

15

La IA y los directivos de alto nivel

En enero de 2007, cuando Steve Jobs subió al escenario y presentó el iPhone al mundo, ni un solo observador reaccionó diciendo: «Bueno, la industria del taxi que se vaya despidiendo». Si avanzamos en el tiempo hasta 2018, en efecto ese parece ser el caso. En la última década, los teléfonos inteligentes han evolucionado de ser teléfonos algo más inteligentes que los anteriores a una plataforma de herramientas indispensables que está trastocando o alterando de manera fundamental todos los sectores de la industria. Incluso Andy Grove, autor de la famosa cita «solo los paranoicos sobreviven», debería admitir que eres un paranoico de tomo y lomo para haber previsto el alcance y el impacto que iban a tener los teléfonos inteligentes en algunas de las industrias más tradicionales.

Los recientes avances en IA y el aprendizaje de máquinas nos han convencido de que esta innovación puede equipararse con las grandes tecnologías transformadoras del pasado: la electricidad, los automóviles, los plásticos, el microchip, internet y los teléfonos inteligentes. A partir de la historia de la economía, sabemos cómo

estas tecnologías de propósito general se difunden y transforman a la sociedad, y además nos damos cuenta de lo difícil que resulta prever cuándo, dónde y cómo se producirán los cambios más disruptivos. Al mismo tiempo, hemos aprendido qué buscar, cómo anticiparnos a las curvas y cuándo es probable que una nueva tecnología pase de ser algo interesante a algo transformador.

¿Cuándo debería la IA ser un asunto crucial de tu programa para el equipo líder de tu organización? A pesar de que los cálculos del retorno sobre la inversión pueden inducir cambios operacionales, las decisiones estratégicas plantean dilemas y obligan a los líderes a lidiar con la incertidumbre. Adoptar la IA en una parte de una organización podría requerir cambios en otra parte. Los efectos internos en la organización, la adopción de la IA y otras decisiones requieren la autoridad de alguien que supervise todo el negocio; es decir, el director general.

Por todo ello, ¿cuándo es probable que la IA se adscriba a esta categoría?, ¿cuándo una caída en el coste de la predicción es lo bastante importante como para cambiar la estrategia? Y, si esto sucede, ¿qué dilema es probable que deba afrontar el director general?

Cómo puede la IA cambiar la estrategia de un negocio

En el capítulo 2, conjeturábamos que, cuando el dial de la máquina predictiva se haya ajustado lo suficiente, empresas como Amazon adquirirán tanta confianza en lo que quieren sus clientes que su modelo de negocios podría cambiar, pasando de un modelo compra-envío a otro de envío-compra; esto es, enviar artículos a los clientes antes de que estos los soliciten. Este escenario ilustra diáfaramente los tres ingredientes que podrían hacer que la inversión en esa herramienta de IA aumentara de nivel hasta convertirse en una decisión estratégica, en lugar de ser una decisión operacional.

En primer lugar, debe existir un dilema estratégico o compromiso. En el caso de Amazon, la disyuntiva es que el modelo envío-compra puede generar más ventas, pero también producir más bienes que los consumidores deseen devolver. Cuando el coste de devolución de artículos es demasiado elevado, el retorno sobre la inversión del modelo envío-compra es menor que el retorno sobre la inversión del tradicional enfoque de compra-envío, lo cual explica la razón por la que, en ausencia de un cambio tecnológico, el modelo de Amazon sigue siendo el de compra-envío, en lugar del modelo inverso, como casi el de cualquier otro minorista.

En segundo lugar, el problema se puede resolver si se reduce la incertidumbre. Para Amazon, se trata de la demanda de los consumidores. Si podemos pronosticar con precisión qué va a comprar la gente, especialmente si se entrega en sus domicilios, reduciremos la probabilidad de devoluciones e incrementaremos las ventas. La reducción de la incertidumbre afecta tanto al apartado del beneficio como al del coste, que forman ambos lados del dilema. Este tipo de gestión de la demanda no es nuevo, y es una de las razones por las que existen los almacenes físicos. Estas instalaciones no pueden pronosticar la demanda que harán los clientes individuales, pero sí la probable demanda que harán un grupo de clientes. Agrupando a los clientes que visitan una ubicación, los almacenes físicos eluden la incertidumbre de la demanda que se da entre los clientes individuales. Pasar a un modelo envío-compra basado en los domicilios individuales requiere más información sobre la demanda del cliente individual, lo cual puede superar la ventaja competitiva que representan los almacenes físicos.

En tercer lugar, para las empresas es necesaria una máquina predictiva que reduzca la incertidumbre lo suficiente como para cambiar el equilibrio del dilema estratégico. En el caso de Amazon, un modelo de demanda de cliente muy preciso podría hacer que el modelo envío-compra valiera la pena. En este caso, los beneficios del aumento de ventas compensan los costes de las devoluciones.

Ahora bien, si Amazon implementara ese modelo, haría otros cambios en su negocio, que incluirían, por ejemplo, inversiones para

reducir el coste de asegurar los paquetes dispuestos para recogida y los servicios de transporte para gestionar las devoluciones. A pesar de que el mercado de distribución cómodo para el cliente es competitivo, los servicios de devolución de productos son un mercado mucho menos desarrollado. La propia Amazon podría establecer una infraestructura de camiones que visitara cada barrio a diario para hacer entregas y devoluciones, integrándose así verticalmente en el negocio de devolución diaria de productos. Efectivamente, Amazon podría llevar los límites de su negocio justo a la puerta tu casa.

Este desplazamiento de los límites ya se está produciendo. Un ejemplo es la empresa de comercio electrónico alemana, Otto.¹ Una de las principales barreras para que el consumidor compre en internet en el lugar de en una tienda son los tiempos de entrega indefinidos. Si los consumidores han tenido una mala experiencia con las entregas, es improbable que vuelvan a visitar un sitio web. Otto descubrió que, cuando las entregas se demoraban —o sea, cuando tardaban más de unos pocos días—, el índice de devoluciones se disparaba. En ese intervalo, los consumidores inevitablemente localizaban el producto en una tienda y lo compraban allí. Incluso cuando Otto tenía ventas, las devoluciones se añadían a sus costes.

¿Cómo se puede reducir el tiempo de entrega de los productos a los consumidores? Anticipándose a lo que es probable que soliciten y tenerlo en stock en un centro de distribución cercano. Pero tal gestión de inventarios es costosa en sí misma. En lugar de eso, lo más adecuado es mantener únicamente el inventario que es probable que vayan a necesitar. O sea, desean una mejor predicción de la demanda de los consumidores. Otto, con una base de datos compuesta por 3 mil millones de transacciones anteriores y cientos de otras variables —incluidos los términos de búsqueda y datos demográficos—, fue capaz de crear una máquina predictiva que manejaba el pronóstico. Esta máquina puede ahora predecir con un 90% de precisión qué productos venderá en el plazo de un mes. Basándose en estos pronósticos, la empresa alemana remodeló su logística. Su inventario bajó en un 20%, y las devoluciones anuales descendieron en 2 millones

de artículos. La predicción mejoró la logística, lo que a su vez redujo costes e incrementó la satisfacción del cliente.

Una vez más, podemos ver los tres ingredientes de importancia estratégica. Otto tenía un dilema —cómo mejorar los tiempos de entrega sin costosos mantenimientos de inventario—, la incertidumbre alimentaba tal dilema —en este caso, la demanda general de los clientes en una ubicación— y, resolviendo tal incertidumbre —a saber, pronosticando mejor la demanda local—, la empresa pudo establecer un nuevo método de organizar la logística, que requería nuevas ubicaciones de almacenes, envíos locales y garantías de entrega al cliente. Y no podría haber conseguido todo esto sin usar la máquina predictiva para resolver la incertidumbre principal.

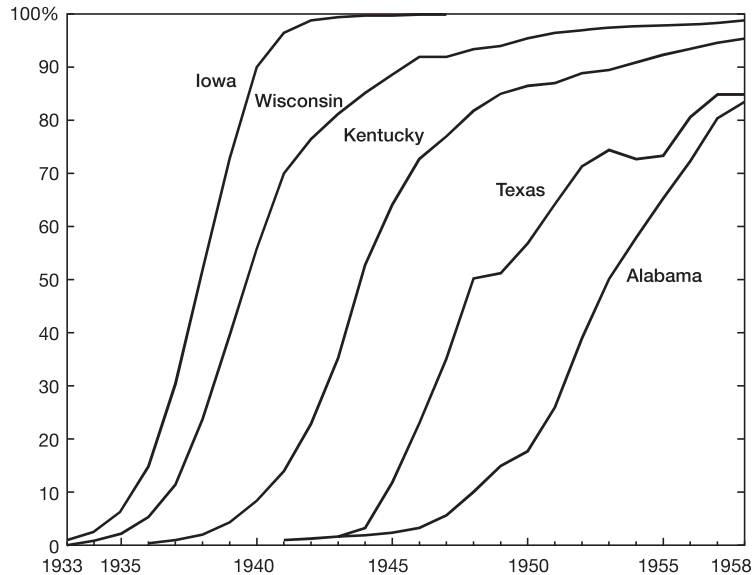
¿Dulce hogar, Alabama?

Para que una máquina predictiva cambie la estrategia de una organización, alguien tiene que crear una que sea útil para ese caso concreto, y ello depende de varios factores que escapan al control de la organización.

Echemos un vistazo a los factores que pueden hacer que la tecnología predictiva esté disponible para tu negocio. Para hacerlo, vamos a viajar a los campos de maíz de Iowa en los años treinta del siglo pasado. Allí, unos cuantos granjeros pioneros introdujeron una nueva clase de maíz, que habían creado mediante la hibridación de cultivos extensiva durante casi dos décadas. Este maíz híbrido era más específico que el maíz comercial ordinario, y requería maridar dos líneas endogámicas de maíz para mejorar sus propiedades, tales como la resistencia a la sequía y obtener así cosechas específicas en su entorno. Este maíz híbrido suponía un cambio crucial, ya que no solo prometía una productividad mucho más elevada, sino que también hacía que el granjero pasara a depender de los proveedores de semillas especiales.

Tal y como muestra el gráfico 15-1, parecía que los granjeros de Alabama no se habían modernizado en comparación con los de Iowa.

GRÁFICO 15-1

El lienzo de IA en el caso de Atomwise

Fuente: Zvi Griliches, «Hybrid Corn and the Economics of Innovation», Science 132, n° 3.422 (julio de 1960): 275-280 (reimpreso con el permiso de AAAs).

Pero, cuando el economista de Harvard Zvi Griliches observó detalladamente las cifras descubrió que el desfase de veinte años entre la adopción de ese cereal en Alabama y Iowa no se debía a que los granjeros de Alabama hubieran actuado tarde, sino a que el retorno sobre la inversión del maíz híbrido no justificaba que las granjas de Alabama lo adoptaran en la década de los treinta.² Las granjas de Alabama eran más pequeñas y tenían pocos márgenes de beneficios comparadas con las granjas de los estados del norte y el oeste. Por contra, los granjeros de Iowa podían aplicar una semilla exitosa en todas sus granjas más grandes y obtener mayores beneficios que justificaran los más elevados costes por las semillas. Una experimentación mayor destinada a las granjas grandes con variedades híbridas nuevas

era más sencilla, porque los granjeros solo tenían que apartar una pequeña porción de su propiedad hasta que las nuevas variedades se revelaran efectivas.³ Los riesgos de los granjeros de Iowa eran menores y tenían márgenes más amplios que actuaban como solución amortiguadora. Una vez que suficientes granjeros de un área sembraron las nuevas semillas, los mercados de semillas crecieron, gracias al mayor número de vendedores y compradores, y el coste de la venta de las semillas descendió, de forma que los riesgos de cosecharlas se vieron reducidos todavía más. Finalmente, los granjeros del maíz de todos los Estados Unidos —y de todo el mundo— acabaron cosechando las semillas híbridas a medida que los costes se reducían y los riesgos percibidos disminuían.

