


# GUÍA PRÁCTICA

# DE LA IA

DOMINA EL ARTE  
POCO COMÚN DE  
LA IMPLEMENTACIÓN  
DEL *MACHINE LEARNING*



**ERIC SIEGEL**

AUTOR SUPERVENTAS DE «ANÁLITICA PREDICTIVA»

# Contenidos

Agradecimientos	6
Sobre el autor	9
<b>Prólogo de la serie</b>	<b>17</b>
<b>Prólogo</b>	<b>19</b>
<b>Prefacio: Breve historia de por qué los proyectos de <i>machine learning</i> se estancan</b>	<b>23</b>
Fallo en el lanzamiento	25
Abrirse camino entre el caos del ML	25
<b>Preguntas frecuentes: De qué trata este libro y para quién es</b>	<b>29</b>
<b>Introducción</b>	<b>37</b>
Cuidado, pioneros: Causad disrupción por vuestra cuenta y riesgo	38
Cuando la grandeza es demasiado grande para verla de cerca	41
Sexy pero vaga: inteligencia artificial	42
La logística está recuperando lo sexy	43
Planificar para mañana con información completa	44
Predecir las entregas de mañana	47
Las predicciones dirigen el mundo	50
Ir con todo	50
Demuestra, no cuentes	51
Ponte en marcha, Jack	52
ML bien hecho y mal hecho	54
Historia de dos tecnologías	54
¿Cómo hacerlo bien?	56

<b>Capítulo 0. BizML: Seis pasos para la implementación del <i>machine learning</i></b>	<b>57</b>
El potencial de la predicción	58
Los dos pasos técnicos principales del <i>machine learning</i>	60
El fracaso del <i>machine learning</i> suele ser un fracaso humano	62
Muchos modelos nunca se implementan:	
un problema generalizado de la industria	63
¿No pueden implementar... o simplemente no lo van a hacer?	66
La solución: BizML	67
Los seis pasos de bizML	68
Por qué la industria converge en estos seis pasos	69
BizML: un requisito fundamental que no tenía nombre	72
El origen y el coste del bombo publicitario	73
Replantear el ML	75
Los vendedores de ML ayudan, pero las empresas lideran la industria	77
El conocimiento contextual semitécnico que necesitas	78
¿Quién está al mando?	80
Aprender por las malas	82
Aprender por las buenas	84
<b>Capítulo 1. Valor: Establecer el objetivo de la implementación</b>	<b>85</b>
La práctica bizML	85
La proposición de valor: definirá una aplicación de ML	87
Planificación hacia atrás: crear un camino a la implementación del ML	88
Por qué la implementación requiere un salto mental	91
Decisiones, decisiones: elegir tu primer proyecto de ML	92
La elección depende, en parte, del sector	94
Detectar una situación en vez de predecir un resultado	95
Obtener la aprobación	97
Siguiendo pasos	98
<b>Capítulo 2. Objetivo: Establecer el objetivo de la predicción</b>	<b>99</b>
La práctica bizML	99
El plan de implementación conforma el objetivo de la predicción	101
La diferencia entre el éxito y el fracaso del ML	103
Prevenir malos resultados de manera proactiva	106

Predecir demasiado tarde	107
Predecir los pasos intermedios	109
Decidir "cuál" en vez de "sí"	110
Colaborar en el objetivo de la predicción	111
Detección frente a predicción: unas veces es más fácil y otras es más difícil	114
Rendimiento del modelo: ¿cómo de bien podemos lograr el objetivo de predicción?	115
<b>Capítulo 3. Rendimiento: Establecer las métricas de evaluación</b>	<b>117</b>
La práctica bizML	117
El "gaydar" de Stanford no funciona por la cara	119
Exactitud: una palabra que a menudo se usa de forma inexacta	121
La cháchara sobre predicciones imperfectas	122
Obligarse a actuar	123
El valor de la predicción imperfecta	124
<i>Lift</i> : una medida significativa del rendimiento	125
Incluso un <i>lift</i> pequeño ayuda mucho	127
Un ejemplo ilustrativo: ¿cómo de grande es tu televisión?	129
Implementar ML es triar y priorizar	130
Trazar la curva de beneficios	132
Implementar de forma agresiva o defensiva:	
tu límite marca la diferencia	135
Métricas empresariales frente a métricas del modelo	136
Métricas empresariales: indicadores clave del rendimiento	138
Distinguir falsos positivos de falsos negativos	139
Calcular el ahorro basado en los costes de clasificación errónea	141
Costes subjetivos: diagnóstico erróneo frente a diagnóstico no realizado	144
Los retos de traducir las métricas de rendimiento predictivo a KPIs	146
Lanzar es dar el salto	147
<b>Capítulo 4. Combustible: Preparar los datos</b>	<b>149</b>
La práctica bizML	149
La savia de la optimización	152
Qué aspecto tienen los datos de entrenamiento: filas y columnas	153
Los datos dictan lo que hace el modelo	155
Grandes datos de entrenamiento para anuncios dirigidos	156

