dibujo, no una foto
 - b. Porque debe elegir una clase, mientras que en la imagen hay varios animales a la vez
 - c. Porque los burros son más difíciles de reconocer que los gatos
 - d. Porque no era lo bastante preciso
2. ¿En qué se diferenciaba PageRank, la primera puntuación de Google, de las puntuaciones de búsqueda actuales?
- a. Usaba las valoraciones con estrellas de los usuarios
 - b. Puntuaba cada página para las palabras concretas escritas
 - c. No dependía de lo que se escribía; un filtro aparte seleccionaba las páginas que coincidían
 - d. Ordenaba las páginas al azar
3. ¿Por qué las valoraciones suelen amontonarse en una estrella y en cinco?
- a. Porque la gente valora sobre todo lo que le encantó o lo que odió
 - b. Porque el sistema de recomendación oculta las valoraciones de tres estrellas
 - c. Porque la mayoría de los productos son perfectos o están rotos
 - d. Porque las escalas de estrellas solo tienen dos valores
4. ¿Qué bucle de retroalimentación de la recomendación advierte el libro?
- a. Usuarios que valoran dos veces el mismo artículo
 - b. Valoraciones que se pierden cuando se salta una canción

- c. El sistema recomienda solo artículos que nadie ha comprado
- d. El sistema promociona un artículo, más gente lo compra, así que parece mejor y se promociona todavía más

Respuestas

- 1. **b)** Tiene que elegir uno, pero están un gato y un perro, y más; la pregunta para la que se construyó es la equivocada para esta imagen.
- 2. **c)** PageRank, curiosamente, no dependía de lo que usted había escrito; un filtro sencillo seleccionaba las páginas que coincidían y PageRank ponía delante las de más autoridad.
- 3. **a)** La retroalimentación está desequilibrada: la gente valora sobre todo lo que le encantó o lo que odió, así que las valoraciones intermedias son extrañamente pocas.
- 4. **d)** El sistema promociona un artículo, más gente lo compra, las compras lo hacen parecer mejor, y el sistema lo promociona todavía más.

Ejercicios

- 1. Para cada caso, diga si puede ser cierta una clase o varias a la vez: una foto de una sola mascota, gato o perro; una entrada de blog sobre computación en la nube y programación; un artículo médico que trata de la diabetes y del corazón.

Pista: ¿Puede el ejemplo pertenecer a más de una clase al mismo tiempo?

Respuesta: La mascota sola es clasificación corriente con una clase. La entrada de blog y el artículo médico pueden llevar cada uno varias etiquetas a la vez, así que son clasificación multitiqueta, que es como funciona el etiquetado automático.

2. Se salta tres canciones seguidas en una aplicación de música. Explique por qué la aplicación no puede estar segura de que no le gustan, y qué tipo de retroalimentación es esta.

Pista: ¿Qué otra cosa podría significar saltárselas?

Respuesta: Saltarse canciones es retroalimentación dada con lo que usted hace, no con una valoración. Puede significar que no le gustan, pero puede significar solo que no encajaban con el momento, así que la aplicación tiene que tratar la señal con cuidado.

Cuando importa el orden

Pause una película en un momento cualquiera y mire ese único fotograma. Un hombre tiene el brazo levantado; ¿está saludando, lanzando algo o a punto de golpear? Reproduzca un segundo antes y un segundo después, y la respuesta es evidente. Un fotograma solo puede engañar; los fotogramas de alrededor cuentan la historia.

LOS DE ALREDEDOR



CUALQUIER LONGITUD



HISTORIAL

Un fotograma engaña, los fotogramas cuentan


Todo lo visto hasta ahora tenía una forma fija. Una casa llegaba como la misma lista corta de datos, una foto como la misma cuadrícula de píxeles, y la respuesta era un precio, o una probabilidad por clase. Y

cada ejemplo se olvidaba en cuanto el modelo lo había respondido, como si cada caso no tuviera nada que ver con el anterior. Para las casas eso está bien, pero muchos problemas no funcionan así.

Un vídeo puede tener cualquier número de fotogramas, y lo que pasa en uno está mucho más claro cuando el modelo mira también a sus vecinos. Con el lenguaje pasa lo mismo: en la traducción automática entra una frase entera, en un idioma, y sale una frase entera, en otro. En la unidad de cuidados intensivos de un hospital, un modelo podría vigilar a los pacientes y dar la alarma cuando el riesgo de muerte en el día siguiente supere cierto límite. Sería absurdo olvidar cada hora la historia de cada paciente y juzgarlo solo por las últimas lecturas. Los problemas así se llaman aprendizaje de secuencias, porque el modelo recibe secuencias, o las da, o ambas cosas. Cuando tanto la entrada como la salida son secuencias de cualquier longitud, se llama aprendizaje de secuencia a secuencia.

TOM HAS DINNER IN
ENT — — —

WASHINGTON WITH SALLY
ENT — ENT



Etiquetas en orden; sonido largo, texto corto

El libro destaca algunos casos especiales. El primero es etiquetar las palabras de una frase, donde cada palabra recibe una etiqueta, en el mismo orden. Se podría marcar cada palabra como sustantivo, verbo, etcétera, o marcar qué palabras nombran personas, lugares u organizaciones: en «Tom has dinner in Washington with Sally» se etiquetan los nombres Tom, Washington y Sally.

El segundo es el reconocimiento de voz: entra una grabación y sale una transcripción escrita. La dificultad es que el sonido se mide miles de veces por segundo, así que una sola palabra hablada puede extenderse a lo largo de miles de mediciones, y no hay una correspondencia limpia uno a uno entre el sonido y las letras. La salida es mucho más corta que la entrada. Cuando su asistente de voz

escribe en la pantalla su pregunta, acaba de resolver este problema, comprimiendo un largo flujo de sonido en un puñado de palabras. Las personas reconocen bien el habla incluso por una línea telefónica con interferencias, pero para los ordenadores es un reto formidable. La tarea inversa, la síntesis de voz, convierte un texto corto en una grabación de sonido larga.

El tercero es la traducción automática, que añade un giro nuevo: las piezas no tienen por qué venir en el mismo orden. El alemán, por ejemplo, gusta de poner el verbo al final. «Haben Sie sich schon dieses grossartige Lehrwerk angeschaut?» significa «¿Ya ha mirado usted este excelente libro de texto?». Traducido palabra por palabra en el orden alemán, sale «¿Ha usted ya este excelente libro de texto mirado?», que ningún hablante diría. El chatbot al que usted escribe se enfrenta a todo esto a la vez, y a más: para decidir qué decir a continuación, tiene que seguir toda la conversación hasta ese momento y recurrir a conocimientos sobre el mundo. Averiguar en qué orden lee alguien una página web, o mantener una conversación larga, siguen siendo áreas de investigación activas.

ALEMÁN

INGLÉS

HABEN SIE

HAVE YOU

SCHON

ALREADY

DIESES LEHRWERK

LOOKED AT

ANGESCHAUT?

THIS TEXTBOOK?

