

Administración de proyectos de aprendizaje automático

Equilibre potencial y contención

Dr. V.M. Megler

Febrero de 2019



Avisos

Los clientes son responsables de realizar sus propias evaluaciones de la información contenida en este documento. Este documento: (a) solo tiene fines informativos, (b) representa las prácticas y las ofertas de productos actuales de AWS, que están sujetas a cambios sin previo aviso, y (c) no crea ningún compromiso ni garantía de AWS y sus empresas afiliadas, proveedores o licenciantes. Los productos o servicios de AWS se proporcionan "tal cual", sin garantías, representaciones ni condiciones de ningún tipo, ya sean explícitas o implícitas. Las responsabilidades y obligaciones de AWS con sus clientes quedan supeditadas a los acuerdos de AWS, y este documento no conforma ni modifica ningún acuerdo entre AWS y sus clientes.

© 2019, Amazon Web Services, Inc. o sus empresas afiliadas. Todos los derechos reservados.

Contenido

Introducción	1
Inteligencia artificial y aprendizaje automático: un (muy) breve resumen de la situación actual.....	2
Proyectos de AA, no su proyecto tradicional de software	4
Investigación versus desarrollo	4
Evaluación del valor económico	7
Compruebe los supuestos	9
Calidad de los datos	11
Documentar el flujo y el catálogo de datos	11
Estimación del impacto de la calidad de los datos	14
Estrategias para aplicar.....	17
Dotar al proyecto de personal.....	17
Evaluación del valor económico	19
Usar tableros de control para gestionar y mitigar riesgos	21
Invertir con incrementos graduales	29
Desde la investigación a la producción	31
Pasar de la investigación al desarrollo	31
Modelo de AA como parte del ecosistema de software	33
Conclusión	34
Revisiones del documento	34
Apéndice: ejemplos de tableros de control.....	35
Contexto del proyecto	35
Finanzas	36
Procesos de proyectos.....	37
Calidad de los datos.....	38
Resumen	39

Resumen

En la actualidad, muchas empresas desean crear aplicaciones que utilicen aprendizaje automático (AA). En este documento se describen algunas prácticas recomendadas para la administración de proyectos de aprendizaje automático y se ofrecen métodos para comprender, administrar y mitigar los riesgos con los que algunas organizaciones podrían enfrentarse en relación con la entrega de estos sistemas complejos.

Los destinatarios previstos de este documento son partes interesadas en el negocio, directores, científicos de datos e ingenieros de desarrollo de software.

Introducción

En la actualidad, muchas organizaciones desean crear aplicaciones que utilicen aprendizaje automático (AA). El 86 % de los responsables de la toma de decisiones vinculadas con la ciencia de datos que forman parte de la lista Global 2000 cree que, actualmente, el aprendizaje automático tiene un impacto en sus sectores. Sin embargo, a muchas empresas les preocupa que solo una fracción de sus proyectos de AA tenga un impacto en el negocio.¹ En algunos casos, las inversiones realizadas en los proyectos de AA se cuestionan y dichos proyectos se abandonan cuando la implementación no coincide con la visión.²

Al momento de crear el plan para su proyecto de aprendizaje automático, es importante considerar algunas de las recientes buenas prácticas. Mediante estas buenas prácticas, es posible ubicar los proyectos de AA en un contexto económico para que usted pueda identificar, cuantificar y administrar el impacto de su proyecto en el negocio. A partir de ellas también se obtienen métodos que ayudan a comprender, administrar y mitigar los riesgos que la organización podría enfrentar mientras entrega su complejo sistema de AA y que podrían dificultar el logro de sus objetivos empresariales. Estas buenas prácticas recomendadas, a las que se hace referencia como *vallas de contención para proyectos de AA*, son una ayuda para que pueda mejorar la comunicación entre los profesionales de AA y las partes interesadas en el negocio, que son los responsables financieros de los costos y los beneficios de su sistema mediante el uso de métodos de administración conocidos.