¿Cómo de grande es lo bastante grande?	158
¿Están infrarrepresentados los casos positivos?	161
Es cuestión de tiempo: las variables de entrada	163
La mayoría de la gente no está preparada para la preparación de datos	165
Hay ruido que mata el ML, pero hay otro que es excelente	167
FICO cultiva datos sin fronteras	170
Diseñar entradas mejores para Falcon	172
Todavía no hemos terminado: etiquetar los datos	174
El Falcon de FICO es un luchador fantástico contra el fraude	176
<b>Capítulo 5. Algoritmo: Entrenar el modelo</b>	<b>177</b>
La práctica bizML	177
Curiosear un modelo	178
¿Tiene sentido el modelo?	180
Inspeccionar modelos para buscar fallos	182
Aprender de los datos: el reto tecnológico definitivo	183
Árboles de decisión: modelos hechos de reglas	185
Más métodos de modelado; regresión lineal y logística	186
Todo lo que necesitas saber sobre los métodos de modelado	187
Por qué hay métodos de modelado que compiten	189
Un resumen de los métodos de modelado	190
Elegir un método de modelado	194
¡Son los datos, estúpido!	196
¿Cómo de profundo es tu aprendizaje?	197
Para muchos problemas empresariales, el <i>deep learning</i> es excesivo	199
Generar numerosos modelos para los anuncios dirigidos	202
<b>Capítulo 6. Lanzamiento: Implementar el modelo</b>	<b>205</b>
La práctica bizML	205
Se produce el cambio: cuando un proceso heredado se digitaliza	206
Para gestionar el cambio, cambia la gestión	208
La importancia de la formación	209
Cuando no necesitamos humanos en el proceso	211
Traducir predicciones en acciones	214
Cómo exportar un modelo	216
La desconexión de los datos: llevar las entradas a un modelo implementado	217

El firme enfoque de una firma respecto a la desconexión de datos	219
La necesidad de la velocidad: guiar decisiones en tiempo real	221
Entrega veloz: los modelos trabajan rápido	223
Las mejores oportunidades son las más difíciles de aprovechar	225
Mitigar los riesgos de la implementación con un grupo de control	226
Atribuir el mérito a quien lo merece: un grupo de control en UPS	228
El final es un nuevo principio	230
<b>Chuleta de BizML: El manual de estrategia para la implementación del <i>machine learning</i></b>	<b>231</b>
<b>Conclusión: Discurso del ascensor del <i>machine learning</i>, personal, plazos, mantenimiento y ética</b>	<b>233</b>
El discurso del ascensor	234
Ejercita la paciencia y solicita opiniones	236
Reúne a tu equipo: asignar personal al proyecto de ML	237
Conseguir el equipo del proyecto de ML	239
Proyectar el proyecto: cuánto tiempo llevará	240
Retroceder: pasar en bucle por los pasos repetidamente	241
La vida después del lanzamiento: mantener el modelo	243
La moral importa	245
<b>Índice alfabético</b>	<b>249</b>

# Preguntas frecuentes

## De qué trata este libro y para quién es

*Puedes saltarte estas preguntas frecuentes opcionales, pero te recomiendo que eches un vistazo a la lista para ver si hay alguna pertinente para ti o que te interese. Los lectores de este libro provienen de entornos diferentes y tienen distintas ideas preconcebidas acerca del problema que el libro aspira a resolver: conseguir implementar el machine learning. Estas preguntas frecuentes te orientarán y aclararán por qué deberías leer este libro y ajustar tus expectativas.*

### **¿De qué trata este libro?**

Este libro presenta una guía estratégica y táctica para lanzar el *machine learning*, una disciplina en seis pasos para realizar un proyecto de ML de forma que se implemente con éxito. Llamo a esta práctica bizML.