En el mundo de la IA, Google es Iowa. Esta entidad tiene en marcha más de mil proyectos de desarrollo de herramientas de IA en todas las categorías de sus negocios, desde la búsqueda a la publicidad y desde los mapas a la traducción.⁴ Otros gigantes tecnológicos de todo el mundo se han unido a Google. La razón es bastante obvia: Google, Facebook, Baidu, Alibaba y Salesforce, entre otros, ya están inmersos en el negocio de las herramientas. Ya han definido claramente las tareas que se extienden por todas sus empresas, y la IA puede en ocasiones mejorar sustancialmente un elemento predictivo en cada una de ellas.

Estas enormes corporaciones obtienen grandes márgenes de beneficio, por lo que pueden permitirse experimentar. Pueden coger una parte del «terreno» y dedicarlo a muchas nuevas variedades de IA; pueden cosechar grandes recompensas por experimentos exitosos, aplicándolos a una amplia gama de productos y operando a gran escala.

Para muchos otros negocios, el camino que conduce a la IA se antoja menos expedito. A diferencia de Google, muchos no han dedicado dos décadas de inversiones en la digitalización de todos los aspectos de su flujo de trabajo ni tienen una clara noción de lo que desean predecir. Pero cuando una empresa ha establecido estrategias bien definidas, ya puede desarrollar esos ingredientes y abonar el terreno para conseguir una IA efectiva.

Cuando las condiciones fueron las idóneas, todos los granjeros de maíz de Wisconsin, Kentucky, Texas y Alabama acabaron siguiendo el ejemplo de sus compatriotas y colegas de Iowa y cosecharon el maíz híbrido. Los beneficios de la demanda fueron lo bastante elevados, y los costes del suministro se redujeron. Del mismo modo, los costes y los riesgos asociados a una IA también acabarán descendiendo con el tiempo, por lo que muchos negocios que no se hallan en la vanguardia del desarrollo de herramientas digitales la adoptarán. Y, al hacerlo, la demanda los impulsará, dándoles la oportunidad de resolver dilemas fundamentales de sus modelos de negocio y reduciendo la incertidumbre.

Complementando a los jugadores de béisbol

La estrategia de Billy Beane en el film *Moneyball* —usar la predicción estadística para superar los prejuicios de los ojeadores de béisbol humanos y mejorar sus pronósticos— fue un ejemplo de cómo usar la predicción para reducir la incertidumbre y mejorar el rendimiento del equipo de los Oakland Athletics. Y ello también supuso un cambio estratégico que requirió alterar la jerarquía implícita y explícita de la organización.

La mejora en la predicción cambió el perfil de los jugadores a los que se contrataba, pero la operación del equipo de béisbol en sí misma no fue modificada. Los jugadores seleccionados por la máquina predictiva jugaban de una forma similar a la de los jugadores a quienes remplazaban, con la única diferencia, tal vez, de que daban a un bateador unas cuantas bases por bolas más. Y los ojeadores continuaron teniendo un papel en la selección de jugadores.⁵

El cambio más fundamental se produjo en aquellas personas que se contrataban para que ocuparan cargos fuera del terreno de juego y en la reestructuración resultante del organigrama. Lo más importante es que el equipo contrataba a personas que podían decir a las

máquinas que debían predecir y usar después esas predicciones para determinar a qué jugadores iban a fichar —el más destacado fue Paul de Podesta, así como otros cuyas contribuciones se reflejaron en el personaje de Peter Brand interpretado por Jonah Hill en la película—. El equipo también creó un nuevo puesto denominado «analista saber métrico». Un analista saber métrico desarrolla medidas para las recompensas que el equipo recibiría si fichara a distintos jugadores. Estos analistas son los ingenieros de función de recompensas del béisbol. Ahora, la mayoría de los equipos tienen al menos un analista de este tipo, y esta función ha aparecido también, con diferentes nombres, en otros deportes.

Esta mejor predicción creó un nuevo puesto de elevado rango en el organigrama. Los científicos de investigación, los científicos responsables de los datos y los vicepresidentes del departamento de analítica están listados como los cargos clave en los directorios en línea de la oficina principal. Los Houston Astros disponen incluso de una unidad de ciencias individual dirigida por un exingeniero de la NASA, Sig Mejdal. El cambio estratégico también significa cambiar a la persona que se encarga de escoger a los jugadores del equipo. Estos expertos analíticos tienen habilidades matemáticas, pero los mejores de entre ellos comprenden perfectamente qué hay que decirle a la máquina predictiva que haga. Aportan juicio.

Volviendo a la economía simple que subyace bajo todos los argumentos de este libro, la predicción y el juicio son complementarios; a medida que aumenta el uso de la predicción, aumenta el valor del juicio. Los equipos están incorporando cada vez más a nuevos asesores superiores; quienes, en ocasiones, es posible que no tengan experiencia de primera mano en ese juego y —fieles al estereotipo— podrían no encajar en el complicado mundo del deporte profesional. No obstante, hasta los novatos reclutados en este ámbito, requieren una profunda comprensión del juego, ya que usar las máquinas predictivas en la gestión deportiva implica un aumento del valor de la gente que tiene el juicio para determinar las recompensas y, por tanto, el juicio para usar esas predicciones en las decisiones.

La elección estratégica requiere un nuevo juicio

El cambio en la organización de la gestión de un equipo de béisbol pone de relieve otro concepto clave para los directivos de alto nivel a la hora de implementar las elecciones estratégicas respecto a la IA. Antes de la sabermetría, el juicio de los ojeadores del béisbol se limitaba a los pros y los contras de los jugadores individuales. Pero el hecho de usar las medidas cuantitativas hizo posible predecir cómo los «grupos» de jugadores se iban a desenvolver juntos. El juicio pasó de pensar en la recompensa de un jugador concreto a pensar en la recompensa de un equipo concreto. Las mejores predicciones permiten ahora al director tomar decisiones que están más cerca de los objetivos de la organización: determinar al mejor equipo en lugar de a los mejores jugadores individuales.

Para sacar el máximo provecho de las máquinas predictivas, es necesario que nos replanteemos las funciones de recompensa en toda nuestra organización, a fin de adaptarnos mejor a nuestras verdaderas metas. Pero esta tarea no es sencilla. Más allá de reclutar, la comercialización del equipo necesita cambiar el rendimiento individual, tal vez incluso restarle importancia. Del mismo modo, los entrenadores deben entender las razones para la contratación de jugadores y las implicaciones de la composición del equipo en cada partido. Finalmente, también los jugadores deben comprender cómo sus funciones y roles pueden cambiar dependiendo de si sus oponentes han adoptado nuevas herramientas de predicción.

Las ventajas que quizá ya tengamos

La estrategia también supone capturar valor; es decir: ¿quién capturaré el valor que cree una mejora de las predicciones?

Los ejecutivos de negocios suelen comentarnos que, como las máquinas predictivas precisan datos, los datos son en sí mismos un activo estratégico. Dicho de otro modo: si has recabado datos de,

pongamos por caso, ventas de yogures durante muchos años, entonces para predecir las ventas de tal alimento usando una máquina predictiva, alguien necesitará esos datos. De ahí que estos sean valiosos para su propietario. Es como tener un depósito de petróleo.

Ese supuesto oculta un importante concepto: al igual que el petróleo, los datos tienen distintos grados. Hemos destacado tres tipos de datos: entrenamiento, entrada y retroalimentación. Los datos de entrenamiento se usan para construir una máquina predictiva. Los datos de entrada se usan para alimentarla y que produzca predicciones. Y los datos de retroalimentación se usan para mejorarla. Solo los dos últimos tipos se necesitan para un uso futuro. Los datos de entrenamiento se usan al principio para formar un algoritmo, pero cuando la máquina predictiva ya está funcionando, estos datos dejan de resultar útiles. Es como si los hubiera quemado. Los anteriores datos sobre ventas de yogures tienen poco valor una vez ha construido una máquina predictiva basada en ellos.⁶ En otras palabras, la máquina puede ser valiosa hoy, pero es improbable que sea una fuente de valor sostenible. Para hacerlo, es necesario generar nuevos datos —de entrada o de retroalimentación— o bien es necesario tener otra ventaja. Exploraremos las ventajas de generar nuevos datos en el próximo capítulo, pues en este nos centraremos en las otras ventajas.

Dan Bricklin, el inventor de la hoja de cálculo, creó un valor enorme, pero no es una persona rica. ¿Dónde fue a parar el valor de la hoja de cálculo? En los ránkines de riqueza, los imitadores como el fundador del Lotus 123, Mitch Kapor, o el de Microsoft, Bill Gates, desde luego superaron en mucho a Bricklin, e incluso se apropiaron de una pequeña fracción del valor de la hoja de cálculo. En lugar de eso, el valor repercutió en los usuarios, en los negocios que aplicaban las hojas de cálculo para tomar muchas decisiones mejores. No importaba lo que Lotus o Microsoft hicieran, sus usuarios eran poseedores de las decisiones que las hojas de cálculo estaban mejorando.

Y como operan al nivel de las decisiones, lo mismo es cierto para las máquinas predictivas. Imaginemos aplicaciones de la IA que asis-

tieran en la gestión de inventarios de una cadena de supermercados. Saber cuándo se va a vender un yogur ayudaría a saber cuándo se debe mantenerlo en almacén y minimizaría la cantidad de unidades no vendidas que deben desecharse. Un innovador de IA que ofrece máquinas predictivas para la demanda de yogures podría hacerlo bien, pero tendría que tratar con una cadena de supermercados para crear algún valor. Solo la cadena de supermercados puede emprender la acción de almacenar yogur o no hacerlo. Y, sin esa acción, la máquina predictiva para demanda de yogures no tiene ningún valor.

Muchos negocios continuarán siendo poseedores de sus acciones con o sin IA; tendrán una ventaja cuando capturen parte del valor que se crea al adoptar una IA. Pero tal ventaja no significa que las empresas que posean las acciones capturen todo el valor.

Antes de vender sus hojas de cálculo, Bricklin y su socio, Bob Frankston, se preguntaron si debían conservarlas. Podían vender sus habilidades de modelación y, como resultado, capturar el valor creado por sus conocimientos. Ambos socios abandonaron su plan —seguramente por un buen motivo—, pero en el campo de la IA esta estrategia puede funcionar. Los proveedores de IA podrían intentar trastocar a quienes sigan funcionando con las herramientas clásicas.