Las vallas de contención para proyectos de AA aumentan las probabilidades de éxito porque:

- Ubican el proyecto de AA en un contexto económico, identifican los beneficios esperados y equilibran con sus costos y riesgos
- Se enfocan en los problemas que se encuentran frecuentemente en proyectos de AA
- Permiten identificar riesgos de manera anticipada para poder realizar tareas de administración y mitigación con posterioridad
- Proporcionan transparencia en los controles del proyecto
- Permiten que los ejecutivos revisen la compensación entre riesgo y beneficios

Si bien estos métodos son más aplicables en organizaciones consolidadas de mayor tamaño o en proyectos de AA de gran envergadura con potencial para generar un impacto amplio, también pueden resultar útiles a cualquier organización que esté considerando implementar un proyecto de AA. Las obligaciones relacionadas con la implementación de la tecnología pueden variar en función del proyecto, la empresa y las necesidades de las partes interesadas.

Inteligencia artificial y aprendizaje automático: un (muy) breve resumen de la situación actual

El potencial del aprendizaje automático (AA) y la inteligencia artificial (IA) se ha debatido ampliamente. Proyectos exitosos recientes que se describen en diarios populares incluyen estos temas del artículo "It Was a Big Year for A.I.":³

- La IA detectó un sistema solar de ocho planetas
- Venza al campeón mundial de Go
- Profesionales de póker vencidos en No-Limit Texas Hold'Em
- Dos agentes de IA, Bob y Alice, empezaron a hablar en inglés, pero luego... desarrollaron su propio idioma para comunicarse
- ... Y la IA se enseñó a sí misma a programar

Sin embargo, la industria del AA está empezando a comprender la necesidad de contar con un nivel mayor de *disciplina ingenieril* en torno a esta tecnología. Tal como se observó en un informe reciente del Consejo Nacional de Ciencia y Tecnología (NTSC), "Actualmente, la IA está basada en un conjunto de métodos y estrategias independientes, donde cada uno resulta útil para diferentes tipos de aplicaciones".⁴ En particular, el informe define la opinión pública en relación con la IA y el AA de la siguiente manera:

- *IA (o AA) limitada*: áreas de aplicación específicas, como videojuegos de estrategia, traducción entre idiomas, vehículos autónomos y reconocimiento de imágenes. En esta área, "se lograron avances importantes", entre los que se incluyen desafíos técnicos específicos relevantes, como ganar al Jeopardy. Sin embargo, la transferencia de dicho conocimiento a otras áreas se identificó como un desafío.
- *IA general*: demuestra un comportamiento aparentemente inteligente, al menos tan avanzado como el de una persona, en una amplia gama de tareas cognitivas. Esta capacidad aún se encuentra muy lejos en el futuro.

Si bien algunos problemas en áreas de aplicación específicas son una buena opción para el AA, otros lo son en menor medida. Pese a que este panorama pueda cambiar con el transcurso del tiempo, el AA logra mejores resultados cuando existe una buena correspondencia entre un problema específico, una estrategia o tecnología de AA específica y la existencia de un conjunto específico de datos que se adapte al problema y a la estrategia.

Existe una creciente convicción de que las características que hacen que un determinado problema sea un buen candidato para técnicas de AA aún no están bien definidas ni comprendidas. Líderes del campo de la IA expresaron esta misma opinión, por ejemplo:

- "En la actualidad, la implementación de la IA, especialmente en las áreas de aprendizaje automático con gran crecimiento, puede llegar a ser tanto arte como ciencia. Algunos aspectos de la implementación no están respaldados por una teoría bien desarrollada, sino que dependen del juicio intuitivo y de las pruebas que realizan los profesionales. Si bien esto no es inusual en nuevas áreas de la tecnología, sí limita la aplicación de la tecnología en la práctica".⁵ – NSTC
- "Resulta que la tecnología de la AI es complicada, más de lo que pensaba".⁶ – Andrew Ng, cofundador de Coursera, jefe científico de Baidu
- "Por lo tanto, de la misma manera en la que los humanos construyeron edificios y puentes antes de la aparición de la ingeniería civil, las personas están creando sistemas de inferencias y toma de decisiones con escala social que incluyen máquinas, individuos y el entorno. Al igual que los primeros edificios y puentes que a menudo se desplomaban (de maneras inesperadas y con consecuencias trágicas), muchos de los sistemas de inferencias y toma de decisiones con escala social están mostrando defectos conceptuales graves... Lo que nos está faltando es una disciplina ingenieril con sus principios de análisis y diseño".⁷ – Prof. Michael Jordan, UC Berkeley