Por el camino, el libro también ofrece la información contextual semitécnica que necesitan todos los participantes en el proyecto de una forma clara y accesible que cualquiera puede entender. Debido a esa cobertura, el libro también sirve como introducción no técnica a este campo para los recién llegados.

### **¿Por qué necesita el *machine learning* una práctica empresarial especializada?**

Aquí está el problema. El ML es la tecnología de aplicación general más potente del mundo, pero solo puede mejorar las operaciones a gran escala cambiándolas. Por esa razón, un proyecto de ML no debería verse como "un proyecto de tecnología", sino que, para tener impacto, debe

replantearse como un proyecto empresarial pensado para mejorar el rendimiento operativo, donde el ML es solo un componente, uno que es necesario, pero no es suficiente.

Al centrar la atención de forma abrumadora en la parte técnica y su ejecución, la industria no ha logrado establecer una práctica empresarial adoptada a nivel general para llevar a cabo la otra mitad de un proyecto de ML con éxito. Como resultado, las nuevas iniciativas de ML fracasan de modo habitual en su implementación.

### Si la mayoría de los proyectos de *machine learning* fracasan en su implementación, ¿acaso es el campo del *machine learning* un fiasco?

En absoluto. Muchos proyectos de ML tienen éxito, aunque sea solo una minoría; incluso una fracción de los múltiples proyectos de este campo tan popular sigue siendo mucho. Además, en determinadas circunstancias, un proyecto de ML está destinado a triunfar, como en los proyectos de alta prioridad de una empresa de los gigantes tecnológicos o proyectos pensados para actualizar un modelo existente que ya se ha implementado. El mundo industrial sigue siendo optimista respecto al ML porque su gran potencial permanece intacto.

### Puesto que este libro describe una práctica para ejecutar proyectos de ML, ¿está pensado solo para jefes?

No. Cuando un proyecto de ML sigue bizML, la práctica organizativa presentada en este libro, todas las personas implicadas en el proyecto participan en esa práctica de algún modo. El equipo solo puede colaborar de la manera más efectiva si todos están familiarizados con esta práctica de principio a fin y con el conocimiento semitécnico que la rige.

### ¿Para quién es este libro?

Este libro es para cualquiera que desee obtener valor con el ML mediante la participación en su implementación empresarial, al margen de si desempeña su papel en el lado empresarial o en el técnico.

Ante todo, escribí este libro para los profesionales de los negocios, las personas que ejecutan el proyecto de ML, tienen interés en él, toman decisiones sobre él o gestionan las operaciones que cambiarán (y mejorarán) con él. Esto incluye a ejecutivos, directores, jefes, consultores y líderes de todo tipo. Pero este libro también es para los expertos en tecnología. Si eres científico de datos, ingeniero de ML o cualquier clase

de profesional técnico relacionado con el ML, este libro te invita a alejarte un poco de la ejecución práctica y obtener una nueva perspectiva del paradigma holístico al cual vas a contribuir.

### ¿Es este libro una guía práctica?

Este libro es una guía práctica empresarial, pero no una técnica. A diferencia de la mayoría de los libros sobre ML, aborda la práctica empresarial en vez de la práctica técnica. Presenta una práctica empresarial en seis pasos, bizML, para ejecutar un proyecto de ML.

Este libro no ahonda lo bastante para servir a los profesionales de los datos como guía práctica. Para eso está la gran mayoría del resto de los libros sobre ML. Los métodos de ML que cubren son solo un ingrediente. Constituyen un componente técnico clave del proyecto, pero ese componente solo supone uno de los seis pasos del proyecto explicados en este libro. Por consiguiente, solo un capítulo de este libro, el capítulo 5, incide en los principales métodos de ML; ofrece un "curso acelerado" accesible.