VERBO AL FINAL

La traducción cambia el orden

Para recordar

Muchos problemas no vienen con formas fijas: los vídeos, las frases y los historiales de pacientes se desarrollan en el tiempo, y cada parte solo tiene sentido junto a las demás. El aprendizaje de secuencias trata entradas o salidas que son secuencias, y el de secuencia a secuencia trata ambas, de cualquier longitud. El etiquetado da a cada palabra una etiqueta en orden; el reconocimiento de voz comprime un sonido largo en un texto corto, y la síntesis de voz hace lo contrario. La traducción es aún más difícil, porque las piezas correspondientes pueden venir en otro orden, como los verbos alemanes al final de la frase.

Preguntas

1. ¿Por qué sería absurdo que un modelo de cuidados intensivos juzgara a cada paciente solo por las últimas lecturas?
 - a. Porque las últimas lecturas siempre son erróneas
 - b. Porque la historia del paciente a lo largo del tiempo ayuda a mostrar el riesgo real
 - c. Porque el modelo solo puede leer un número cada vez
 - d. Porque las alarmas tienen que darse cada hora
2. ¿Qué hace difícil el reconocimiento de voz comparado con etiquetar las palabras de una frase?
 - a. Una palabra puede extenderse a lo largo de miles de mediciones de sonido, así que el sonido y las letras no se corresponden uno a uno
 - b. El habla siempre tiene una longitud fija
 - c. Cada palabra debe recibir una etiqueta de categoría gramatical
 - d. La salida es más larga que la entrada
3. ¿Qué dificultad nueva añade la traducción automática?
 - a. La entrada no tiene palabras
 - b. La salida siempre es más corta que la entrada
 - c. Las piezas correspondientes pueden venir en otro orden, como los verbos alemanes al final
 - d. Cada palabra recibe exactamente una etiqueta

Respuestas

1. **b)** Sería absurdo olvidar cada hora la historia de cada paciente y juzgarlo solo por las últimas lecturas.
2. **a)** El sonido se mide miles de veces por segundo, así que una sola palabra hablada se extiende a lo largo de miles de mediciones y no hay una correspondencia limpia uno a uno.
3. **c)** En la traducción las piezas no tienen por qué venir en el mismo orden; el alemán, por ejemplo, gusta de poner el verbo al final.

Ejercicios

1. Para cada tarea, diga si la salida es más o menos igual de larga que la entrada, mucho más corta o mucho más larga: etiquetar cada palabra de una frase; convertir una grabación en texto; leer un texto en voz alta.

Pista: Compare cuántas piezas entran con cuántas salen.

Respuesta: El etiquetado da una etiqueta por palabra, así que la salida es tan larga como la entrada. El reconocimiento de voz convierte miles de mediciones de sonido en unas pocas palabras, así que la salida es mucho más corta. La síntesis de voz convierte un texto corto en una grabación larga, así que la salida es mucho más larga.

2. Explique con la película en pausa por qué un modelo que olvida cada ejemplo después de responder encaja mal con el vídeo.


Pista: ¿Qué le ayuda a distinguir un saludo de un lanzamiento?

Respuesta: Un fotograma solo puede ser ambiguo, como un brazo levantado que podría estar saludando o lanzando. Los fotogramas de antes y de después lo aclaran, así que un modelo que juzga cada fotograma por separado, olvidando los demás, tira justo el contexto que necesita.

Aprender sin respuestas

Recorra la galería de fotos de su teléfono y busque los álbumes que ha creado por sí sola: playas, mascotas, montañas, las mismas pocas caras. Nadie le dijo qué foto era una playa. Encontró los grupos por su cuenta, sin nada más que las imágenes. ¿Cómo puede una máquina aprender algo si nadie le da las respuestas?

AGRUPAMIENTO




Grupos hallados sin respuestas

El aprendizaje supervisado, dice el libro, es como un trabajo con un jefe muy mandón que está detrás de usted y le dice exactamente qué hacer en cada situación. Aburrido, quizá, pero fácil de contentar:

detectar el patrón y copiar al jefe. El trabajo opuesto es un jefe que le entrega una montaña de datos y le dice: «¡Haga algo de ciencia de datos con esto!». Suena vago porque es vago. Aprender de datos sin respuestas adjuntas se llama aprendizaje no supervisado, y las preguntas que se pueden hacer solo tienen el límite de su imaginación.

El libro enumera algunas. ¿Se pueden ordenar los datos en un puñado de grupos naturales, como fotos de paisajes, perros, bebés, gatos y cumbres, o compradores que navegan de forma parecida? Eso se llama agrupamiento. ¿Pueden unos pocos números captar lo que importa? La trayectoria de una pelota lanzada se describe bien con su velocidad, su tamaño y su peso, y los sastres ajustan la ropa con un pequeño conjunto de medidas del cuerpo. ¿Se pueden colocar las palabras como puntos en un mapa, de modo que las relaciones entre ellas se conviertan en direcciones, y que ir de Italia a Roma sea el mismo paso que ir de Francia a París? ¿Podemos encontrar las causas ocultas de lo que vemos, como la forma en que los precios de la vivienda, la contaminación, la delincuencia, la educación y los salarios se influyen entre sí?

MAPA DE PALABRAS




Palabras como puntos en un mapa

Uno de los avances recientes más emocionantes son los modelos generativos. Aprenden cómo son los datos tan bien que pueden juzgar lo probable que es un ejemplo, o producir ejemplos completamente nuevos por su cuenta. Los generadores de imágenes que pintan un cuadro a partir de su descripción pertenecen a esta familia; el libro cita los modelos de difusión entre los últimos avances.

Otro avance es el aprendizaje autosupervisado, en el que los propios datos aportan las preguntas y las respuestas. Con texto, se oculta una palabra al azar y se pide al modelo que la adivine a partir de las palabras de alrededor; así se pueden aprovechar enormes cantidades de texto sin ningún etiquetado. El chatbot al que usted escribe empezó con un entrenamiento de este tipo, aprendiendo a predecir

palabras ocultas o siguientes en una cantidad enorme de texto. Con imágenes, se puede pedir a un modelo dónde estaba un trozo recortado respecto a otro, que rellene una parte tapada, o que diga si dos imágenes alteradas vienen del mismo original. Lo que un modelo aprende así se puede reutilizar después: se ajusta finamente, con un poco de entrenamiento extra, para la tarea concreta que de verdad le interesa.



Ocultar una palabra y adivinarla

Para recordar

El aprendizaje supervisado tiene un jefe mandón con todas las respuestas; el no supervisado solo recibe los datos y debe encontrar estructura en ellos. Puede encontrar grupos naturales, unos pocos números que captan lo que importa, relaciones entre palabras y causas ocultas. Los modelos generativos aprenden los datos tan bien que pueden producir ejemplos nuevos propios. El aprendizaje autosupervisado fabrica sus propias preguntas a partir de los datos, como adivinar palabras ocultas, y lo que aprende se ajusta luego finamente para la tarea que necesitamos.