Los vehículos autónomos son un ejemplo de ello, hasta cierto punto. Mientras que algunos fabricantes de coches tradicionales están invirtiendo vehementemente en sus propias capacidades, otros esperan asociarse con aquellos que están fuera de su industria (como Alphabet de Waymo), en lugar de desarrollar esas capacidades en su empresa. En otros casos, las grandes empresas tecnológicas están iniciando proyectos con fabricantes de coches tradicionales. Por ejemplo, Baidu, operador del mayor motor de búsqueda de China, lidera una ambiciosa y diversificada iniciativa de conducción abierta y autónoma, el Proyecto Apolo, con varias decenas de socios, que incluyen a Daimler y Ford. Además, Tencent Holdings, propietario de WeChat, que posee casi mil millones de cuentas de usuarios activas mensuales, lidera una alianza de la automoción que incluye a empresas tan consolidadas y prominentes como Beijing Automotive

Group. Chen Juhong, vicepresidente de Tencent, remarcó: «Tencent pretende hacer un ímprobo esfuerzo para reforzar el desarrollo de las tecnologías IA usadas en la conducción autónoma... Queremos ser «un conector» para ayudar a acelerar la cooperación, la innovación y la convergencia industrial...».⁷

Reflexionando sobre las presiones competitivas que impulsan la colaboración, el presidente de Beijing Automotive, Xu Heyi, comentó: «En esta nueva era, solo aquellos que conecten con otras empresas para construir la próxima generación de vehículos sobrevivirán, mientras que los que se encierren en una sala para fabricar coches perecerán».⁸ Operadores relativamente nuevos —como Tesla— están compitiendo con empresas consolidadas usando directamente la IA en coches nuevos que integran estrechamente el software y el hardware. Empresas como Uber están usando la IA para desarrollar un grado de autonomía tal que les lleve a quitar a los conductores el poder de decisión en la conducción.

La simple economía de la estrategia IA

Los cambios que hemos destacado dependen de dos aspectos diferentes del impacto de la IA en el corazón de nuestro escenario económico.

En primer lugar, igual que sucede en el modelo envío-compra de Amazon, las máquinas predictivas reducen la incertidumbre. A medida que la IA avanza, usaremos las máquinas predictivas para reducir la incertidumbre en más ámbitos. Por ende, los dilemas estratégicos generados por la incertidumbre evolucionarán con la IA. A medida que el coste de la IA baje, las máquinas predictivas resolverán una mayor variedad de dilemas estratégicos.

En segundo lugar, la IA aumentará el valor de los complementos de predicción. Un juicio de un analista de béisbol, las acciones de un minorista de comestibles, y (como expondremos en el capítulo 17) los datos de las máquinas predictivas se volverán tan importantes que quizá necesites cambiar de estrategia para sacar partido a lo que ofreces.

PUNTOS CLAVE

- El liderazgo de los directivos de alto nivel no debe delegar completamente la estrategia IA a su departamento de informática, porque las poderosas herramientas de IA podrían ir más allá, mejorando la productividad de las tareas realizadas al servicio de una ejecución contraria a la estrategia de la organización, lo que conllevaría un cambio en la propia estrategia. La IA puede comportar un cambio estratégico si se presentan tres factores: (1) existe un intercambio básico en el modelo de negocio —por ejemplo, compra-envío frente a envío-compra—; (2) el intercambio está influenciado por la incertidumbre —por ejemplo, las mayores ventas procedentes del modelo envío-compra se ven contrarrestadas por los elevados costes de los artículos devueltos debido a la incertidumbre en torno a lo que los clientes van a comprar—; y (3) una herramienta IA que reduce la incertidumbre inclina la balanza del intercambio a su favor, por lo que la estrategia óptima cambia de un lado del comercio al otro —por ejemplo, una IA que reduce la incertidumbre, al predecir lo que un cliente comprará, inclina la balanza de forma tal que los beneficios obtenidos con el modelo envío-compra superan a los del modelo tradicional—.
- Otra razón por la que se requiere un liderazgo de los directivos de alto nivel en la estrategia de IA es que la implementación de las herramientas de IA en una parte del negocio también puede afectar a otras partes del mismo. En el experimento de reflexión de Amazon, el efecto secundario de hacer la transición hacia un modelo envío-compra era la integración vertical en el sector de la recogida de artículos devueltos, tal vez con una flota de camiones que hiciera recogidas semanales por todo el barrio. En otras palabras, las poderosas herramientas de IA pueden conllevar un sig-

nificativo rediseño de los flujos de trabajo y de los límites de la empresa.

- Las máquinas predictivas aumentarán el valor de los complementos, lo que incluye el juicio, las acciones y los datos. El valor aumentado del juicio podría conllevar cambios en la jerarquía organizacional; el hecho de colocar a distintas personas o distintos roles en posiciones de poder podría reportar mayores beneficios. Además, las máquinas predictivas permiten a los directores ir más allá de la optimización de los componentes individuales y optimizar metas de mayor nivel, haciendo así que la toma de decisiones se acerque más a los objetivos de la organización. Poseer las acciones afectadas por la predicción puede ser una fuente de ventaja competitiva que permita a los negocios tradicionales capturar parte del valor de la IA. Sin embargo, en algunos casos en los que las poderosas herramientas de IA proporcionan una significativa ventaja competitiva, los nuevos operadores podrían integrar verticalmente la propiedad de la acción, impulsando así sus IA como punto de partida para ser más competitivos.

16

Cuando la IA transforma tu negocio

Joshua, uno de los autores de este libro, preguntó recientemente a una empresa principiante en el aprendizaje de máquinas por qué estaba suministrando diagnósticos a los doctores. El proyecto consistía en construir una herramienta de IA que pudiera decirle a un médico si una afección concreta estaba presente o no. Un simple resultado binario. Un diagnóstico. El problema era ser capaz de hacerlo. La empresa debía obtener la aprobación regulatoria, lo que requería costosos ensayos. Para gestionar tales ensayos, la empresa estaba sopesando la posibilidad de asociarse con una empresa farmacéutica o de aparatos médicos consolidada.

La pregunta de Joshua era más estratégica que médica: ¿por qué el proyecto tenía que suministrar un diagnóstico? En lugar de ello, ¿no podía simplemente suministrar una predicción? Esto es, la herramienta podía analizar los datos y después decirle al doctor que «existía un 80% de posibilidades de que el paciente tuviera la afección». El doctor podía entonces explorar de forma precisa qué factores llevaban a esa conclusión y hacer un último diagnóstico; a saber, un

resultado binario: «presente o no presente». La empresa podía permitir que el cliente —en este caso, el médico— fuera un paso más allá.

Joshua sugirió que la empresa se centrara en la predicción en lugar de hacerlo en el diagnóstico. Los límites de su negocio acabarían con una predicción. Esto obviaba la necesidad de aprobación regulatoria, porque los médicos disponen de muchas herramientas para llegar a una conclusión diagnóstica. La empresa no necesitaba asociarse tempranamente con empresas establecidas. Y lo más importante, esta ya no debía investigar y dilucidar con precisión cómo traducir la predicción en un diagnóstico. Todo lo que tenía que deducir era la precisión del umbral requerida para suministrar una predicción valiosa. ¿Era de un 70%, un 80% o un 99%?

¿Dónde empieza tu negocio y dónde empieza el de otra persona? ¿Dónde están exactamente los límites de tu empresa? A largo plazo, esta decisión requiere una cuidadosa atención en el nivel más alto de la organización. Es más, las innovaciones de propósito general suelen desembocar en nuevas respuestas relativas a la cuestión de los límites del negocio. Ciertas herramientas de IA pueden transformar los límites de un negocio. Las máquinas predictivas van a cambiar la forma de pensar de las empresas, desde sus bienes de capital a sus datos y su personal.

Qué se debe mantener y qué se debe descartar

La incertidumbre tiene un impacto sobre los límites de un negocio.¹ Los economistas Silke Forbes y Mara Ledermann examinaron la organización de la industria aeronáutica estadounidense en el cambio de milenio.² Las aerolíneas importantes, como United Airlines y American Airlines, gestionaban algunas rutas, mientras que los socios regionales, como American Eagle y SkyWest, se encargaban de las demás. Estos socios eran empresas independientes que tenían acuerdos contractuales con las aerolíneas principales. A falta de otras

consideraciones, las aerolíneas regionales solían operar con un coste menor que las principales, ahorrando dinero en salarios y rigiéndose por normas laborales menos beneficiosas. Por ejemplo, algunos estudios mostraron que los pilotos experimentados de las aerolíneas principales recibían una paga superior en un 80% que la de sus socios regionales.

El enigma reside en por qué las aerolíneas principales gestionan tantas rutas en lugar de las regionales, habida cuenta de que los socios pueden prestar el servicio a un coste inferior. Forbes y Ledermann identificaron un factor determinante: la climatología. O más específicamente: la «incertidumbre» sobre la climatología. Cuando un evento meteorológico sale de lo ordinario, demora los vuelos; lo cual, en la estrechamente interconectada industria aeronáutica, gestora de capacidades, podría tener un efecto dominó en todo el sistema. Cuando el tiempo se vuelve en contra, las aerolíneas principales no desean quedar paralizadas mientras los socios revisan sus contratos y hacen cambios rápidos con costes inciertos. Así pues, en las rutas en las que es probable que haya demoras por el tiempo, las aerolíneas principales mantienen el control y la operación.

Los tres ingredientes que hemos resaltado en el capítulo anterior sugieren que la IA podría conllevar un cambio estratégico. Primero, costes menores frente a más control es una compensación básica. Segundo, tal compensación es mediada por la incertidumbre; específicamente, los beneficios del aumento del control con el nivel de incertidumbre. Las principales compañías aéreas equilibran el bajo coste con un mayor control, optimizando los límites de dónde acaban sus propias actividades y dónde empiezan las de sus socios. Si una máquina predictiva pudiera suprimir esta incertidumbre, el tercer ingrediente estaría presente y el equilibrio se modificaría. Las aerolíneas contratarían más actividades para sus socios.

Las empresas que se embarcan en la innovación continua, especialmente en la innovación que supone aprender de la experiencia, crean un patrón similar. Los nuevos modelos de automóviles salen al mercado aproximadamente cada cinco años y, como su fabricación

implica elaborar especificaciones detalladas de las piezas y del trabajo de diseño, los fabricantes necesitan saber de dónde vienen las piezas antes de que salgan al mercado. ¿Están fabricando las piezas ellos mismos o las externalizan? A lo largo de todo el proceso de desarrollo, un fabricante de automóviles puede saber algunas cosas sobre qué rendimiento va a tener un nuevo modelo. Ciertas informaciones solo pueden recabarse tras su lanzamiento, como la información del cliente y otras medidas de rendimiento a largo plazo. Esta es una razón clave para entender por qué los modelos presentan actualizaciones anuales que no implican cambios importantes en el diseño del vehículo, sino que ofrecen mejoras en los componentes para resolver problemas y mejorar el producto.

Los economistas Sharon Novak y Scott Stern descubrieron que los fabricantes de automóviles de lujo que confeccionaban sus propias piezas mejoraban más rápido entre el año del modelo y el siguiente;³ los fabricantes calibraban las mejoras en el lado del cliente, usando categorías extraídas de la revista estadounidense *Consumer Reports*. Tener el control significa que los fabricantes podían adaptarse más fácilmente a la opinión del cliente. Por el contrario, aquellos que externalizaban las piezas no mostraban la misma mejora. Sin embargo, estos últimos obtuvieron un beneficio distinto; sus modelos iniciales eran de mayor calidad que los primeros modelos de los fabricantes que hacían sus propias piezas. Los modelos más recientes y modernos de los fabricantes que externalizaban las piezas eran mejores desde el principio, ya que los proveedores hacían piezas mejores. De ahí que, los fabricantes se enfrentaran a la elección de externalizar o fabricar las piezas ellos mismos para obtener mejoras con el tiempo, ya que controlaban la innovación dentro del ciclo de vida de sus productos. Una vez más, una máquina predictiva que reduce la incertidumbre en torno a las necesidades del cliente pudo cambiar la estrategia.