Este libro también se diferencia de la mayoría de los libros de negocios sobre ML, que presentan una visión general estratégica de la industria. Esos libros suelen abordar el tema desde un nivel superior, sin proporcionar una orientación práctica y sin detallar de manera concreta cómo se integra el ML para ofrecer mejoras operativas.

### ¿Qué materiales introductorios debería leer antes de este libro?

No se necesita ninguno. Este libro es accesible para todos los lectores y sirve como introducción completa a nivel conceptual al campo del ML para recién llegados. Mientras describe los pasos de principio a fin para ejecutar un proyecto de ML, abarca los conceptos básicos por el camino. Desde luego, obtener cierto conocimiento conceptual sobre métodos de ML antes de leer este libro no te perjudicaría, pero, teniendo en cuenta el tema de este libro (la perspectiva empresarial de un proyecto de ML debería preceder a la perspectiva técnica), puedes leer este libro primero y determinar después cuánto quieres ahondar en la tecnología central.

### Ya entiendo que los proyectos de ML deben empezar con un objetivo empresarial; ¿necesito este libro?

Establecer el objetivo de la implementación es solo el primer paso, literalmente. Es el primer paso de la práctica bizML de seis pasos que se recoge en este libro. El resto sirve para cumplir ese objetivo. Perseguirlo

# Introducción

*Nunca vendas IA. En su lugar, presenta mejoras operativas, y menciona el machine learning solo por encima como parte de la solución.*

*La mayoría de los líderes del ML se centran más en la tecnología que en su implementación, así que la mayoría de las nuevas iniciativas de ML fallan.*

*No te equivoques; los cambios operativos son difíciles de vender, sobre todo en comparación con una tecnología de moda, que se vende con tan poco esfuerzo que la llamamos "sexy". Es menos glamuroso proponer una renovación de los procesos. La gente responde como si estuvieses sugiriendo una endodoncia. Pero así es la vida; las grandes ganancias solo llegan si se imponen grandes cambios. Vamos a empezar por la historia de un ambicioso pionero decidido a llegar alto con el ML en una empresa de la lista Fortune 500 de un siglo de antigüedad. ¿Su campo? La logística. Pero no pierdas detalle y verás por qué los proyectos de ML aburridos en realidad son, irónicamente, los más sexys. También verás cómo la paradoja de la innovación puede superarse y por qué es algo bueno que, al final, la mayoría de los proyectos de ML prácticos estén destinados a desprenderse de la marca "IA".*

**I**ntentaron advertirle. Mientras Jack Levis perseguía un deseo arraigado de innovar, sus colegas pensaban que estaba cometiendo un suicidio profesional. "Me encanta tu pasión", le dijo un compañero, "pero debes saberlo: todo el mundo cree que estás loco".

Jack no estaba intentando cambiar el mundo. Solo estaba ocupándose de la pequeña cuestión de optimizar cómo entregaba los paquetes el United Parcel Service (UPS); 16 millones de paquetes al día. No estaba satisfecho con el *statu quo*. Había casi 300 millones de kilómetros de conducción anual que podían reducirse.

Jack había abordado esa idea loca de forma voluntaria. Nadie de arriba le había encargado el proyecto, ni era parte de sus responsabilidades en UPS, sino que él mismo había creado de manera proactiva un pequeño equipo para desarrollar un prototipo de prueba de concepto. Como grupo, se dedicaban a ello a tiempo parcial, no de forma prioritaria.

Un día de otoño, después de años de trabajo, Jack consiguió por fin una oportunidad excelente de presentar la idea a un ejecutivo clave de UPS llamado Chuck. Así que se sentó con Chuck y le presentó una historia ingeniosa: un sistema que prescribiría rutas de entrega más eficientes para los conductores de los camiones; y, al hacerlo, lograría el valor completo de otra de las recientes contribuciones de Jack, un sistema que planificaba las entregas del día siguiente prediciéndolas.

Vale, implementar ese sistema significaría introducir un cambio enorme en las operaciones existentes. Pero también prometía una recompensa enorme. Jack hizo la presentación con soltura y clavó el final.