Preguntas

1. ¿Cuál es la diferencia clave entre el aprendizaje supervisado y el no supervisado?
 - a. El aprendizaje no supervisado usa menos datos
 - b. En el aprendizaje no supervisado los datos llegan sin respuestas adjuntas, y el modelo debe encontrar la estructura por sí mismo
 - c. El aprendizaje no supervisado necesita a una persona vigilándolo
 - d. El aprendizaje supervisado no puede con las fotos
2. Su teléfono ordena las fotos en playas, mascotas y montañas sin que nadie le diga cuál es cuál. ¿Cómo se llama esto?
 - a. Agrupamiento

- b. Ajuste fino
 - c. Regresión
 - d. Clasificación con etiquetas
3. ¿Cómo obtiene el aprendizaje autosupervisado sus preguntas y respuestas sin que nadie etiquete los datos?
- a. Copia las respuestas de un modelo supervisado
 - b. Pide a los usuarios que valoren ejemplos
 - c. Oculta parte de los datos, como una palabra, y aprende a adivinarla a partir del resto
 - d. Solo funciona con datos etiquetados hace mucho tiempo
4. ¿Qué ocurre después de que un modelo ha aprendido con entrenamiento autosupervisado?
- a. Se tira
 - b. Solo se usa para adivinar palabras ocultas
 - c. Se convierte en un modelo de agrupamiento
 - d. Se ajusta finamente con un poco de entrenamiento extra para la tarea que nos interesa

Respuestas

- 1. b)** Aprender de datos sin respuestas adjuntas se llama aprendizaje no supervisado.
- 2. a)** Ordenar los datos en un puñado de grupos naturales, como paisajes, perros y gatos, se llama agrupamiento.
- 3. c)** Con texto, se oculta una palabra al azar y se pide al modelo que la adivine a partir de las palabras de alrededor, sin ningún etiquetado.

4. d) Lo que un modelo aprende así se puede reutilizar: se ajusta finamente con un poco de entrenamiento extra para la tarea concreta que le interesa.

Ejercicios

1. Diga si cada caso es agrupamiento, un modelo generativo o aprendizaje autosupervisado: agrupar compradores según cómo navegan; una aplicación que pinta un cuadro a partir de su descripción; adivinar una palabra oculta a partir de las de alrededor.

Pista: ¿La tarea es encontrar grupos, crear ejemplos nuevos o responder a una pregunta sacada de los propios datos?

Respuesta: Agrupar compradores es agrupamiento; pintar un cuadro a partir de una descripción es trabajo de un modelo generativo; adivinar una palabra oculta es aprendizaje autosupervisado.

2. Explique con sus palabras por qué las medidas de un sastre son un buen ejemplo de encontrar «unos pocos números que captan lo que importa».


Pista: ¿Cuántos números hacen falta para describir un cuerpo lo bastante bien como para ajustar la ropa?

Respuesta: Un cuerpo humano es muy complicado, pero un pequeño conjunto de medidas, como pecho, cintura y largo, describe su forma lo bastante bien como para ajustar la ropa. Del mismo modo, el aprendizaje no supervisado puede buscar unos pocos números que capten las propiedades importantes de datos complicados.

Aprender haciendo

Observe a un niño pequeño aprendiendo a apilar bloques. Nadie le da una lista de respuestas correctas. Pone un bloque sobre otro, la torre se tambalea, se cae o se mantiene, y vuelve a intentarlo. Cada movimiento cambia lo que verá después, y el único veredicto es si la torre sigue en pie al final.

FUERA DE LÍNEA



ACTUAR




Aprender aislado, o actuar

Todo lo visto hasta ahora funcionaba de otra manera. Cogíamos de antemano un gran montón de datos, cortábamos el contacto con el mundo y dejábamos que la máquina buscadora de patrones hiciera su

trabajo. Como todo el aprendizaje ocurre después de que la máquina queda aislada del mundo, esto se llama aprendizaje fuera de línea. Tiene su encanto: podemos pensar en reconocer patrones sin preocuparnos por un mundo que se mueve y responde. Pero es limitante. Los lectores de los relatos de robots de Asimov imaginan máquinas que no solo predicen sino que actúan, y las acciones, a diferencia de las predicciones, cambian el mundo que la máquina verá después. Para entrenar a un agente así hay que tener en cuenta cómo sus propias acciones dan forma a lo que viene después, y el aprendizaje fuera de línea no puede.

En cuanto el mundo responde, aparecen preguntas nuevas. ¿Recuerda lo que hicimos antes? ¿Quiere ayudarnos, como alguien que habla con claridad a un reconocedor de voz? ¿Quiere ganarnos? Los spammers son el ejemplo del libro: no dejan de cambiar sus correos para colarse por su filtro de spam. ¿Cambia con el tiempo, por sí solo o por culpa de nuestras herramientas? Siempre que los datos en la prueba difieren de los datos del entrenamiento, tenemos lo que se llama desplazamiento de distribución. El ejemplo del libro le resultará familiar de la escuela: hacer los deberes que ponen los ayudantes de cátedra, y luego presentarse a un examen escrito por el profesor.



Los datos de prueba pueden desplazarse


El marco principal para máquinas que actúan es el aprendizaje por refuerzo. Se usa en robots, en sistemas conversacionales y en los rivales controlados por el ordenador en los videojuegos. Combinado con el aprendizaje profundo ha tenido éxitos famosos: un programa que aprendió a ganar a las personas en viejos juegos de recreativa de Atari solo con la pantalla, y AlphaGo, que derrotó al campeón del mundo del juego de tablero go. La imagen es un ciclo. En cada paso, el agente observa el mundo, elige una acción, y el mundo responde, a veces con una recompensa; luego el agente vuelve a observar, y así sucesivamente. La forma que tiene el agente de elegir acciones a partir de lo que ve se llama su política, y el objetivo del aprendizaje por refuerzo es encontrar una buena política.



El ciclo del aprendizaje por refuerzo

El marco es extremadamente general; incluso la clasificación corriente se puede disfrazar de aprendizaje por refuerzo, con una acción por cada clase y la recompensa fijada según lo acertada que sea la elección. Pero puede hacer mucho más que el aprendizaje supervisado, porque el mundo rara vez le dice al agente cuál es la mejor acción. Solo le da una recompensa, y a menudo ni siquiera qué acción se la ganó. En el ajedrez, el único veredicto real llega al final: ganar o perder. ¿Cuál de los cuarenta movimientos merece el mérito o la culpa? Este es el problema de la asignación de mérito, y las personas también se enfrentan a él: alguien ascendido en el trabajo tiene que averiguar cuáles de las decisiones del último año lo llevaron de verdad a ello.

Hay más dificultades. El agente puede ver solo parte de la situación, como un robot de limpieza atrapado en uno de varios armarios idénticos, que tiene que recordar cómo llegó allí para saber dónde está. Y debe elegir entre usar la mejor estrategia que conoce y probar algo nuevo que podría ser mejor, renunciando a algo de recompensa ahora a cambio de conocimiento. Ese es el equilibrio entre explotar y explorar. Su aplicación de música se enfrenta a él cada día: poner canciones que sabe que le gustan, o arriesgarse con una nueva que puede encantarle o que puede saltarse.