En cada caso, la compensación entre el rendimiento a corto y largo plazo y los eventos rutinarios frente a eventos no rutinarios se resuelve con una elección organizacional clave: ¿cuánta confianza

depositamos en los proveedores externos? Pero la relevancia de esta elección está estrechamente relacionada con la incertidumbre. ¿Hasta qué punto son importantes los eventos meteorológicos que las aerolíneas no pueden prever de antemano? ¿Cómo se adaptará el vehículo a lo que los clientes realmente desean?

Impacto de la IA: el capital

Asumamos que una IA que puede reducir esta incertidumbre está disponible, así que el tercer ingrediente está presente. La predicción es tan barata que minimiza la incertidumbre lo suficiente como para cambiar la naturaleza del dilema estratégico. ¿Cómo afectará tal situación a lo que hacen las aerolíneas y los fabricantes de automóviles? La IA permitiría que las máquinas operasen en entornos más complejos, pues expande el número de «síes» fiables, por lo que reduce la necesidad empresarial de poseer sus propios bienes de equipo por dos razones.

En primer lugar, más «síes» significa que un negocio puede redactar contratos para que especifiquen qué hacer si sucede algo inusual. Supongamos que una IA permite que las aerolíneas no solo pronostiquen los eventos meteorológicos, sino que además generan predicciones sobre la mejor manera de gestionar las interrupciones provocadas por estos fenómenos. Esto aumentaría los beneficios de las compañías aéreas principales por ser más específicos en sus contratos sobre la gestión de estas contingencias. Podrían especificar un mayor número de «síes» en sus contratos; por lo que, en lugar de controlar las rutas aéreas a través de la propiedad, las compañías aéreas principales tendrían el poder predictivo para redactar contratos de forma más segura con aerolíneas regionales independientes, permitiéndoles sacar partido de los costes más reducidos de este tipo de empresas. Requerirían menos bienes de capital —tales como aeronaves— porque podrían externalizar más vuelos a las pequeñas aerolíneas regionales.

En segundo lugar, la predicción de la IA —siguiendo todo el proceso hasta predecir la satisfacción del cliente— permitiría a los

fabricantes de coches diseñar de antemano sus productos con más seguridad y confianza, por lo que el consumidor tendría mayor satisfacción y habría un mejor rendimiento sin la consiguiente necesidad de ajustes extensos de modelos medios. En consecuencia, los fabricantes de coches serían capaces de seleccionar para sus modelos las mejores piezas del mundo de proveedores independientes, confiados en que una predicción anticipada superior elimina la necesidad de costosas renegociaciones contractuales. Los fabricantes de automóviles tendrían así menos necesidad de poseer sus propias fábricas suministradoras de piezas. Desde una perspectiva más general, la predicción nos proporciona muchos más «síes» que podemos usar para especificar claramente los «entonces».

Esta valoración contempla la complejidad de las redes de aerolíneas y productos de automoción como algo fijo. Podría suceder perfectamente que una predicción anticipada suministrara a las aerolíneas y los fabricantes de coches la confianza suficiente para permitir más acuerdos y productos complejos. No está claro cuál será el impacto en la externalización, dado que una mejor predicción impulsa un mayor grado de externalización, mientras que una mayor complejidad tiende a reducirla. Es difícil de saber en esta fase cuál de estos factores predominará. Lo que sí podemos decir es que, aunque los procesos complejos recientemente viables se puedan hacer internamente, muchos procesos más simples, que previamente eran realizados por las empresas, se van a externalizar en un futuro próximo.

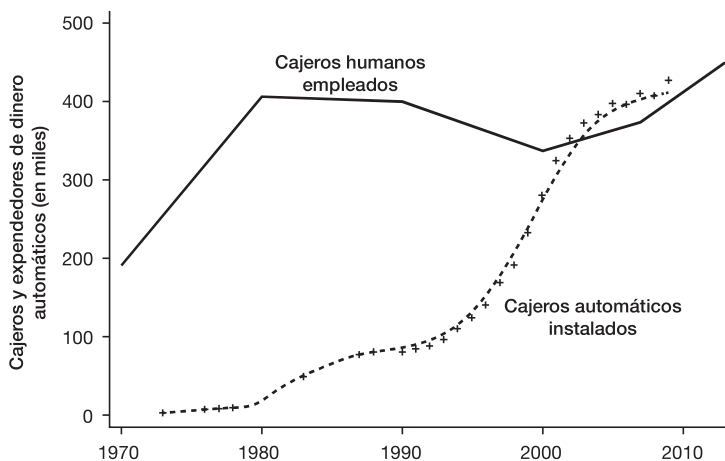
Impacto de la IA: la mano de obra

Los bancos lanzaron el cajero automático, desarrollado durante la década de los setenta, que fue extendiéndose progresivamente durante la década de los ochenta. Esta tecnología, potencialmente ahorradora de tiempo y trabajo, se diseñó —como su propio nombre indica— para automatizar el trabajo de los cajeros.

Según la Oficina de Estadística Laboral de EE. UU., no se estaba perdiendo de su trabajo a los cajeros (ver el gráfico 16-1), sino que

GRÁFICO 16-1

Evolución de los cajeros humanos y de los cajeros automáticos con el paso tiempo



Fuente: James E. Bessen, «How Computer Automation Affects Occupations: Technology, Jobs, and Skills», Escuela de Derecho de la Universidad de Boston. Informe de investigación sobre derecho y economía, núm. 15-49 (3 de octubre de 2016); cort.as/-15-K.

se les quitaba las tareas propias de un cajero. Aquellos empleados acabaron convirtiéndose en agentes de comercialización y servicio al cliente para productos bancarios, más allá de la recogida y la dispensa de dinero en efectivo. Ahora, las máquinas se ocupaban de tales tareas de forma más segura que las personas. Una razón por la que los bancos no tenían intención de abrir más sucursales era precisamente por aspectos de seguridad y por el coste humano de dedicar tiempo a hacer algo tan transaccional como despachar billetes. Liberadas de esta carga, las sucursales bancarias empezaron a proliferar (43% más en áreas urbanas) adoptando más formas y tamaños, y junto con ellas, un personal que era anacrónicamente denominado «cajeros».

La introducción de los cajeros automáticos produjo una significativa transformación organizacional: era necesario que los nuevos cajeros tuvieran más juicio subjetivo. Las tareas originales de los

cajeros humanos eran, por definición, rutinarias y fueron fácilmente mecanizadas. Pero las nuevas tareas —a saber, hablar con los clientes sobre sus necesidades bancarias, aconsejarles sobre préstamos y decidir sobre opciones de tarjetas de crédito— eran más complicadas. Durante el proceso, evaluar si los nuevos cajeros estaban haciendo un buen trabajo se volvió un asunto más complejo.⁴

Cuando las medidas de rendimiento pasan de ser objetivas —¿está haciendo que las colas del banco sean cortas?— a subjetivas —¿está vendiendo los productos correctos?—, la gestión de los recursos humanos se convierte en un asunto más arduo. Los economistas nos dirían que las responsabilidades laborales deben volverse menos explícitas y más relacionales. Evaluaríamos y premiaríamos a nuestros empleados basándonos en los procesos subjetivos, tales como las revisiones de rendimiento que tengan en cuenta la complejidad de las tareas, así como los puntos fuertes y débiles de los empleados. Tales procesos son difíciles de implementar, porque basarse en ellos para crear incentivos por buen rendimiento requiere mucha confianza. Después de todo, una empresa puede decidir negar una bonificación, un aumento de salario o un ascenso más fácilmente si se basa en un análisis subjetivo que cuando las medidas de rendimiento son objetivas. Sin embargo, cuando las medidas de rendimiento son objetivas en entornos complejos, es posible cometer errores graves, tal como nos demostró fehacientemente la experiencia de Well Fargo con el fraude de los gestores contables.⁵

La implicación directa de esta línea de lógica económica es que la IA cambiará la gestión de los recursos humanos hacia lo relacional y se apartará de lo transaccional. La razón es doble. En primer lugar, el juicio humano, allá donde sea valioso, se utiliza porque es difícil programar tal juicio en una máquina. Las recompensas son inestables o desconocidas, o bien requieren la experiencia humana para implementarlas. En segundo lugar, en la medida en que el juicio humano se vuelva más importante cuando las predicciones artificiales proliferen, tal juicio implica necesariamente medios subjetivos de evaluación del rendimiento. Si los medios objetivos están disponibles, es probable que una máquina pueda hacer tal juicio sin necesidad de ninguna gestión

de recursos humanos. Por tanto, las personas son primordiales en las tomas de decisiones en que las metas son subjetivas. Según lo expuesto, es probable que la gestión de tales personas tenga un carácter más relacional.

Por consiguiente, la IA tendrá un impacto en la mano de obra distinto al impacto en el capital. La importancia del juicio significa que los contratos de empleados deberán ser más subjetivos.

Las fuerzas que afectan a los bienes de capital también afectan a los trabajadores. Si los productos clave de la mano de obra son los datos, las predicciones o las acciones, usar una IA significa contratar a más mano de obra externa, así como a más equipo y suministros externalizados. En cuanto al capital, las mejores predicciones suministran más «sís», que podemos usar para especificar más claramente los «entonces» en un contrato de externalización.

A pesar de todo, el efecto más importante en la mano de obra será la creciente importancia del juicio humano. La predicción y el juicio son complementarios, así que una menor predicción aumenta la demanda de juicio, lo cual significa que el papel principal de sus empleados será poner en práctica el juicio en la toma de decisiones. Esto, por definición, no puede ser bien especificado en un contrato. En este caso, la máquina predictiva incrementa la incertidumbre en el dilema estratégico, porque evaluar la calidad del juicio es complicado, así que contratar externamente es arriesgado. Contra lo que parece indicar la intuición, una mejor predicción aumenta la incertidumbre que podemos tener sobre la calidad del trabajo humano realizado: normalmente, es necesario mantener a los ingenieros de función de recompensas, así como a otros empleados centrados en el juicio en su empresa.

Impacto de la IA: los datos

Otro aspecto importante de la estrategia es la propiedad y el control de los datos. Del mismo modo que las consecuencias para los trabajadores se relacionan con la complementariedad entre la predicción y

el juicio, la relación entre la predicción y los datos también estimula esas compensaciones. Los datos mejoran las predicciones. Aquí, consideramos las compensaciones asociadas a los límites organizacionales. ¿Deberías utilizar los datos de otros o solo tus propios datos? (en el próximo capítulo exploraremos algunos temas relativos a la importancia estratégica de la recogida de datos).

En cuanto las empresas de IA emergentes, poseer datos que les permitan aprender es primordial. En caso contrario, esas empresas no mejorarán sus productos a la larga. La empresa de IA emergente Ada Support ayuda a otras empresas a que interactúen con sus clientes. Ada tuvo la oportunidad de integrar su producto en el sistema de un proveedor de servicios de chat con sólida reputación. Si funcionaba, iba a ser mucho más sencillo obtener un buen punto de apoyo y establecer una base de usuarios extensa. Era un camino tentador.

El problema, no obstante, era que las empresas establecidas poseían los datos de retroalimentación sobre las interacciones. Sin esos datos, Ada no sería capaz de mejorar su producto, basándose en lo que realmente pasó en la práctica. Ada fue alentada a reconsiderar este enfoque, pero no lo integró hasta que pudo garantizar que los datos resultantes eran suyos. Al hacerlo, Ada generó un sinfín de datos presentes y futuros, y pudo sacar provecho del aprendizaje continuo.

Pero el dilema de poseer o suministrar datos no se limita en ningún caso a las empresas emergentes. Consideremos los datos diseñados para ayudar a los publicistas a dirigirse a potenciales clientes. John Wanamaker, quien, entre otros, creó la moderna estructura de la publicidad en los medios, dijo en cierta ocasión: «La mitad del dinero que gasto en publicidad se está desperdiciando; el problema es que no sé qué mitad».