Pero, en respuesta, la cara de Chuck permaneció inexpresiva. Después de una pausa, carraspeó y preguntó: "Bueno, ¿estás trabajando en algo importante?".

A Jack se le encogió el corazón. Años después todavía recuerda muy bien ese día. "Te aseguro", dice, "que no pegué ojo esa noche".

La paradoja de la innovación afirma que, cuanto más novedosa o radical sea una idea, más cuesta obtener apoyo para ella. Esta poderosa ley parecía estar atando a Jack de pies y manos. ¿Cómo vendes una innovación que es tan profunda que el comprador no la entiende?

## Cuidado, pioneros: Causad disrupción por vuestra cuenta y riesgo

Por desgracia, la advertencia de los compañeros de Jack se aplica por todas partes: cuanto mayor es el potencial de tu innovación, más traicionero resulta perseguirla. Si sigues adelante con valentía, te enfrentarás a un infierno en forma de duda, obstinación, resentimiento y, quizá lo peor de todo, una falta evidente de aprecio. A cambio de tu innovación, espera primero que no se te entienda y después, al final, que se te explote sin piedad.

El mundo margina a los propios innovadores que lo construyen. ¿Qué pasaría si hubieses desarrollado la primera televisión (Philo Farnsworth, inspirado para emitir imágenes fila a fila como un

agricultor ara un campo) o hubieses inventado el limpiaparabrisas intermitente (Robert Kearns; más complicado de lo que parece)? Digamos que pilotaste el primer vuelo continuo observado oficialmente (Alberto Santos-Dumont; no dejes que el "salto largo" de los hermanos Wright te engañe) o que fuiste el padre de la informática teórica (Alan Turing, que también descifró el funcionamiento de la máquina alemana Enigma en la Segunda Guerra Mundial y fundó la filosofía de la IA). Las cosas no te habrían ido demasiado bien. Los imperios corporativos se echaron encima de Farnsworth y Kearns y los gobiernos persiguieron de manera brutal a Santos-Dumont y Turing. ¿El resultado? Tres muertes y una crisis nerviosa.

Y, aun así, en la actualidad, los innovadores pueden causar más disrupción que nunca. Las mayores oportunidades no están en construir un dispositivo nuevo, como una televisión o un avión, sino que el paradigma innovador líder mejora sistemas ya existentes. Se infiltra en empresas consolidadas y renueva sus actividades a gran escala, sus millones de operaciones diarias. Lucha contra riesgos, orienta la publicidad, evita el fraude, optimiza la fabricación, hace un triaje de casos médicos y optimiza la logística.

Estoy hablando del *machine learning* (ML). Este libro trata sobre el ML en el siguiente sentido práctico aplicado:

**Machine learning:** Tecnología que aprende de la experiencia (datos) para predecir el resultado o comportamiento de cada cliente, paciente, entrega de paquetes, negocio, vehículo, imagen, pieza de equipamiento u otra unidad individual para guiar decisiones operativas mejores. El ML genera un modelo predictivo cuya tarea es calcular una puntuación predictiva (probabilidad) para cada individuo.

El ML es una base central para la IA (y a lo que se refieren muchos cuando hablan de ella). Este libro no cubre otras áreas a las que también se llama a veces IA, incluyendo la inteligencia artificial general (sistemas hipotéticos que serían capaces de realizar cualquier tarea intelectual que puedan hacer los humanos), el procesamiento del lenguaje natural, los sistemas basados en reglas y la visión por ordenador, pero sí habla de la IA generativa, conocida sobre todo por escribir texto y producir imágenes. A la hora de mejorar la eficiencia operativa, el ML domina desde hace mucho, pero la IA generativa también es adecuada y podría superar al ML clásico en algunas áreas. El marco de trabajo presentado



# Rendimiento

## Establecer las métricas de evaluación

*Una vez que hayas establecido lo que predecirá el machine learning, la siguiente cuestión es cómo lo predecirá. Por suerte, evaluar el rendimiento no requiere convertirse en un experto técnico, ya que puedes comparar un modelo sin tener en cuenta su funcionamiento interno. Aquí, solo juzgamos lo bien que predice, no cómo predice. Es solo una cuestión de aritmética, no de "ingeniería aeroespacial". A menudo, oírás hablar de exactitud, un recuento de con qué frecuencia predice correctamente un modelo. Pero la exactitud no solo es la medida errónea para la mayoría de los proyectos de ML, sino que también alimenta una falacia común que gestiona muy mal las expectativas.*