Explotar o explorar; casos más sencillos

Abordar todo esto a la vez quizá sea pedir demasiado, y no todo problema real lo tiene todo, así que los investigadores estudian casos especiales más sencillos. Cuando el agente puede ver la situación

completa, el problema se llama proceso de decisión de Markov. Cuando la situación no depende de lo que el agente hizo antes, es un problema de bandido contextual. Y cuando no hay situación alguna, solo una fila de acciones posibles con recompensas desconocidas, como una fila de máquinas tragaperras, es el clásico problema del bandido multibrazo.

Para recordar

El aprendizaje fuera de línea reúne primero los datos y aprende después, aislado del mundo; un agente que actúa cambia el mundo que verá después. Cuando los datos de prueba difieren de los de entrenamiento, como cuando el examen lo escribe alguien distinto de quien puso los deberes, eso es desplazamiento de distribución. El aprendizaje por refuerzo es un ciclo de observar, actuar y recibir recompensas, y su objetivo es una buena política para elegir acciones. Sus problemas más difíciles son saber qué acciones se ganaron una recompensa tardía, ver solo parte de la situación y equilibrar explorar con explotar. Los casos especiales más sencillos son el proceso de decisión de Markov, el bandido contextual y el bandido multibrazo.

Preguntas

1. ¿Por qué no basta el aprendizaje fuera de línea para entrenar a un agente que actúa?

- a. Porque el aprendizaje fuera de línea no puede usar grandes conjuntos de datos
 - b. Porque las acciones de un agente cambian lo que verá después, y un montón fijo de datos no puede recoger eso
 - c. Porque los agentes nunca reciben recompensas
 - d. Porque el aprendizaje fuera de línea solo funciona con texto
2. Los deberes los ponen los ayudantes de cátedra, pero el examen lo escribe el profesor. ¿Qué problema del aprendizaje automático ilustra esto?
- a. La asignación de mérito
 - b. La exploración
 - c. El desplazamiento de distribución: datos de prueba distintos de los de entrenamiento
 - d. Un bandido multibrazo
3. Un programa de ajedrez gana una partida. ¿Qué es difícil de aprender a partir de esta única recompensa?
- a. Averiguar cuáles de sus muchos movimientos merecen el mérito
 - b. Saber si ganó
 - c. Ver el tablero
 - d. Elegir un rival
4. Su aplicación de música a veces pone una canción que nunca ha oído en lugar de una favorita conocida. ¿Por qué podría hacerlo?
- a. Porque olvidó sus favoritas
 - b. Porque no tiene política

- c. Porque la canción era más popular
- d. Porque cambia algo de recompensa segura ahora por conocimiento que podría encontrar algo mejor

Respuestas

- 1. **b)** Para entrenar a un agente hay que tener en cuenta cómo sus propias acciones dan forma a lo que viene después, y el aprendizaje fuera de línea no puede.
- 2. **c)** Siempre que los datos en la prueba difieren de los del entrenamiento, tenemos desplazamiento de distribución; los deberes y el examen son el ejemplo del libro.
- 3. **a)** El único veredicto real llega al final, así que el programa tiene que averiguar qué movimientos merecen el mérito o la culpa: el problema de la asignación de mérito.
- 4. **d)** Debe elegir entre usar la mejor estrategia que conoce y probar algo nuevo: el equilibrio entre explotar y explorar.

Ejercicios

- 1. Describa el ciclo del aprendizaje por refuerzo para un robot aspirador: ¿cuáles son sus observaciones, sus acciones y sus recompensas, y cuál es su política?

Pista: Observar, actuar, recibir una recompensa, volver a observar.

Respuesta: El robot observa su entorno con sus sensores, elige acciones como avanzar o girar, y recibe recompensas, por ejemplo por recoger suciedad, o penalizaciones por chocar con cosas. Su política es su regla para elegir una acción a partir de lo que observa en ese momento, y el aprendizaje busca que esa política sea buena.

2. Un robot de limpieza está atrapado en uno de varios armarios idénticos. Explique por qué no puede saber dónde está por lo que ve ahora mismo, y qué podría usar en su lugar.

Pista: ¿Cómo es por dentro cada armario?

Respuesta: Todos los armarios parecen iguales por dentro, así que la vista actual no le dice en cuál está; solo ve parte de la situación. Tiene que usar lo que vio antes, al entrar, para averiguar su ubicación.

Raíces antiguas

Imagine una mañana de domingo de hace quinientos años, a la puerta de una iglesia alemana. Cuando sale la congregación, se pide a dieciséis hombres adultos que se pongan en fila, talón con punta. Se mide la longitud total de sus pies, se reparte a partes iguales entre los dieciséis y se declara que el resultado es un pie. Suena pintoresco, pero es un auténtico método de aprendizaje a partir de datos, y aparece en un libro de geometría del siglo dieciséis de Jacob Köbel.

UN PIE TÍPICO

EL MÁS CORTO

EL MÁS LARGO



total $\div$ 16

rest $\div$ 14


MEDIA RECORTADA

Dieciséis pies, una media recortada

El aprendizaje profundo es joven, pero el deseo de aprender de los datos y predecir lo que viene después es muy antiguo, y está en la raíz de buena parte de la ciencia y las matemáticas. Dos grandes matemáticos dieron su nombre a patrones del azar que aún se usan en todas partes: Jacob Bernoulli, hacia 1700, y Carl Friedrich Gauss, un siglo después. Gauss inventó además el método de mínimos cuadrados, que ajusta una recta a las mediciones manteniendo pequeños los fallos, y que todavía se usa para todo, desde los seguros hasta el diagnóstico médico. Esas herramientas afinaron la ciencia experimental; la ley de Ohm, que relaciona la corriente que atraviesa un cable con el voltaje entre sus extremos, es una regla lineal perfecta.

Los medidores de pies incluso mejoraron su método. Para protegerse de pies inusuales, se apartaba a los hombres con los pies más cortos y más largos, y solo se promediaba al resto. Es uno de los primeros ejemplos conocidos de media recortada, una media que ignora los extremos. Algunos sistemas de puntuación usan el mismo truco, ignorando las notas más altas y más bajas para que unas pocas opiniones disparatadas no alteren el resultado.

La estadística despegó de verdad cuando se empezaron a recoger datos a gran escala. Uno de sus pioneros, Ronald Fisher, construyó gran parte de su teoría y la aplicó a la genética, y varios de sus métodos siguen siendo estándar. Un pequeño conjunto de datos que publicó en 1936, medidas de flores de iris, todavía se usa a veces hoy para lucir métodos de aprendizaje. Fisher fue también partidario de la eugenesia, un recordatorio de que el mal uso de la ciencia de datos tiene una historia tan larga como sus buenos usos.




Raíces antiguas del aprendizaje con datos

Otras raíces vinieron de otros lugares. Claude Shannon fundó la teoría de la información, y Alan Turing la teoría de la computación. Turing preguntó: «¿Pueden pensar las máquinas?», y propuso lo que hoy se llama la prueba de Turing: una máquina cuenta como inteligente si una persona que intercambia mensajes escritos con ella no puede distinguirla fácilmente de un humano. Los chatbots de hoy han hecho que esa vieja pregunta se sienta muy real.