Esta sentencia encierra la cuestión fundamental del mundo publicitario. Si pones un anuncio en una página web, todo el mundo que visita esa página verá el anuncio, y pagarás por cada impresión. Si solo una fracción de esas personas son clientes potenciales, tu predisposición a pagar por cada impresión será relativamente baja. Ese es

tu problema como anunciante y el de la página web que intenta sacar dinero de los anuncios.

Una solución es centrarse en diseñar páginas web que atraigan a la gente con intereses específicos —deportes, finanzas, etc.—, los cuales tienen una mayor proporción de clientes potenciales para ciertos tipos de anunciantes. Antes del surgimiento de internet, este era un rasgo esencial de la publicidad; lo que conducía a una proliferación de revistas, canales de televisión por cable y secciones de periódicos dedicadas a la automoción, la moda, las inmobiliarias y la inversión. No obstante, no todos los medios de difusión pueden confeccionar su contenido de esta manera.

En lugar de ello, gracias a las innovaciones en los navegadores web, sobre todo las *cookies*, los anunciantes pueden rastrear a los usuarios a lo largo del tiempo y por los sitios web, adquiriendo la capacidad de seleccionar mejor el objetivo de su publicidad. Las *cookies* registran información sobre los visitantes de las páginas web y, lo que aún es más importante, información sobre el tipo de sitios, incluidos los de compras, que estos frecuentan. A causa de esta tecnología de rastreo, cuando visitamos un sitio web para comprar unos nuevos calzoncillos, es posible que encontremos una desproporcionada cuota de anuncios subsiguientes, con sitios que no tienen absolutamente nada que ver con la venta de ropa interior.

Cualquier sitio web puede instalar *cookies*, pero estas no son necesariamente de mucho valor para el sitio web. En lugar de ello, las páginas web ofrecen *cookies* a la venta para intercambios publicitarios —o, a veces, directamente a los anunciantes—, de forma que pueden adaptar mejor el objetivo de sus anuncios. Las páginas web venden datos sobre sus visitantes a las empresas que instalan anuncios.

Las empresas compran esos datos porque no pueden recopilarlos por sí mismas. No es de extrañar que compren datos que les ayuden a identificar a los clientes de alto valor, y es posible que también compren datos que les ayuden a evitar hacer publicidad a clientes de bajo valor. Ambos tipos de datos son valiosos en la medida en que permiten a una empresa centrar su gasto publicitario en clientes de alto valor.⁶

Muchos líderes en tecnología IA, como Google, Facebook y Microsoft, han construido o adquirido sus propias redes de publicidad, de forma que pueden poseer sus propios datos valiosos. Estas empresas decidieron que poseer los propios datos compensa el coste de adquirirlos. Para otros, los datos publicitarios son menos relevantes, por lo que hacen un intercambio con el control de esos datos para evitar incurrir en el elevado gasto de recopilarlos por sí mismos; los datos de publicidad permanecen, pues, fuera de los límites de esas empresas.

Vendiendo predicciones

Google, Facebook y Microsoft, así como un puñado de empresas, disponen de datos particularmente útiles sobre las preferencias de los clientes en red. En lugar de limitarse a vender datos, estas compañías fueron un paso más allá e hicieron predicciones para los anunciantes. Por ejemplo, Google, mediante la búsqueda, YouTube, y su red de publicidad, posee abundantes datos sobre las necesidades de los usuarios. No venden datos, pero sí que venden las predicciones que los datos generan a los anunciantes como parte de un servicio combinado. Si haces publicidad a través de la red de Google, tu anuncio se muestra a aquellos usuarios a los que la red predice que es más probable influenciar con el anuncio. Hacer publicidad a través de Facebook o Microsoft produce resultados similares. Sin un acceso directo a los datos, el anunciante compra la predicción.

La unicidad de los datos es importante para crear una ventaja estratégica. Si los datos no son únicos, es difícil construir un negocio en base a las máquinas predictivas. Sin datos, no existe un camino real hacia el aprendizaje, por lo que la IA no es una parte esencial de una estrategia. Tal como mencionamos en el ejemplo de las redes de publicidad, las predicciones pueden seguir siendo útiles, pues permiten al anunciante dirigirse al cliente de mayor valor. Por consiguiente, una mejor predicción puede ayudar a una organización, incluso si los datos y predicciones no son una fuente de ventaja estratégica.⁷ Tanto

los datos como la predicción están fuera de los límites de una organización, pero esta puede seguir usando la predicción.

La principal implicación es que los datos y las máquinas predictivas son complementos, por lo que suministrar o desarrollar una IA tendrá un valor limitado, a menos que se tengan los datos para alimentarla. Y, si los datos están en poder de otros, será necesaria una estrategia para conseguirlos. Si los datos obran en poder de un proveedor monopólico o exclusivo, podemos encontrarnos con el riesgo de que ese proveedor se apropie de todo el valor de nuestra IA. Si los datos están en manos de los competidores, es posible que ninguna estrategia merezca la pena obtenerlos de ellos. Y, si los datos los tienen los consumidores, estos pueden ser intercambiados a cambio de un mejor producto o de un servicio de mayor calidad.

A pesar de todo, en algunas situaciones, es posible que tanto tú como los demás tengáis datos que sean de valor mutuo; de ahí que sea factible realizar un canje de datos. En otros casos, en cambio, los datos pueden obrar en poder de múltiples proveedores, en cuyo caso es posible que sea necesario un acuerdo más complejo o adquirir una combinación de datos y predicción. Elegir si recopilas tus propios datos y haces las predicciones o si se los compras a otros dependerá de la importancia que las máquinas predictivas tengan en tu empresa. Si la máquina predictiva es un insumo que está disponible comercialmente y puedes adquirirla, entonces puedes planteártelo como la mayoría de las empresas concibe la energía y adquirirlo del mercado, siempre que la IA no sea un elemento central de tu estrategia. Por el contrario, si las máquinas predictivas van a ser el centro de la estrategia de tu empresa, necesitarás el control de los datos para mejorar la máquina, así que tanto los datos como la máquina deberán estar en tu empresa.

Al principio de este capítulo sugerimos que una empresa emergente enfocada hacia el aprendizaje de máquina y que se dedicaba a suministrar diagnósticos médicos pasara a vender predicciones. ¿Por qué iba a estar el médico dispuesto a comprar una predicción en lugar de un diagnóstico completo? ¿Y por qué el doctor no querría

poseer la máquina predictiva y los datos? Las respuestas residen en las recompensas y las compensaciones relevantes que hemos expuesto en capítulos anteriores. Un elemento clave del trabajo de un médico es el diagnóstico, por lo que comprar la predicción no es una decisión estratégica esencial de un doctor. Los galenos continúan haciendo lo que ya hacían antes, pero añadiendo una información adicional. Si no es una decisión estratégica esencial, entonces la predicción se puede comprar sin necesidad de poseer los datos ni la predicción. Por el contrario, la esencia de una empresa emergente es la IA y la predicción que suministra valor a los clientes. Así pues, siempre que una empresa emergente posea sus propios datos y máquinas predictivas, no necesitará poseer un diagnóstico. La frontera entre la empresa emergente y el doctor es la frontera donde la IA deja de ser estratégica para ser simplemente un insumo destinado a un proceso diferente.

PUNTOS CLAVE

- Una elección estratégica clave es determinar dónde acaba tu negocio y dónde empieza el del otro, decidiendo cuáles son los límites de la empresa —por ejemplo, asociaciones de aerolíneas, externalización de la fabricación de piezas de automóviles—. La incertidumbre influye en esta elección. Dado que las máquinas predictivas reducen la incertidumbre, estas pueden influir en los límites entre tu organización y la de los demás.
- Al reducir la incertidumbre, las máquinas predictivas aumentan la habilidad de redactar contratos, aumentando a su vez el incentivo para las empresas de contratar externamente tanto los bienes de capital como la mano de obra que se centra en los datos, la predicción y la acción. Sin embargo, las máquinas predictivas reducen el incentivo para que las empresas contraten externamente la mano de obra

que se centra en el juicio. La calidad del juicio es difícil de especificar en un contrato y complicada de monitorizar. Si el juicio se pudiera especificar bien, podría ser programado y no necesitaríamos a personas que lo suministraran. Dado que es probable que el juicio sea la función clave de la mano de obra humana a medida que la IA se difunda, el empleo interno aumentará y la contratación externa descenderá.

- La IA aumentará los incentivos de poseer datos. Aun así, la contratación externa de los datos podría ser necesaria cuando las predicciones que los datos proveen no sean estratégicamente esenciales para tu organización. En tales casos, podría ser mejor comprar las predicciones directamente en lugar de adquirir los datos y después generar tus propias predicciones.

17

Su estrategia de aprendizaje

En marzo de 2017, en un discurso de presentación de su evento I/O anual, el director ejecutivo de Google, Sundar Pichai, anunció que la empresa estaba pasando de dar «prioridad a los dispositivos móviles a dar prioridad a la tecnología IA». A continuación, el director hizo una serie de pronósticos sobre varios aspectos en los que la IA tendrían repercusión: desde el desarrollo de los chips especializados para optimizar el aprendizaje de máquina al uso del aprendizaje profundo en las nuevas aplicaciones, incluidas la investigación sobre el cáncer o la colocación del asistente IA de Google en tantos dispositivos como fuera posible. El Sr. Pichai afirmó que la empresa se hallaba en plena transición de «buscar y organizar la información del mundo hacia la IA y el aprendizaje profundo».

El anuncio era más estratégico que un cambio fundamental de perspectiva. El fundador de Google, Larry Page, subrayó este camino en 2002:

No siempre producimos lo que la gente quiere. En eso es en lo que trabajamos duramente. Es realmente complicado. Para

hacerlo, tienes que ser inteligente, tienes que comprender todo lo que hay en el mundo, tienes que comprender la búsqueda. Lo que estamos intentando hacer es la inteligencia artificial... En última instancia, el motor de búsqueda llegará a ser inteligente. Y para eso trabajamos, para acercarnos cada vez más a eso».¹

En este sentido, desde hace años Google considera que está en el camino de construir inteligencia artificial. Solo recientemente la empresa ha aplicado abierta y externamente técnicas de IA en la esencia de todo lo que hace. Google no está sola en su compromiso estratégico. Aquel mismo mes, Microsoft anunció sus primeras intenciones de dar «prioridad a la IA», dejando atrás su pasado de dar «prioridad a la tecnología de dispositivos móviles» y «a la nube».² Pero ¿qué significa la noción de dar prioridad a la IA? Tanto para Google como para Microsoft, la primera parte de su cambio —dejar de dar prioridad a la tecnología móvil— nos da una pista. Dar prioridad a la tecnología móvil es trasladar el tráfico de datos a su experiencia móvil y optimizar las interfaces de los clientes en los dispositivos móviles «incluso a expensas de toda su página web y de otras plataformas». La última parte es lo que la convierte en estratégica. «Hacerlo bien en tecnología móvil» es algo a lo que aspirar, pero decir que lo harás aunque eso dañe a otros canales es un verdadero compromiso.