*Entonces, si no es la exactitud, ¿qué métrica usamos? Una es lift o elevación, un multiplicador simple que nos indica cuántas veces mejor que las suposiciones son las predicciones del modelo. Otra es el coste, el precio de cada falso positivo y el precio (por lo general, muy diferente) de cada falso negativo. Una vez establecidas, las métricas sirven para evaluar tanto el entrenamiento del modelo (paso 5) como su implementación (paso 6). Este capítulo va al meollo de la cuestión. ¿Qué valor tiene exactamente una predicción imperfecta? ¿De qué modo sirven todas las implementaciones de ML para triar y priorizar? ¿Y cómo se traduce un rendimiento predictivo bruto en métricas empresariales auténticas como el beneficio?*

### La práctica bizML

1. Valor: Establecer el objetivo de la implementación.
2. Objetivo: Establecer el objetivo de la predicción.
3. Rendimiento: Establecer las métricas de evaluación.
4. Combustible: Preparar los datos.
5. Algoritmo: Entrenar el modelo.
6. Lanzamiento: Implementar el modelo.

Los titulares sobre el *machine learning* prometen un poder predictivo casi divino. Veamos algunos ejemplos:

- *Newsweek*: "La IA puede decir si eres gay: la inteligencia artificial predice la sexualidad a partir de una foto con una exactitud sorprendente".
- *The Spectator*: "El análisis lingüístico puede predecir con exactitud la psicosis".
- *The Daily Mail*: "Escáneres que utilizan IA pueden identificar a personas en riesgo de sufrir un infarto mortal con casi una década de antelación... con una exactitud del 90 por ciento".
- *The Next Web*: "Esta IA aterradora ha aprendido a identificar a criminales por sus caras".

Todo eso es mentira. El ML no puede decir cosas así con confianza acerca de cada individuo. En la mayoría de los casos, estas cosas son demasiado difíciles de predecir con certeza.

Vamos a ver cómo funciona la mentira. Primero, los investigadores informan de una exactitud "alta", sugiriendo así (y engañando de forma fiable al lector para que crea) que su modelo puede identificar tanto casos positivos como negativos y, por lo general, tendrá razón. Para muchos problemas de predicción, ese nivel de rendimiento solo puede conseguirse en la ciencia ficción.

Estos informes revelan más tarde, con información enterrada entre los detalles de un artículo técnico, que estaban utilizando mal la palabra exactitud para referirse a otra medida de rendimiento relacionada con la exactitud, pero, en realidad, no tan impresionante como lo que "exactitud alta" implica.

Pero la prensa lo utiliza. Una y otra vez, esta argucia consigue embaucar a los medios, una bestia que con demasiada frecuencia prospera gracias a la hipérbole. Esta práctica de larga tradición genera repetidamente trucos publicitarios flagrantes que llaman a engaño.

Ahora bien, los modelos predictivos sobre los que están informando merecen a menudo recibir halagos. La capacidad para predecir mejor que una suposición aleatoria, incluso aunque en muchos casos no se haga con una gran certeza, mejora todo tipo de procesos empresariales. Eso es un chollo. Y, en algunos campos limitados, el ML puede predecir extremadamente bien, como en el reconocimiento de semáforos en fotografías o el reconocimiento de la presencia de determinadas enfermedades a partir de imágenes médicas.

Pero muchos comportamientos humanos desafían las predicciones fiables. Predecirlos es como intentar predecir el tiempo que va a hacer con muchas semanas de antelación. No se puede lograr una certeza elevada de manera consistente. No hay una bola de cristal mágica.