El estudio del cerebro aportó más. El psicólogo Donald Hebb sugirió que las conexiones entre células nerviosas se refuerzan cuando se usan con éxito, una regla que hoy lleva su nombre. Esa idea llevó a métodos de aprendizaje posteriores y a la receta básica del aprendizaje profundo actual: reforzar lo que funciona, debilitar lo que

no. También por eso estos sistemas se llaman redes neuronales, por las redes de células nerviosas, aunque el parecido con la biología se ha ido aflojando con el tiempo. En su corazón hay dos ideas: capas de procesamiento sencillo apiladas una tras otra, y una forma de ajustar a la vez todas las perillas de toda la red, llamada retropropagación.



Capas, y los años tranquilos

Tras un estallido de progreso inicial, la investigación en redes neuronales se estancó aproximadamente entre 1995 y 2005. Entrenarlas exigía muchísima potencia de cálculo, que escaseaba, y los conjuntos de datos eran pequeños: una colección de sesenta mil dígitos escritos a mano se consideraba enorme, y las flores de Fisher de 1936 seguían en uso. Con tan pocos datos y tan poco cálculo, otros métodos, con nombres como métodos de núcleo y árboles de decisión,

funcionaban mejor en la práctica. Además se entrenaban en horas en lugar de semanas y venían con sólidas garantías matemáticas.

Para recordar

Aprender de los datos tiene siglos, desde promediar los pies de dieciséis hombres hasta los mínimos cuadrados de Gauss.

Descartar los extremos antes de promediar, la media recortada, es uno de sus primeros refinamientos. La estadística, la teoría de la información, la teoría de la computación y el estudio del cerebro alimentaron el aprendizaje automático, y su mal uso es tan antiguo como su buen uso. Las redes neuronales se basan en capas apiladas y en ajustar todas sus perillas a la vez, pero se estancaron durante una década porque el cálculo escaseaba y los conjuntos de datos eran pequeños.

Preguntas

1. ¿Por qué los medidores de pies apartaban a los hombres de pies más cortos y más largos?
 - a. Para que la fila fuera más corta
 - b. Para que los pies inusuales no distorsionaran la media
 - c. Porque solo hacían falta catorce hombres
 - d. Para que el pie saliera más largo
2. ¿Qué nos recuerda la historia de Ronald Fisher?
 - a. Que la estadística empezó solo en el siglo veinte

- b. Que los conjuntos de datos pequeños son inútiles
 - c. Que la ciencia de datos puede usarse mal, y se ha usado mal desde que se usa bien
 - d. Que las flores son los mejores datos
3. ¿Por qué se estancó la investigación en redes neuronales aproximadamente entre 1995 y 2005?
- a. La potencia de cálculo escaseaba y los conjuntos de datos eran pequeños
 - b. Se había demostrado que las redes neuronales no funcionaban
 - c. La retropropagación todavía no se había inventado
 - d. Los investigadores perdieron el interés por el cerebro

Respuestas

1. **b)** Para protegerse de pies inusuales, se apartaba a los extremos y solo se promediaba al resto: una media recortada.
2. **c)** Fisher apoyó la eugenesia, un recordatorio de que el mal uso de la ciencia de datos tiene una historia tan larga como sus buenos usos.
3. **a)** Entrenar exigía muchísima potencia de cálculo, que escaseaba, y los conjuntos de datos eran pequeños.

Ejercicios

1. Cinco jueces puntúan un salto de trampolín: 6, 7, 7, 8 y 1. Explique por qué una media recortada, quitando la nota más alta y la más baja, da un resultado más justo que la media corriente, y diga qué notas conserva.

Pista: ¿Qué nota se sale de lo normal respecto a las demás?

Respuesta: La nota de 1 se sale mucho de lo normal y arrastraría la media corriente hacia abajo. Quitando la más alta y la más baja quedan 7, 7 y 7, así que la media recortada es 7, que refleja lo que pensaba la mayoría de los jueces.

2. Explique con sus palabras qué plantea la prueba de Turing.

Pista: Piense en una conversación que se mantiene solo por escrito.

Respuesta: Una persona intercambia mensajes escritos con algo que podría ser una máquina o un humano. Si la persona no puede distinguir fácilmente las respuestas de la máquina de las de un humano, Turing propuso que la máquina debía contar como inteligente.

La gran aceleración

Piense en el primer videojuego al que jugó, y luego en un juego de un teléfono de hoy. El salto en lo que una máquina pequeña puede dibujar, y en lo rápido que lo hace, es enorme. Y aquí está la sorpresa: los chips contruidos para que los juegos se vieran bien resultaron ser justo lo que las redes neuronales estaban esperando. Ese es uno de los hilos de cómo el aprendizaje profundo pasó de estar estancado a estar en todas partes.

CRECIMIENTO DESDE 1970

DATOS



CÁLCULO



MEMORIA



Qué creció, y cuánto


El cambio empezó con los datos. La web, empresas que atienden en línea a cientos de millones de personas, sensores baratos y buenos en todo, y un almacenamiento cada vez más barato produjeron juntos datos en cantidades que nadie había visto. Al mismo tiempo, el cálculo seguía abaratándose, y los chips gráficos diseñados para los videojuegos, llamados GPU, resultaron hacer la aritmética de las redes neuronales con una rapidez extraordinaria. De repente, métodos que habían parecido desesperadamente lentos estaban al alcance.

El libro lo muestra con una tabla, década a década. En 1970 un conjunto de datos típico eran las ciento y pico flores de iris, y un ordenador tenía una memoria diminuta y hacía unos cien mil cálculos por segundo. En 2020 un conjunto de datos podía ser una red social entera, billones de elementos, y una sola máquina llena de chips gráficos podía hacer aproximadamente mil billones de cálculos por segundo. La memoria también creció, pero mucho menos que los datos, mientras que la potencia de cálculo creció aún más deprisa que los datos. Así que ganan los métodos ahorradores de memoria pero dispuestos a gastar mucho cálculo en ajustar sus perillas, y eso favoreció a las redes neuronales profundas frente a los métodos más antiguos. Por eso también varias ideas antiguas, desde las redes sencillas apiladas hasta las redes que recuerdan secuencias, se redescubrieron tras años en el estante.

Pero el progreso no fue solo recetas viejas en máquinas más rápidas; el libro compara la última década con la explosión cámbrica, el estallido en que la vida animal se diversificó de repente. Las ideas nuevas llegaron a raudales. Una, llamada dropout, combate el sobreajuste añadiendo a propósito ruido aleatorio dentro de la red mientras aprende. Otra, la atención, permite a un modelo volver la

vista justo a la parte de la entrada que necesita, en lugar de meter una frase entera en la memoria antes de traducirla, y las frases largas se volvieron mucho más precisas.

ATENCIÓN



TRANSFORMER: SOLO ATENCIÓN


La atención vuelve la vista

Construido enteramente sobre la atención, el diseño Transformer mejora sin parar a medida que crecen los datos, el modelo y el cálculo, y hoy funciona para el lenguaje, las imágenes, el habla y mucho más. Incluso se ha entrenado un único Transformer para jugar a juegos de Atari, describir imágenes, conversar y controlar un robot. Los modelos de lenguaje, que predicen texto a partir de otro texto, ganaron cada vez más capacidades a medida que se hacían más grandes. El chatbot al que usted escribe es uno de ellos: el libro cita ChatGPT, un modelo de lenguaje ajustado para seguir lo que quiere la

gente, que puede ayudar a arreglar código informático o escribir un cuento con usted.