¿Qué significa esto en el contexto de dar prioridad a la IA? El director de investigación de Google, Peter Norving, nos da una respuesta:

Con la recuperación de información, cualquier cosa que esté por encima del 80% de memoria y precisión está bastante bien, no todas las sugerencias tienen que ser perfectas, porque el usuario puede ignorar las malas sugerencias. Con asistencia, existe una barrera mucho más alta. No usarías un servicio que hiciera una mala reserva el 20% del tiempo, o incluso el 2% del tiempo. Así pues, un asistente necesita ser mucho más

preciso y, por tanto, más inteligente, más consciente de la situación. Eso es lo que denominamos «dar prioridad a la IA».³

Esa es una buena respuesta para un científico informático, pues enfatiza el rendimiento técnico y la precisión en particular. Pero esta sentencia también dice otra cosa implícitamente: si la IA tiene prioridad —maximizar la precisión predictiva—, ¿qué es lo segundo?

La visión de los economistas nos indica que cualquier sentencia del tipo «pondremos nuestra atención en X» significa una compensación o un intercambio. Siempre se va a dar algo a cambio. ¿Qué hace falta para enfatizar la precisión predictiva sobre cualquier otra cosa? Nuestra respuesta proviene de nuestro marco económico principal: dar prioridad a la IA significa dedicar recursos a la recopilación de datos y al aprendizaje —un objetivo a largo plazo— a expensas de importantes consideraciones a corto plazo, tales como la experiencia inmediata del cliente, los ingresos y el número de usuarios.

Cierta sensación de disrupción

Adoptar una estrategia que otorgue prioridad a la IA es un compromiso para priorizar la calidad de predicción y para fomentar el proceso de aprendizaje artificial, incluso a costa de los factores cortoplacistas, tales como la satisfacción del cliente y el rendimiento operacional. Recopilar datos puede significar desarrollar una IA cuya calidad de predicción no llegue todavía a niveles óptimos. El dilema estratégico central es si priorizar ese aprendizaje o bien evitar otros los sacrificios de rendimiento que ello conlleva.

Cada empresa abordará este dilema y hará elecciones de forma diferente, pero ¿por qué Google, Microsoft y otras empresas tecnológicas están dando prioridad a la IA? ¿Es algo que otras empresas pueden aplicar? ¿O estas compañías tienen algo especial?

Un rasgo distintivo de estas empresas es que están recopilando y generando grandes cantidades de datos digitales y operando en entornos con incertidumbre, por lo que las máquinas predictivas

podrán permitir el uso extensivo de herramientas en todos los productos de sus negocios. Internamente, las herramientas que implican una predicción superior y más barata tienen demanda, además de ser una ventaja en cuanto al suministro. Estas empresas ya poseen talento interno que pueden usar para desarrollar el aprendizaje de máquina y sus aplicaciones.

Estas empresas, recuperando la analogía del maíz híbrido expuesta en el capítulo 15, son como los granjeros de Iowa, pero las tecnologías relacionadas con la IA hacen gala de otra importante característica. Dado que el aprendizaje lleva tiempo y, a menudo, deriva en un rendimiento inferior —especialmente, para los consumidores—, este comparte rasgos con lo que Clay Christensen ha definido como «tecnologías disruptivas», lo cual significa que algunas empresas ya establecidas se encontrarán con dificultades para adoptar tales tecnologías rápidamente.⁴

Consideremos una nueva versión IA de un producto existente. Para desarrollar el producto, es necesario que tenga usuarios. Los primeros usuarios del producto IA tendrán una baja experiencia de cliente, porque la IA necesita aprender. Una empresa podrá tener una sólida base de clientes y, por tanto, podrá hacer que estos usen el producto y provean datos de entrenamiento, pero es posible que los clientes estén contentos con el producto existente y que quizá no toleren que se cambie a un producto temporalmente inferior.

Se trata del clásico «dilema del innovador», con el que firmas consolidadas no desean trastocar sus relaciones con los clientes existentes, aunque el hecho de hacerlo acabe siendo beneficioso a la larga. El dilema del innovador ocurre porque, cuando las innovaciones aparecen por primera vez, puede que no sean lo bastante buenas como para servir a los clientes de las empresas consolidadas de una industria, pero sí lo bastante como para suministrar suficientes clientes a una empresa emergente en algún nicho de mercado y construir un producto. Con el tiempo, la empresa emergente adquiere experiencia. Eventualmente, dicha empresa habrá aprendido lo suficiente como para crear un producto sólido que se lleve los mejores clientes de la competencia.

Llegados a ese punto, la empresa grande quedará muy rezagada, y la empresa emergente dominará el panorama. La IA requiere aprendizaje, y las empresas emergentes podrían estar más dispuestas a invertir en este aprendizaje que sus rivales más consolidados.

El dilema del innovador no es tal cuando la empresa en cuestión se enfrenta a la dura competencia, especialmente si esa competencia proviene de nuevos participantes que no deben hacer frente a restricciones asociadas con tener que satisfacer una base de clientes existente. En esa situación, la amenaza de la competencia significa que el coste de no hacer nada es demasiado alto. Tal competencia inclina la ecuación hacia la adopción de una tecnología disruptiva rápidamente, aunque estemos hablando de una empresa consolidada. Dicho de otro modo, para tecnologías como la IA en las que el impacto potencial a largo plazo es probablemente enorme, esa sensación de disrupción puede llevar a una adopción temprana, incluso en caso de empresas establecidas.

Aprender puede requerir de una gran cantidad de datos y tiempo, antes de que las predicciones de una máquina sean fiablemente precisas. Sería en efecto algo raro que una máquina predictiva funcionara a las primeras de cambio. Aquel que venda un producto de software con tecnología IA seguramente habrá hecho previamente el trabajo sucio del entrenamiento. Pero, si deseamos gestionar la IA para un propósito esencial de nuestro propio negocio, no es probable que exista ninguna solución estándar idónea. No necesitaremos tanto un manual de usuario como un manual de entrenamiento, el cual requiere cierto recorrido para que la IA recopile datos y para que con ello mejore.

Un camino hacia el aprendizaje

El «aprendizaje con el uso» es un término que el historiador económico Nathan Rosenberg acuñó para describir el fenómeno por el que las empresas mejoran su diseño de producto mediante interacciones con los usuarios.⁶ Sus principales aplicaciones tienen que ver con el

rendimiento de los aviones, cuyos diseños iniciales más conservadores dieron pie a unos mejores diseños con mayor capacidad y eficiencia a medida que los fabricantes de aviones aprendían con el uso adicional. Los fabricantes que empezaron pronto partieron con una ventaja: pudieron aprender más. Por supuesto, tales curvas de aprendizaje dieron una ventaja estratégica en una variedad de contextos, siendo especialmente importantes en el ámbito de las máquinas predictivas, que, después de todo, se basan en el aprendizaje artificial.

Hasta ahora, en este libro no hemos dedicado mucho tiempo a distinguir entre los distintos tipos de aprendizaje que componen el aprendizaje artificial. Nos hemos centrado principalmente en el «aprendizaje supervisado». Se usa esta técnica cuando ya se dispone de una buena cantidad de datos de lo que se está intentando predecir; por ejemplo, cuando se dispone de millones de imágenes en las que se sabe si se muestra un gato o un tumor, y se entrena a la IA basándose en ese conocimiento. El aprendizaje supervisado es una parte esencial de lo que hacemos los profesores: presentamos un nuevo material y mostramos a nuestros estudiantes qué problemas presenta y sus soluciones.

En cambio, ¿qué sucede cuando no disponemos de suficientes datos sobre lo que se desea predecir, pero podemos decir, *a posteriori*, lo acertado que estuvimos? En esa situación, como expusimos en el capítulo 2, los científicos informáticos desarrollan técnicas de «aprendizaje de refuerzo». Muchos niños y animales jóvenes aprenden de esa manera. El psicólogo Pavlov tocaba una campanilla cada vez que daba a los perros un obsequio y, después, descubrió que tocar la campanilla activaba una salivación en esos animales a modo de respuesta. Los perros aprendieron a asociar el toque de la campanilla con la recepción de comida y que ese ruido predecía la cercanía de la comida, preparando sus respuestas corporales en consonancia.

En el ámbito de la IA, gran parte de los progresos realizados en el aprendizaje de refuerzo se han centrado en enseñar a las máquinas a jugar. DeepMind incorporó en su IA una serie de controles de videojuegos como el Breakout y «recompensó» a la IA por obtener una alta

puntuación sin dar ninguna otra instrucción. La IA aprendió a jugar un montón de juegos Atari mejor que los jugadores humanos. A esto le llamamos «aprendizaje con el uso». Las IA jugaron este juego miles de veces y aprendieron a jugar mejor, igual que haría una persona, excepto que la IA podía jugar más partidas y hacerlo más rápidamente que una persona.⁷

El aprendizaje se produce cuando la máquina hace ciertos movimientos y después usa los datos de esos movimientos junto con la experiencia adquirida —de los movimientos y las puntuaciones resultantes— para predecir qué movimientos conllevarán mayores aumentos en la puntuación. La única forma de aprender es jugando. Sin un camino o una trayectoria hacia el aprendizaje, no se juega bien ni se mejora con el tiempo. Pero tales caminos hacia el aprendizaje son costosos.

Cuándo se debe salir al mundo real

Quienes estén familiarizados con el desarrollo del software sabrán que la codificación necesita test exhaustivos para localizar fallos y errores. En algunas situaciones, las empresas lanzan el software al mercado para que los usuarios les ayuden a encontrar los errores que vayan surgiendo en el uso cotidiano. Ya sea mediante el *dogfooding* —imponer que se usen internamente versiones tempranas del software— o mediante «pruebas beta» —incitar a los que adoptaron la versión anticipadamente a que pongan a prueba el software—, estas formas de aprendizaje con el uso implican una inversión a corto plazo en el aprendizaje para que el producto mejore con el tiempo.

Este coste de entrenamiento a corto plazo para un beneficio a largo plazo es similar a la forma en que las personas aprenden a mejorar en su trabajo. A título de ejemplo, si bien no es necesario demasiado entrenamiento para empezar a trabajar como empleado en un McDonald's, los nuevos empleados son más lentos y cometen más errores que sus compañeros más experimentados. Los nuevos mejoran a medida que van sirviendo a más clientes.

También los pilotos de aerolíneas comerciales continúan aprendiendo de su experiencia diaria. El 15 de enero de 2009, a pesar de que, tras topar con una bandada de gansos canadienses, el vuelo 1549 de US Airways se quedó sin potencia motriz, el capitán Chesley «Sully» Sullenberger consiguió aterrizar milagrosamente en el río Hudson, salvando la vida de los 155 pasajeros. La mayoría de los reporteros atribuyeron esa actuación a su experiencia, pues llevaba un total de 19.663 horas de vuelo, incluidas 4.765 con un Airbus A320. El propio Sully comentaba al respecto: «Una forma de analizar lo que sucedió es que durante cuarenta y dos años he estado haciendo pequeños depósitos regulares en ese banco de la experiencia, la formación y el entrenamiento. Y el 15 de enero, el saldo era lo suficientemente alto como para hacer una gran extracción».⁸ Sully y todos sus pasajeros se beneficiaron de que el piloto hubiera llevado antes a miles de personas en distintos aviones.

La diferencia entre las habilidades de los nuevos cajeros y los pilotos en cuanto a lo que constituye algo «lo bastante bueno como para empezar» se basa en la tolerancia al error. Obviamente, nuestra tolerancia es mucho menor en el caso de los pilotos. Nos reconforta que el certificado de un piloto esté regulado por el departamento de Transporte y la Administración Federal de Aviación, que requiere un mínimo de mil quinientas horas de vuelo, quinientas horas de vuelo en travesía, cien horas de vuelo nocturno y setenta y cinco horas de operación con instrumentos, aunque los pilotos continúan aprendiendo de la experiencia cotidiana. Tenemos diferentes definiciones de «lo bastante bueno» en lo referente a cuánto entrenamiento requieren las personas para efectuar cada trabajo. Y lo mismo es aplicable al caso de las máquinas.