### El "gaydar" de Stanford no funciona por la cara

Piensa en el bombo que rodeó al tristemente célebre estudio sobre el "gaydar" de la universidad de Stanford. En su resumen inicial (el *abstract*), un artículo publicado en 2018 por los investigadores Michal Kosinski y Yilun Wang afirma que su modelo predictivo logra una exactitud del 91 por ciento al distinguir entre hombres gays y heterosexuales a partir de imágenes faciales. Eso animó a los periodistas a publicar afirmaciones muy exageradas acerca del rendimiento predictivo. Empezó un artículo de *Newsweek* con "Ahora la IA puede decir si eres gay o heterosexual con solo analizar una foto de tu cara". La portada de *The Economist* mostraba una cara que parecía una huella dactilar con el titular "Qué pueden decir las máquinas a partir de nuestra cara".

La cobertura mediática engañosa resultante es esperable. La afirmación inicial de los investigadores sobre la exactitud del 91 por ciento transmite de forma tácita e inevitable (a los lectores legos, los periodistas no técnicos e incluso a lectores técnicos casuales) la idea de que el sistema puede decir quién es gay y quién no y, en general, estar en lo cierto en ambas categorías.

Pero esa aseveración es falsa. El modelo no puede "decir" eso con seguridad acerca de cualquier individuo dado en general. En realidad, lo que puede hacer el modelo de Stanford el 91 por ciento de las veces es mucho menos extraordinario: puede identificar cuál de un par de dos hombres es gay cuando ya se ha establecido que uno lo es y el otro no.

Esta comparación (a la que yo llamo "prueba de pares") puede parecer una historia convincente, pero es engañosa. En principio, puede parecer un indicador razonable del rendimiento de un modelo predictivo, ya que la prueba crea un campo de juego equilibrado donde cada caso tiene unas probabilidades de 50/50. Y, de hecho, el resultado de esta prueba confirma que el modelo tiene un rendimiento mejor que las suposiciones aleatorias. La mayoría de los científicos de datos conocen la prueba de pares por un nombre más técnico, AUC (*Area Under the receiver operating characteristic Curve*, área bajo la curva ROC). Y, aun así, la mayoría de los científicos de datos, según mi experiencia,

# GUÍA PRÁCTICA DE LA IA

La mejor herramienta es la más difícil de utilizar. El *machine learning* es la tecnología de uso general más importante del mundo, pero es muy complicada de lanzar. Fuera de los gigantes tecnológicos y algunas otras empresas líderes, las iniciativas de *machine learning* suelen fallar a la hora de implementarse y nunca llegan a aportar valor. ¿Qué falta? Una práctica empresarial especializada apta para una adopción amplia. En la *Guía práctica de la IA*, el autor superventas Eric Siegel presenta el estándar de referencia, un modelo práctico en seis pasos para llevar los proyectos de *machine learning* desde su concepción hasta su implementación. Ilustra la práctica con historias de éxito y fracaso, incluyendo casos prácticos reveladores de UPS, FICO y empresas puntocom destacadas. Este enfoque disciplinado sirve para ambas partes: da poder a los profesionales empresariales y establece un marco de trabajo estratégico muy necesario para los profesionales de los datos.

Además de detallar la práctica, este libro también mejora las cualificaciones de los profesionales empresariales de forma indolora. Ofrece una dosis vital pero amable de conocimiento contextual semitécnico, que todas las partes interesadas necesitan para dirigir o participar en proyectos de *machine learning* de principio a fin. Esto pone a los profesionales empresariales y los de datos en igualdad de condiciones para que puedan colaborar de manera conjunta y profunda para establecer con precisión lo que debe predecir el *machine learning*, cómo de bien predice y cómo se actuará en función de sus predicciones para mejorar las operaciones. Estas cuestiones esenciales determinan el éxito o el fracaso de cada iniciativa; si se hacen bien, allanan el camino para la implementación dirigida al valor del *machine learning*.

Fotografía del autor: Stephanie Gross



## Doctor Eric Siegel

Consultor líder y exprofesor de la Universidad de Columbia y UVA Darden. Es el fundador de la longeva serie de conferencias Machine Learning Week, primer orador habitual y autor del libro, éxito de ventas, *Análítica predictiva. Predecir el futuro utilizando Big Data*.

2315273

ISBN 978-84-415-5176-3

**ANAYA**  
MULTIMEDIA



9 788441 551763