Los modelos generativos también dieron saltos. Las redes generativas antagónicas enfrentan a dos redes: una fabrica ejemplos falsos, la otra intenta distinguir lo falso de lo real, y la fabricante mejora hasta engañar a la verificadora, produciendo caras convincentes de personas que nunca existieron. Más recientemente, los modelos de difusión aprenden a deshacer la adición gradual de ruido, construyendo una imagen paso a paso a partir de interferencias. Los generadores de imágenes que pintan un cuadro a partir de su descripción, como los que cita el libro, DALL-E 2 e Imagen, funcionan así.

DIFUSIÓN



QUITAR RUIDO

Una imagen a partir del ruido

La ingeniería importó tanto como las ideas. Cuando un chip gráfico no basta, el entrenamiento se puede repartir entre cientos o miles de ellos trabajando juntos. Aquella tarea de reconocimiento de imágenes, antes estándar, que llevaba días de entrenamiento, se redujo así a menos de siete minutos. Ejecutar en paralelo muchas copias de un mundo simulado también impulsó al aprendizaje por refuerzo a ganar a los mejores humanos en el go, en juegos de Atari y en el juego de estrategia StarCraft, porque estos aprendices mejoran más cuando pueden probar cosas millones de veces.

Por último, el software lo puso todo al alcance de cualquiera. Herramientas gratuitas y compartidas para construir redes neuronales difundieron las ideas deprisa; la primera generación tenía nombres como Caffé, Torch y Theano, seguida de TensorFlow y otras. El tipo más nuevo, como PyTorch y JAX, permite escribir modelos con el mismo estilo natural que la programación científica corriente en Python, lo que facilitó mucho experimentar.

Para recordar

El aprendizaje profundo revivió cuando enormes conjuntos de datos se encontraron con un almacenamiento barato y un cálculo rápido, sobre todo con chips gráficos hechos al principio para juegos. El cálculo creció más deprisa que los datos, y los datos más que la memoria, lo que favoreció a las redes profundas y recuperó ideas antiguas. Ideas nuevas como el dropout, la atención, el Transformer, los modelos de lenguaje, las redes antagónicas y los modelos de difusión impulsaron un estallido de progreso. El entrenamiento se repartió entre muchos chips y muchas simulaciones, y herramientas gratuitas como PyTorch pusieron los métodos al alcance de todos.

Preguntas

1. ¿Por qué importaron tanto al aprendizaje profundo los chips gráficos hechos para los juegos?
 - a. Hacen la aritmética de las redes neuronales con una rapidez extraordinaria
 - b. Guardan más datos que la memoria corriente
 - c. Eran más baratos que cualquier otro ordenador
 - d. Venían con software gratuito
2. La potencia de cálculo creció más deprisa que los datos, y los datos más que la memoria. ¿Qué tipo de método favoreció esto?
 - a. Métodos que guardan cada ejemplo en memoria

- b. Métodos ahorradores de memoria pero dispuestos a gastar mucho cálculo en ajustar sus perillas, como las redes profundas
 - c. Métodos que no necesitan ningún entrenamiento
 - d. Métodos que solo usan conjuntos de datos pequeños
3. ¿Qué problema resuelve la atención al traducir una frase larga?
- a. Hace el modelo más pequeño
 - b. Elimina la necesidad de datos de entrenamiento
 - c. Permite al modelo volver la vista a la parte que necesita en lugar de meter primero toda la frase en la memoria
 - d. Añade ruido para evitar el sobreajuste
4. ¿Cómo trabajan juntas las dos redes de una red generativa antagónica?
- a. Las dos hacen imágenes y se queda la mejor
 - b. Una traduce y la otra revisa la gramática
 - c. Se reparten los datos de entrenamiento
 - d. Una fabrica falsificaciones, la otra intenta detectarlas, y la fabricante mejora hasta engañar a la verificadora

Respuestas

- 1. a)** Los chips gráficos diseñados para los juegos resultaron hacer la aritmética de las redes neuronales con una rapidez extraordinaria.
- 2. b)** Ganan los métodos ahorradores de memoria pero dispuestos a gastar mucho cálculo en ajustar sus perillas, lo que favoreció a las redes neuronales profundas.
- 3. c)** La atención permite a un modelo volver la vista justo a la parte de la entrada que necesita, en lugar de meter una frase entera en la memoria

antes de traducir.

4. d) Una red fabrica ejemplos falsos, la otra intenta distinguir lo falso de lo real, y la fabricante mejora hasta engañar a la verificadora.

Ejercicios

1. Explique con sus palabras por qué el libro compara la última década del aprendizaje profundo con la explosión cámbrica, y dé dos de las ideas nuevas que hay detrás.

Pista: ¿Fue el progreso solo máquinas más rápidas ejecutando métodos antiguos?

Respuesta: La explosión cámbrica fue un estallido repentino de nuevas formas de vida; la última década ha visto un estallido repentino de métodos nuevos, no solo recetas viejas en máquinas más rápidas. Ejemplos son el dropout, que combate el sobreajuste con ruido, y la atención y el Transformer basado en ella, que permiten a los modelos manejar entradas largas y seguir mejorando a medida que crecen.


2. ¿Por qué ejecutar en paralelo muchos mundos simulados ayudó al aprendizaje por refuerzo a ganar a las personas en el go y en juegos de Atari?

Pista: ¿De qué necesita mucho un aprendiz por refuerzo?

Respuesta: Los aprendices por refuerzo mejoran probando acciones y viendo las recompensas, y necesitan cantidades enormes de intentos. Las simulaciones en paralelo aportan millones de esos intentos mucho más deprisa de lo que podría el mundo real.

En todas partes, casi sin verse

Pague algo en internet con una tarjeta, y en el parpadeo antes de que se apruebe el pago, un programa ya ha juzgado si parece un fraude. Envíe una carta, y probablemente una máquina habrá leído la dirección escrita a mano. Ninguna de las dos cosas parece inteligencia artificial, pero ambas son aprendizaje automático en acción, y lo son desde hace años. La mayor parte, dice el libro, simplemente está oculta a la vista.



Aprendizaje automático, fuera de la vista


Parte de la razón de que se extendiera tan deprisa es que las herramientas se volvieron fáciles. Unas personas construyen mejor software, otras construyen mejores modelos, y cada lado se beneficia del trabajo del otro. En 2014, entrenar un clasificador bastante sencillo era un problema de deberes que merecía la pena poner a los nuevos doctorandos de aprendizaje automático de una universidad puntera. Hoy el mismo trabajo lleva menos de diez líneas de código, al alcance de cualquier programador.

Algunos éxitos son antiguos. Las máquinas clasifican el correo leyendo direcciones escritas a mano desde los años noventa, y de ahí salió la famosa colección de dígitos escritos a mano. Leen cheques, puntúan la solvencia de las personas y revisan los pagos en busca de fraude detrás de la mayoría de los grandes servicios de pago. Los programas de ajedrez son fuertes desde hace décadas, y el aprendizaje automático mueve en silencio la búsqueda, las recomendaciones y el orden personal de lo que usted ve en internet.