Las empresas diseñan sistemas para entrenar a los nuevos empleados hasta que estos sean lo bastante buenos y, acto seguido, los ponen a trabajar, aun sabiendo que mejorarán a medida que aprendan de la experiencia. Pero determinar cuándo se es «lo bastante bueno» es una decisión clave. En el caso de las máquinas predictivas, esta puede ser una decisión estratégica de gran calado respecto al tiempo: cuándo se debe pasar del entrenamiento interno al aprendizaje en la práctica.

No existen respuestas preestablecidas de cuánto tiempo se necesita para llegar a ser «lo bastante bueno» en el ámbito de las máquinas predictivas, solo intercambios. El éxito con las máquinas predictivas requerirá tomarse estos intercambios en serio y analizarlos desde un enfoque estratégico.

En primer lugar, ¿qué tolerancia al error tiene la gente? Pues la verdad es que tenemos una alta tolerancia al error con algunas máquinas predictivas y una tolerancia baja con otras. Por ejemplo, la aplicación Inbox (bandeja de entrada) de Google lee nuestro correo electrónico, usa la IA para predecir cómo queremos responder y genera tres cortas respuestas entre las que podemos elegir. Muchos usuarios afirman que disfrutaban al usar esta aplicación, a pesar de que tiene un índice de error del 70% —en el momento de escribir estas líneas, la respuesta generada por IA solo es útil alrededor del 30% de las veces—. La razón de esta alta tolerancia al error es que el beneficio de composición y escritura reducida compensa el coste de suministrar sugerencias y malgastar espacio en pantalla cuando la respuesta corta predicha es errónea.

En contraste, tenemos baja tolerancia al error en el apartado de la conducción autónoma. La primera generación de vehículos autónomos, de la que Google fue en gran medida precursora, fue entrenada usando a conductores humanos especialistas que conducían un número limitado de vehículos durante cientos de miles de kilómetros, algo muy similar a cómo un padre supervisa a su hijo adolescente en sus primeros esarceos automovilísticos. Tales conductores especialistas proveen un entorno seguro de entrenamiento, pero también están sumamente limitados. La máquina solo aprende unas pocas situaciones. Un conductor puede tener que hacer muchos miles de kilómetros en multitud de entornos y situaciones antes de aprender cómo afrontar escenarios o situaciones poco comunes que comportan accidentes. En cuanto a los vehículos autónomos, las carreteras reales son desagradables y despiadadas, precisamente porque en ellas pueden darse situaciones implacables causadas por personas.

En segundo lugar, ¿en qué medida es importante obtener los datos de usuarios en el mundo real? Comprendiendo que el entrenamiento puede llevar un tiempo prohibitivamente largo, Tesla ha desarrollado funciones de vehículos autónomos para todos sus modelos recientes. Estas funciones incluyen una serie de sensores que obtienen datos del entorno, así como datos de conducción, los cuales se cargan en los servidores de aprendizaje artificial de Tesla. En un lapso muy breve de tiempo, Tesla puede obtener datos de entrenamiento solo observando cómo los conductores conducen sus coches. Cuantos más vehículos de Tesla circulen por las carreteras, más podrán aprender las máquinas de Tesla. No obstante, además de recoger datos pasivamente a medida que los humanos conducen sus coches, la empresa necesita los datos de conducción autónoma para comprender cómo están operando sus sistemas autónomos. Para ello, la empresa necesita que sus coches conduzcan autónomamente, de forma que se pueda valorar el rendimiento, y también analizar cuándo un conductor humano, cuya presencia y atención se requieren, opta por intervenir. El objetivo último de Tesla no es producir un copiloto o un adolescente que conduce bajo supervisión, sino un vehículo completamente autónomo, y ello requiere llegar a un punto en el que las personas se sientan cómodas en un coche autopilotado.

Y ahí subyace una relación de compensación capciosa. Para ser mejor, Tesla necesita que sus máquinas aprendan en situaciones reales. Pero poner sus coches actuales en situaciones reales significa suministrar a sus clientes un sistema de conducción relativamente inexperto, aunque quizá tan bueno o mejor que el de muchos conductores jóvenes humanos. Aun así, este método es mucho más arriesgado que las pruebas beta para ver si Siri o Alexa comprendieron qué les dijiste o si el Inbox de Google predice correctamente tu respuesta a un correo electrónico. En el caso de Siri, Alexa o el Inbox de Google, un error significa una experiencia de usuario de menor calidad, pero en el caso de los vehículos autónomos un error significa poner vidas en riesgo.

Esa experiencia puede ser terrorífica.⁹ Un coche puede salir de una autopista sin aviso o pisando los frenos al confundir un paso

subterráneo con una obstrucción. Los conductores nerviosos pueden optar por no usar las funciones autónomas y, en el proceso, impedir la capacidad de aprendizaje de Tesla. Aunque la empresa pueda convencer a algunas personas para que sean sujetos de pruebas beta, ¿son esas las personas que la empresa realmente necesita? Después de todo, un sujeto de prueba beta para conducción autónoma puede ser alguien al que le guste un riesgo mayor que el conductor corriente. En ese caso, ¿a quién está tomando la empresa como referencia para entrenar a sus máquinas? Las máquinas aprenden más rápido con más datos y, cuando estas se despliegan en el mundo real, generan más datos. Sin embargo, en el mundo real pueden suceder cosas negativas que dañen la imagen de la empresa. Sacar productos al mundo real tempranamente acelera el aprendizaje, pero comporta riesgos de deterioro de la marca —y tal vez al cliente—; sacarlos más tarde ralentiza el aprendizaje, pero concede más tiempo para mejorar el producto internamente y protege la marca —y, de nuevo, tal vez al cliente—.

En el caso de algunos productos, como el Inbox de Google, la respuesta al intercambio parece clara, porque el coste del mal rendimiento es bajo y los beneficios de aprender del uso de los clientes son elevados. Tiene sentido sacar ese tipo de productos al mundo real tempranamente. En cambio, en el caso de otros productos, como los coches, la respuesta es menos clara. A medida que más empresas de todos los sectores industriales busquen sacar partido del aprendizaje artificial, las estrategias asociadas al manejo de este intercambio se volverán cada vez más importantes.

Aprender por simulación

Un paso intermedio para suavizar este intercambio es usar entornos simulados. Cuando los pilotos humanos se están entrenando, antes de llevar los mandos de un avión real en vuelo, pasan cientos de horas en simuladores muy sofisticados y realistas. Un método similar está disponible para la IA. Google entrenó al Alpha Go de DeepMind

para que derrotara a los mejores jugadores de Go del mundo, no solo observando miles de partidas jugadas por humanos, sino también jugando contra otra versión de sí mismo.

Una forma de esta metodología es el denominado «aprendizaje artificial confrontativo», el cual contrapone a la IA principal y su objetivo a otra IA que intenta hacer fracasar dicho objetivo. Por ejemplo, los investigadores de Google hicieron que una IA enviara mensajes a otra usando un proceso de encriptación. Las dos IA compartían una clave para codificar y decodificar el mensaje. Una tercera IA —el adversario— tenía los mensajes, pero no la clave, e intentaba decodificarlos. Con muchas simulaciones, el adversario entrenó a la IA principal para que se comunicara en formas que son difíciles de decodificar sin una clave.¹⁰ Tales métodos de aprendizaje simulado no se pueden realizar sobre el terreno, sino que requieren algo similar a un laboratorio que produzca un nuevo algoritmo de aprendizaje artificial, que después será copiado y transferido a los usuarios. La ventaja es no se entrena a la máquina en el mundo real, por lo que se mitiga el riesgo de empeorar la experiencia del usuario o incluso de afectar negativamente a los propios usuarios. El inconveniente es que es posible que las simulaciones no suministren una retroalimentación suficientemente copiosa; lo que reduce, pero no elimina, la necesidad de sacar al mercado la IA tempranamente. Antes o después, deberás dejar que la IA dé el salto al mundo real.

Aprender en la nube frente a aprender sobre el terreno

Aprender en el mundo real mejora la IA. La empresa puede usar los resultados obtenidos en la realidad que experimenta la máquina predictiva para mejorar las predicciones de cara a la próxima vez. A menudo, la empresa recopila datos en el mundo real, que afinan la máquina antes de que esta produzca un modelo de predicción actualizado.

El Autopilot de Tesla nunca aprende una tarea con los consumidores reales. Cuando se halla sobre el terreno, la máquina envía datos a la nube de computación de Tesla, que después son agregados y usados para actualizar el Autopilot. Solo entonces la empresa saca una nueva versión de Autopilot. El aprendizaje tiene lugar en la nube.

Este método estándar tiene la ventaja de que protege a los usuarios de las versiones poco entrenadas. La parte negativa, sin embargo, es que la IA ordinaria que reside en los dispositivos no puede tener en consideración condiciones locales rápidamente cambiantes o, en el mejor de los casos, solo puede hacerlo cuando esos datos se integran en una nueva generación. De ahí que, desde el punto de vista del usuario, las mejoras lleguen a trompicones.

En cambio, imaginemos ahora que la IA pudiera aprender en el dispositivo y mejorar en ese entorno; en tal caso, podría responder más rápidamente a las condiciones locales y optimizarse a sí misma en diferentes entornos. En situaciones donde las cosas cambian radicalmente es beneficioso mejorar las máquinas predictivas dentro de los propios dispositivos. Por ejemplo, en aplicaciones como Tinder —la popular aplicación geosocial en la que los usuarios seleccionan una opción arrastrando a la izquierda en caso de «no» o a la derecha en caso de «sí»—, los usuarios toman muchas decisiones rápidamente, lo cual puede alimentar a las predicciones de manera inmediata para determinar qué citas o encuentros potenciales se deben mostrar a continuación. Los gustos son específicos de cada usuario y cambian con el tiempo, tanto a lo largo del año como durante un mismo día. En la medida en que las personas sean similares y tengan preferencias estables, enviar datos a la nube y actualizarlos funcionará bien. Y en la medida en que los gustos de un individuo sean idiosincráticos y muy cambiantes, la capacidad de ajustar las predicciones a nivel del dispositivo resultará útil.

Las empresas deben sopesar qué tiempo necesitan para usar la experiencia de una máquina predictiva en el mundo real para generar nuevas predicciones. Si se usa esa experiencia inmediatamente, la IA se adapta más rápidamente a los cambios en las condiciones locales, pero en detrimento de la garantía de calidad.

Permiso para aprender

Aprender suele requerir de clientes dispuestos a suministrar datos. Si la estrategia implica hacer algo a expensas de otros, en el ámbito de la IA pocas empresas se han comprometido de forma tan temprana y decidida como Apple. En una sección especial dedicada a la privacidad de la página web de Apple, Tim Cook escribió: «En Apple, su confianza lo es todo para nosotros. Por esa razón respetamos su privacidad y la protegemos con fuertes cifrados, además de aplicar estrictas políticas que rigen la manipulación de los datos».¹¹

Y continuó:

«Hace pocos años, los usuarios de internet empezaron a darse cuenta de que, cuando un servicio en línea era gratuito, la persona ya no era el usuario, sino el producto. Pero en Apple creemos que una gran experiencia para el usuario no debería ir en detrimento de su privacidad.