Lo que ha puesto recientemente a la inteligencia artificial en el foco es que empezó a resolver problemas que se creían imposibles, problemas con los que los consumidores corrientes se encuentran directamente, y el aprendizaje profundo está detrás de muchos de ellos. Los asistentes de voz como Siri, Alexa y el asistente de Google responden razonablemente bien a peticiones habladas, desde encender una luz hasta pedir cita en la peluquería, y eso es probablemente la señal más visible de la inteligencia artificial en la vida diaria. Su ingrediente clave, el reconocimiento de voz, se ha vuelto tan preciso como las personas para algunos usos. El reconocimiento de objetos en fotos ha mejorado de forma espectacular: en una prueba estándar, la proporción de fotos para las que la respuesta correcta ni siquiera estaba entre las cinco mejores estimaciones de un modelo cayó de

más de una cuarta parte en 2010 a apenas algo más de dos de cada cien en 2017. Saltos parecidos llegaron en la identificación de pájaros por su canto y en el diagnóstico del cáncer de piel.


JUEGOS GANADOS POR MÁQUINAS



Juegos que las máquinas aprendieron a ganar

Los juegos solían ser una vara de medir la capacidad humana, y las máquinas la han ido escalando paso a paso. Un programa aprendió backgammon por aprendizaje por refuerzo; Deep Blue venció al campeón del mundo de ajedrez Garri Kaspárov con hardware especial y una búsqueda rápida entre los movimientos posibles. El go, con un número de posiciones muchísimo mayor, cayó ante AlphaGo, que combinó el aprendizaje profundo con una forma ingeniosa de muestrear futuros posibles. El póquer era difícil porque no se ven las cartas de los otros jugadores, y aun así un programa llamado Libratus

ganó a profesionales humanos. Los coches autónomos también han progresado mucho, con algunos coches que ya conducen solos parte del tiempo, aunque la conducción totalmente autónoma sigue fuera de alcance: conducir exige ver, razonar y seguir normas, y el aprendizaje profundo se ocupa sobre todo de ver. La robótica, la logística, la biología, la física de partículas y la astronomía también deben avances recientes al aprendizaje automático.



Miedos de titular, preocupaciones reales

Los artículos de divulgación se preocupan a menudo por un apocalipsis robótico inminente, máquinas que se vuelven conscientes y deciden ir contra nosotros. Los autores están tranquilos en este punto. Los sistemas actuales se construyen y entrenan para objetivos concretos, y detrás de cualquier apariencia de inteligencia general hay

una mezcla de reglas, reglas prácticas y modelos estadísticos. Sencillamente, dicen, todavía no hay herramientas para una inteligencia general capaz de entenderse a sí misma y rediseñarse para resolver cualquier tarea.

Las preocupaciones reales están más cerca. La inteligencia artificial ya influye en la vida de las personas: la solvencia se juzga de forma automática, los pilotos automáticos se encargan de buena parte del trabajo de guiar vehículos, y las decisiones sobre conceder la libertad bajo fianza se apoyan en datos estadísticos. Muchos trabajos rutinarios que hacen las personas pueden automatizarse y se automatizarán; los robots agrícolas pueden abaratar los alimentos ecológicos pero también sustituir a los temporeros, y como el trabajo manual sencillo emplea a muchísima gente en muchos países, los efectos en la sociedad podrían ser profundos. Y los modelos usados sin cuidado pueden tener sesgos de raza, género o edad, lo que es especialmente preocupante cuando ayudan a tomar decisiones importantes. Como el modelo de contratación de una parte anterior, un sistema que decide quién recibe un préstamo puede copiar en silencio la injusticia del pasado. Los autores consideran estas preocupaciones mucho más urgentes que una superinteligencia malvada, e insisten en que estos sistemas se usen con cuidado.

Para recordar

El aprendizaje automático lleva décadas trabajando en silencio, clasificando el correo, cazando fraudes y ordenando lo que vemos en internet. Las herramientas de software fáciles permiten ahora a cualquier programador hacer lo que antes era un ejercicio de doctorado. El aprendizaje profundo trajo saltos visibles: asistentes de voz, reconocimiento de voz y de imágenes, diagnóstico del cáncer de piel y victorias en el go y el póquer. Los autores no ven señales de una rebelión de máquinas conscientes; las preocupaciones reales son los empleos perdidos y las decisiones sesgadas, que exigen un uso cuidadoso.

Preguntas

1. ¿Por qué dice el libro que el aprendizaje automático suele estar oculto a la vista?
 - a. Porque las empresas lo mantienen en secreto por ley
 - b. Porque trabaja en silencio en sistemas cotidianos como la detección de fraudes y la clasificación del correo, que no parecen IA
 - c. Porque solo funciona de noche
 - d. Porque todavía no tiene usos prácticos
2. ¿Por qué el póquer era, en un aspecto concreto, un juego más difícil que el ajedrez para las máquinas?
 - a. El póquer tiene más reglas

- b. Las partidas de póquer duran más
 - c. Los jugadores no ven las cartas de los demás, así que la situación solo es parcialmente visible
 - d. El póquer necesita hardware especial
3. ¿Qué preocupación consideran los autores más urgente?
- a. Los empleos perdidos y las decisiones automáticas sesgadas
 - b. Una máquina consciente que decida ir contra la humanidad
 - c. Que los ordenadores se queden sin memoria
 - d. Que los juegos se vuelvan demasiado fáciles

Respuestas

1. **b)** La detección de fraudes y la lectura de direcciones no parecen inteligencia artificial, pero ambas son aprendizaje automático en acción: la mayor parte está oculta a la vista.
2. **c)** El póquer era difícil porque no se ven las cartas de los otros jugadores.
3. **a)** Los autores consideran la automatización del trabajo y el sesgo mucho más urgentes que una superinteligencia malvada.

Ejercicios

1. Enumere tres formas en que el aprendizaje automático influye en su día sin que usted lo note, con ejemplos de la lección.

Pista: Piense en los pagos, el correo y lo que ve en internet.

Respuesta: Un pago con tarjeta se revisa automáticamente en busca de fraude; una dirección escrita a mano en una carta puede leerla una máquina; y los resultados de búsqueda, las recomendaciones y el orden de lo que ve en internet los fija el aprendizaje automático.


2. Explique con sus palabras por qué a los autores no les preocupa una rebelión de una IA consciente, pero sí el sesgo.

Pista: ¿De qué están hechos en realidad los sistemas actuales, y qué pasa cuando se usan sin cuidado?

Respuesta: Los sistemas actuales se construyen y entrenan para objetivos concretos a partir de reglas, reglas prácticas y modelos estadísticos, y no hay herramientas para una máquina capaz de entenderse y rediseñarse. Pero los modelos usados sin cuidado pueden tener sesgos de raza, género o edad, y cuando ayudan a decidir sobre préstamos, fianzas o empleos, esa injusticia perjudica ya a personas reales.