Nuestro modelo de negocio es muy directo: vendemos grandes productos. No construimos un perfil basándonos en el contenido de sus correos electrónicos o de sus hábitos de navegación para después venderlo a los anunciantes. No «monetizamos» la información que usted almacena en su iPhone o en su iCloud. Y no leemos su correo electrónico ni sus mensajes para conseguir información y comerciar con usted. Nuestro software y nuestros servicios están diseñados para mejorar nuestros dispositivos. Simple y llanamente».¹²

Apple no tomó esta decisión debido a una regulación gubernamental. Hubo quienes afirmaron que Apple había tomado esa decisión porque, supuestamente, se hallaba rezagada respecto a Google y Facebook en el desarrollo de la IA. Ninguna empresa, y desde luego Apple tampoco, podía renunciar a la IA. Ese compromiso iba a complicar más su trabajo. La empresa planeaba desarrollar la IA de una

forma que respetara la privacidad. Supone hacer una gran apuesta estratégica pensar que los consumidores van a querer controlar sus propios datos. Ya sea por privacidad o por seguridad, Apple apostó que su compromiso hiciera más probable, y no menos, que los consumidores permitieran que se integrara la IA en sus dispositivos. Apple no está solo en la suposición de que proteger la privacidad dará sus beneficios. Salesforce, Adobe, Uber, Dropbox, entre otras empresas, han invertido grandes cantidades en privacidad.

Esta apuesta es estratégica. Muchas otras empresas, como Google, Facebook y Amazon, han escogido un camino distinto, diciendo a los usuarios que usaran sus datos para suministrar mejores productos. El foco de Apple en la privacidad limita los productos que puede ofrecer. Por ejemplo, tanto Apple como Google disponen de sistemas de reconocimiento facial integrados en sus servicios de fotografía. Para que a los consumidores les resulten útiles, los rostros deben ser etiquetados. Google hace tal proceso preservando las etiquetas, con independencia del dispositivo, dado que el reconocimiento tiene lugar en los servidores de Google. Apple, en cambio, a causa de su compromiso de privacidad, ha optado por hacer que el reconocimiento se produzca a nivel del dispositivo; lo que significa que, si etiquetas los rostros de personas que conoces en tu Mac, las etiquetas no se transferirán a tu iPhone ni a tu iPad. No es de extrañar que ello haga que las inquietudes sobre la privacidad y la usabilidad del consumidor topen con un obstáculo (desconocemos cómo Apple aborda estos temas en el momento de escribir este libro).

Desde luego, no sabemos qué sucederá en la práctica. En cualquier caso, nuestra perspectiva de economistas nos deja claro que las relativas compensaciones asociadas al intercambio de inquietudes sobre privacidad a cambio de precisión predictiva servirán de guía para tomar la última decisión estratégica. Una mejora de la privacidad podría autorizar a las empresas para que aprendieran sobre los consumidores, pero también podría significar que ese aprendizaje no resultara demasiado útil.

La experiencia es el nuevo recurso escaso

La aplicación de navegación Waze recopila datos de otros usuarios de Waze para predecir la ubicación de los problemas de tráfico, además de que encuentra la ruta más rápida para un usuario particular. Si eso fuera todo lo que hace, no habría problema. No obstante, la predicción altera el comportamiento humano, que es para lo que ha sido diseñado Waze. El que la máquina reciba información de muchos usuarios puede distorsionar sus predicciones.

Para Waze, el problema reside en que sus usuarios seguirán esa guía para evitar los problemas de tráfico, tal vez yendo por calles adyacentes. A menos que Waze se ajuste a ese hecho, nunca se le avisará de que el problema de tráfico se ha resuelto y de que la ruta habitual vuelve a ser la más rápida. Por tanto, para superar ese obstáculo, la aplicación deberá enviar a algunos conductores humanos de vuelta al atasco de tráfico para ver si sigue existiendo. Hacer esto presenta un obvio inconveniente: los humanos hacia allí dirigidos podrían convertirse en corderos sacrificados para beneficiar a la mayoría. No es de extrañar que tal situación degrade la calidad del producto para esos usuarios.

No existen vías sencillas para superar la compensación que surge cuando la predicción altera el comportamiento de la mayoría, negando así a la IA la información que necesita para conformar una predicción correcta. En ese instante, las necesidades de la mayoría superan a las necesidades de la minoría o de uno solo. Pero, ciertamente, ese no es un modo de pensar reconfortante acerca de la gestión de las relaciones con los usuarios.

En ocasiones, para mejorar los productos, especialmente cuando estos implican «aprender con el uso» es importante «sacudir» el sistema, de forma que los consumidores realmente experimenten algo nuevo de lo que la máquina pueda aprender. Los clientes a los que se dirige hacia ese nuevo entorno suelen tener una peor experiencia, pero el resto se beneficia de esas experiencias. En cuanto a las pruebas beta, el intercam-

bio es voluntario, dado que los clientes optan por las primeras versiones, pero esta prueba puede atraer a los clientes que no usan el producto de la misma forma en que lo harían sus clientes generales. Para adquirir experiencia sobre todos nuestros clientes, es posible que, a veces, sea necesario degradar el producto para algunos usuarios y así obtener comentarios y una retroalimentación que beneficie a todo el mundo.

Las personas también precisan experiencia

La escasez de experiencia se vuelve más relevante cuando nos planteamos la experiencia de nuestros recursos humanos. Si las máquinas adquieren experiencia, tal vez los humanos no lo hagan. Recientemente, ciertos círculos han manifestado su inquietud por el hecho de que la automatización pueda descualificar a las personas.

En 2009, el vuelo 447 de Air France se estrelló en el Atlántico cuando hacía la ruta entre Río de Janeiro y París. La emergencia comenzó con el mal tiempo, pero empeoró exponencialmente cuando el piloto automático del avión se apagó. Según los informes del suceso, a diferencia del capitán Sully cuando pilotaba el avión de US Airways, a los mandos del avión un relativamente inexperto piloto manejó mal la situación. Cuando el piloto más experimentado se puso a los mandos —pues había estado durmiendo—, fue incapaz de evaluar adecuadamente qué estaba ocurriendo.¹⁴ El piloto experimentado había dormido poco la noche antes, pero el punto decisivo fue que el piloto menos avezado llevaba casi tres mil horas de vuelo, pero no era una experiencia de calidad, pues la mayor parte del tiempo había estado volando con el piloto automático.

La automatización de la aviación se ha vuelto moneda común: una reacción a la evidencia que mostraba que la mayoría de los accidentes de avión desde la década de los años setenta se debían a errores humanos, por lo que se decidió eliminar a los humanos del circuito de control. Si embargo, la punzante e involuntaria consecuencia es

que los pilotos humanos acopiaron menos experiencia y bajara su nivel de pilotaje.

Para el economista Tim Hartford, la solución es obvia: la proporción de automatización debe reducirse. Lo que debe automatizarse, argumenta, son las situaciones rutinarias, por lo que la intervención humana se requiere en las situaciones más extremas. Si la forma de aprender a tratar con lo extremo es tener mucha práctica con lo ordinario, entonces ahí reside el problema. El avión de Air France se enfrentó a una situación extrema sin la debida atención de una mano experimentada.

Hartford recalca que la automatización no siempre conduce a este dilema:

«Existen muchas situaciones en las que la automatización no crea tal paradoja. Una página web de servicio al cliente puede ser capaz de manejar las quejas y las peticiones rutinarias de forma que el personal se ahorre el trabajo repetitivo y pueda hacer un mejor trabajo para los clientes en cuestiones más complejas. Los pilotos automáticos y la asistencia más sutil del pilotaje por mandos electrónicos no liberan a la tripulación de concentrarse en lo que es esencial, sino que evitan que el personal se quede dormido en los controles, figurada o literalmente. Ese mismo año 2009, ocurrió un incidente notable cuando dos pilotos dejaron que su piloto automático se pasara de largo el aeropuerto de Minneapolis en más de 150 kilómetros, porque estaban mirando sus ordenadores portátiles.¹⁵

No es de extrañar que otros ejemplos que hemos expuesto en este libro tiendan a adscribirse a la categoría de la aviación en lugar de a la de quejas del servicio de atención al cliente, incluyendo todo el sector de coches autopilotados. ¿Qué hay que hacer si la mayor parte del tiempo no conducimos nuestro coche y este toma el control cuando se presenta un evento extremo? ¿Qué harían nuestros hijos?

Las soluciones pasan por asegurar que las personas adquieran y retengan habilidades, reduciendo la cantidad de automatización para proveer tiempo al aprendizaje humano. En efecto, la experiencia es un recurso escaso, del que se necesita destinar cierta cantidad a las personas para evitar su descualificación.

La lógica inversa también es cierta. Para entrenar a las máquinas predictivas, también resulta valioso hacer que aprendan a través de la experiencia de eventos potencialmente catastróficos. Pero, si ponemos a una persona en el bucle, ¿cómo emergerá la experiencia de la máquina? Así pues, otro compromiso para generar un camino hacia el aprendizaje reside en equilibrar la experiencia humana con la artificial.

Estos intercambios revelan las implicaciones de las declaraciones en torno al liderazgo y a dar prioridad a la IA de Google, de Microsoft y de otras compañías. Las empresas están dispuestas a invertir en datos para ayudar a sus máquinas a que aprendan. Mejorar las máquinas predictivas tiene prioridad, aun cuando eso requiera degradar la calidad de la experiencia inmediata del cliente o la formación de los empleados. La estrategia de datos es clave para la estrategia de la IA.

PUNTOS CLAVE

- Cambiar la estrategia para dar prioridad a la IA significa degradar la prioridad previa. En otras palabras, dar prioridad a la IA no es una palabra de moda, sino que representa un intercambio real. Una estrategia de prioridad a la IA consiste en maximizar la precisión de la predicción como objetivo central de la organización, aunque eso signifique comprometer otras metas, como maximizar los beneficios, el número de usuarios o la experiencia de estos.
- La IA puede llevar a la disrupción, porque las empresas consolidadas suelen tener incentivos económicos menores que las empresas emergentes para adoptar esa tecnología. Los productos activados por IA suelen ser inferiores al principio,

ya que lleva tiempo entrenar a una máquina predictiva para que rinda tan bien como un dispositivo codificado que sigue las instrucciones humanas, en lugar de aprender por su cuenta. No obstante, una vez desplegada, la IA puede continuar aprendiendo y mejorando, dejando atrás los productos no inteligentes de los competidores. Para las empresas establecidas resulta tentador adoptar una postura expectante, quedándose al margen y observando los avances de la IA aplicada a su industria. Esa táctica puede funcionar para algunas empresas, pero otras tendrán dificultades para ponerse al día cuando la competencia se adelante en las posibilidades y el despliegue de sus herramientas de IA.

- Otra decisión estratégica concierne al tiempo: cuándo se deben lanzar al mercado las herramientas de IA. Inicialmente, las herramientas de IA son entrenadas internamente, sin que medien los clientes. Sin embargo, estas máquinas aprenden más rápido cuando se les da un uso comercial, porque están expuestas a condiciones operativas reales y, a menudo, a mayores volúmenes de datos. El beneficio de la salida al mercado temprana es un aprendizaje más rápido y el inconveniente es un mayor riesgo —riesgo para la seguridad de la marca o del cliente exponiendo a estos a una IA inmadura que no está adecuadamente entrenada—. En algunos casos, tales como el Inbox de Google, el intercambio es claro, pues aquí los beneficios de un aprendizaje más rápido superan el inconveniente de un mal rendimiento. Pero en otros casos, tales como la conducción autónoma, el intercambio es más ambiguo, dada la cuantía del premio por actuar prematuramente con un producto comercial en comparación con el alto coste de un error si el producto sale al mercado antes de estar listo.