Qué lo hace profundo


Imagine enseñar a un robot a reconocer gatos a la antigua. Primero usted, una persona lista, escribe reglas para encontrar bordes, esquinas y manchas de pelo en una foto. Luego entrega esos hallazgos a una máquina de aprendizaje sencilla que decide «gato» o «no gato». Si su buscador de bordes pasa por alto algo importante, ningún aprendizaje al final podrá recuperarlo. El aprendizaje profundo desecha esa división, y ese es el corazón de lo que lo hace distinto.



Parte delantera artesanal, o de extremo a extremo

El aprendizaje profundo es la parte del aprendizaje automático basada en redes neuronales con muchas capas. Es profundo justo en ese sentido: sus modelos aprenden muchas capas de pasos, cada una de las cuales transforma un poco los datos y los pasa adelante. En cierto modo, todo aprendizaje automático tiene varias etapas, y la primera suele ser algún tipo de preparación de las características. Lo que distingue al aprendizaje profundo es que cada una de sus muchas capas se aprende, todas a la vez, a partir de los datos.

Por eso brilla justo donde tropezaban los métodos más antiguos: el sonido en bruto, los píxeles en bruto de las fotos y frases de cualquier longitud que hay que pasar a otro idioma. El libro destaca una cosa que comparten la mayoría de los métodos de aprendizaje profundo, llamada entrenamiento de extremo a extremo. En lugar de construir un sistema con piezas que se ajustan cada una por separado, se construye el conjunto y se ajusta todo a la vez. En visión por computadora, durante más de una década los mejores resultados vinieron de buscadores de características diseñados a mano, famosos detectores de bordes y similares, que convertían las imágenes en listas de números para que las usara un modelo sencillo. La habilidad crucial era inventar formas ingeniosas de preparar los datos a mano. Pero el ingenio humano tiene un límite frente a un método que prueba millones de opciones automáticamente, y cuando el aprendizaje profundo tomó el relevo, esos buscadores de características hechos a mano se sustituyeron por filtros ajustados por la propia máquina, con mejor precisión.




Un tipo de red para todos los campos

Así que el aprendizaje profundo sustituye no solo el modelo sencillo del final, sino también la larga preparación artesanal previa. Y como tanta de esa preparación era propia de un solo campo, los muros entre la visión, el habla, el lenguaje, los datos médicos y otras áreas se han derrumbado en gran parte; las mismas herramientas sirven ahora para todos. Por eso el mismo tipo de modelo puede estar detrás tanto del asistente de voz que le oye como del chatbot que le responde por escrito.


También hay cambios más profundos. Cuando los datos escasean, los modelos tienen que apoyarse en suposiciones simplificadoras sobre el mundo; cuando abundan, pueden seguir los datos con más libertad. El libro lo compara con la física del siglo pasado: con la llegada de los

ordenadores, los físicos pudieron simular directamente el comportamiento de los electrones en lugar de calcular a mano aproximaciones simplificadas, ganando precisión, aunque a menudo perdiendo algo de comprensión del porqué. El aprendizaje profundo también acepta soluciones buenas en lugar de demostrablemente óptimas, y está dispuesto a probar ideas antes de demostrarlas, y ese espíritu práctico, junto con una avalancha de talento nuevo, ha impulsado un progreso rápido.

POCOS: SUPONER



MUCHOS: SEGUIR



Suponer menos cuando hay muchos datos

Por último, la comunidad se enorgullece de compartir: herramientas, modelos y redes entrenadas se publican libremente desde universidades y empresas. Con ese espíritu, el propio libro es libre de leer, compartir y usar, y los autores esperan que rebaje la barrera para

cualquiera que quiera aprender. Y con esto termina nuestro recorrido por la introducción: desde las reglas que nunca aprenden, pasando por los muchos tipos de problemas de aprendizaje, hasta los datos, los chips y las herramientas compartidas que hicieron posible el aprendizaje profundo.

Para recordar

El aprendizaje automático trata de sistemas que mejoran en una tarea con la experiencia, normalmente datos. El aprendizaje profundo usa redes neuronales con muchas capas, todas aprendidas a la vez a partir de los datos, de extremo a extremo. Sustituyó tanto los modelos sencillos como la preparación artesanal de los datos, y reunió la visión, el habla y el lenguaje bajo un mismo conjunto de herramientas. Su progreso vino de la abundancia de datos, los chips gráficos rápidos y los marcos gratuitos y eficientes, junto con una disposición práctica a probar antes de demostrar.

Preguntas

1. ¿Qué distingue al aprendizaje profundo de otro aprendizaje automático que también tiene varias etapas?
 - a. Usa más datos que cualquier otro método
 - b. Cada una de sus muchas capas se aprende, todas a la vez, a partir de los datos
 - c. No necesita chips informáticos

- d. Solo funciona con imágenes
2. ¿Por qué en visión por computadora los filtros ajustados por la máquina superaron a los buscadores de características diseñados a mano?
- a. Porque el ingenio humano no puede competir con un método que prueba millones de opciones automáticamente
 - b. Porque los buscadores hechos a mano eran ilegales
 - c. Porque los filtros no necesitaban datos
 - d. Porque los bordes no importan en las fotos
3. ¿Por qué se han derrumbado en gran parte los muros entre la visión, el habla y el lenguaje?
- a. Porque los tres usan los mismos datos
 - b. Porque los ordenadores se volvieron más rápidos
 - c. Porque el aprendizaje profundo sustituyó la preparación artesanal de los datos propia de cada campo, así que las mismas herramientas sirven para todos
 - d. Porque los investigadores fusionaron sus universidades

Respuestas

- 1. b)** Todo aprendizaje automático tiene etapas, pero en el aprendizaje profundo cada una de sus muchas capas se aprende a la vez a partir de los datos.
- 2. a)** El ingenio humano tiene un límite frente a un método que prueba millones de opciones automáticamente.
- 3. c)** Como tanta preparación era propia de un solo campo, sustituirla permitió que las mismas herramientas sirvieran para la visión, el habla, el lenguaje y más.

Ejercicios

1. Explique con sus palabras la diferencia entre la antigua forma en dos pasos de reconocer gatos y el entrenamiento de extremo a extremo.

Pista: ¿Quién diseña el primer paso en cada caso?

Respuesta: A la antigua, una persona diseña a mano reglas para encontrar bordes y esquinas, y una máquina de aprendizaje sencilla solo aprende el último paso; si el paso hecho a mano pasa algo por alto, el aprendizaje no puede recuperarlo. En el entrenamiento de extremo a extremo, todo el sistema, incluidos los primeros pasos, se construye y ajusta a la vez a partir de los datos, así que la máquina encuentra sus propias características útiles.

2. Nombre las tres cosas a las que el curso atribuye el progreso reciente del aprendizaje profundo, y diga en una frase qué aportó cada una.

Pista: Una trata de ejemplos, otra de hardware, otra de software.

Respuesta: Los datos abundantes de internet y de sensores baratos dieron a los modelos suficientes ejemplos de los que aprender; los chips gráficos rápidos dieron la potencia de cálculo para entrenar redes grandes; y los marcos gratuitos y eficientes hicieron fácil para mucha gente construir y entrenar sistemas completos.