La adaptación e implementación de nuevas prácticas recomendadas en proyectos de AA puede ayudar a reducir la brecha entre los proyectos de AA y las disciplinas ingenieriles. Mejores procesos para proyectos, incluidos aquellos que se describen en este documento técnico, pueden ayudarlo a identificar y administrar de mejor manera los riesgos de sus proyectos de AA.

Proyectos de AA, no su proyecto tradicional de software

Los proyectos de aprendizaje automático tienen algunos aspectos que suelen diferenciarlos de los proyectos tradicionales de ingeniería de software. Algunos de estos aspectos incluyen:

- Si el proyecto de AA se encuentra actualmente en una etapa de investigación o de desarrollo
- Cuál es el valor económico esperado del proyecto de AA
- Verificación de que los supuestos del proyecto de AA sean válidos

Investigación versus desarrollo

En los proyectos de aprendizaje automático, la eficacia del proyecto depende profundamente de la naturaleza, la calidad y el contenido de los datos, y de cómo se aplican al problema en cuestión. A menudo, la primera pregunta que se debe responder en relación con proyectos de AA es: *¿Es posible utilizar estos datos para mejorar los resultados en [proceso empresarial específico]?*

Para poder responder esta primera pregunta es necesario hacer un poco de investigación: *¿Qué datos hay disponibles? ¿Los datos son directamente relevantes para el problema? ¿Qué métodos de AA deberíamos probar? ¿Qué métrica debe utilizarse para medir el "éxito"?*

Estas son preguntas orientadas a la investigación, por lo que el trabajo durante esta parte del proyecto es exploratorio e iterativo. Es posible que los primeros resultados parezcan positivos, pero pueden estar seguidos de una falta de avance total, a pesar del esfuerzo invertido.⁸ Como consecuencia de los resultados de la investigación inicial, es posible que deba buscar orígenes de datos adicionales que pueda integrar en el proyecto. Podría ocurrir que su problema empresarial no se pueda resolver con los datos disponibles. También puede suceder que la solución sea modificar los sistemas para que los datos sí estén disponibles o que lo estén en el plazo que el modelo necesita (por ejemplo, los datos de secuencias de clics podrían necesitarse en tiempo real). O bien, puede ser que la solución consista en modificar el problema empresarial. También existe la posibilidad de descubrir que se puede formular una solución para el problema empresarial mediante una regla heurística o práctica, una estrategia más económica o adecuada en lugar de una solución de AA. Si bien el AA es una herramienta eficiente, no es la solución para todos los problemas.

Estas preguntas orientadas a la investigación contrastan directamente con las preguntas orientadas a la ingeniería, que tienen lugar después de responder la pregunta inicial.

Una estrategia, que puede ayudarlo a esclarecer el progreso de su proyecto y a encontrar enfoques adecuados, es identificar claramente en qué fase del espectro investigación-desarrollo se encuentra en la actualidad el proyecto de AA:

- **Fase de investigación:** de naturaleza exploratoria, con una respuesta incierta. Las preguntas se formulan de la siguiente manera: "¿es posible...?", o "¿podemos usar estos datos para resolver el siguiente problema?" o "seguramente vamos a poder...". La respuesta es incierta, al igual que el método apropiado que se debe implementar para lograr los resultados. El resultado de este esfuerzo puede ser: "sí, es posible, y esta es una manera de hacerlo que respalda esa afirmación" o bien "no, no creemos que sea posible; estas son todas las cosas que probamos y que no tuvieron resultado". Este tipo de investigación es realizado, con mayor frecuencia, por científicos de datos.
- **Fase de desarrollo:** el método para resolver el problema ya se conoce. A continuación, las preguntas se cambian por: ¿cómo se puede implementar este método a escala? ¿Cómo canalizamos los datos en el modelo de manera oportuna? ¿Cómo recopilamos, almacenamos y transformamos los datos para poder volver a entrenar modelos de forma coherente y calcular predicciones precisas dentro de un acuerdo de nivel de servicios obligatorio? ¿Cómo podemos crear un entorno de pruebas A/B con el fin de probar futuras iteraciones de modelos? Este trabajo corresponde al conjunto de capacidades de los ingenieros de software y datos.

Actualmente, muchos proyectos de AA en compañías de gran tamaño siguen este modelo: "investigación seguida de desarrollo, si se encuentran resultados positivos". Como estas dos fases distintas del proyecto tienen una naturaleza diferente, necesitan estrategias de proyecto diferentes:

- **Fase de investigación:** esta fase es de naturaleza iterativa y exploratoria, una estrategia de proyecto Kanban suele ser mejor para realizar el seguimiento y mostrar el progreso del proyecto. La investigación de los datos, la creación del modelo inicial y el análisis requieren, generalmente, plazos prolongados de tiempo de concentración ininterrumpido. Inclusive las reuniones breves pueden cortar la concentración y provocar la pérdida de un impulso o del contexto, los cuales son factores clave para un análisis complejo, en consecuencia se retrasa el progreso. Durante esta etapa, las estrategias Kanban ayudan con las duraciones de difícil predicción de la mayor parte de las tareas de investigación y experimentación, lo que permite obtener plazos de tiempo más prolongados y productivos y, simultáneamente, mostrar el progreso, las dependencias y los elementos que no permiten avanzar.
- **Fase de desarrollo:** en esta etapa, como los requisitos de implementación son más claros, los métodos Agile como Scrum y XP son estrategias de proyectos más adecuadas.

Evaluar el estado actual del proyecto en el espectro investigación-desarrollo es importante porque ayuda a crear de forma eficaz planes de dotación de personal, planes de trabajo y cronogramas de proyectos. Los proyectos de investigación con cronogramas desinformados generan roces entre los equipos e introducen soluciones de calidad intermedias en aras de percibir algún progreso. En lugar de ello, incluya tiempo para la investigación de datos y la iteración al principio del proyecto, con un punto de comprobación principal que marque la transición a la fase de desarrollo. Revise los cronogramas de los proyectos con frecuencia, a medida que se modifiquen las estimaciones del nivel de confianza.

Evaluación del valor económico

Para la mayoría de los proyectos de AA, las partes interesadas asumen que existe un valor económico de incremento gradual en relación con el proyecto. Como el incremento del valor es gradual, puede calcularlo y evaluarlo, y luego compararlo con los costos y los riesgos del proyecto. Una forma de conseguirlo es dentro de un contexto económico.

Este contexto económico se basa en un modelo de retorno de inversión (ROI), que intercambia costos por beneficios esperados. Teniendo en cuenta la velocidad y el volumen de los datos sobre los que muchos modelos operan, es importante tener en cuenta algunos problemas como la calidad de los datos y los peores impactos económicos de las inferencias de AA. Por lo tanto, añadimos algunos factores adicionales para los proyectos de AA, tales como inspeccionar los riesgos y sus costos potenciales y usar herramientas como los tableros de control, según se describe en la sección [Usar tableros de control para gestionar y mitigar riesgos](#).

A grandes rasgos, un panorama completo de los proyectos de AA incluye la recopilación y canalización de los datos, el modelo en sí y las inferencias, lo que da lugar al valor empresarial (consulte Figura 1). La canalización de datos está conformada, generalmente, por (potencialmente varias instancias) varias etapas de procesamiento (filtrado, combinación, transformación) y almacenamiento de datos. El valor económico y el análisis de riesgo deben incluir el proceso de principio a fin.

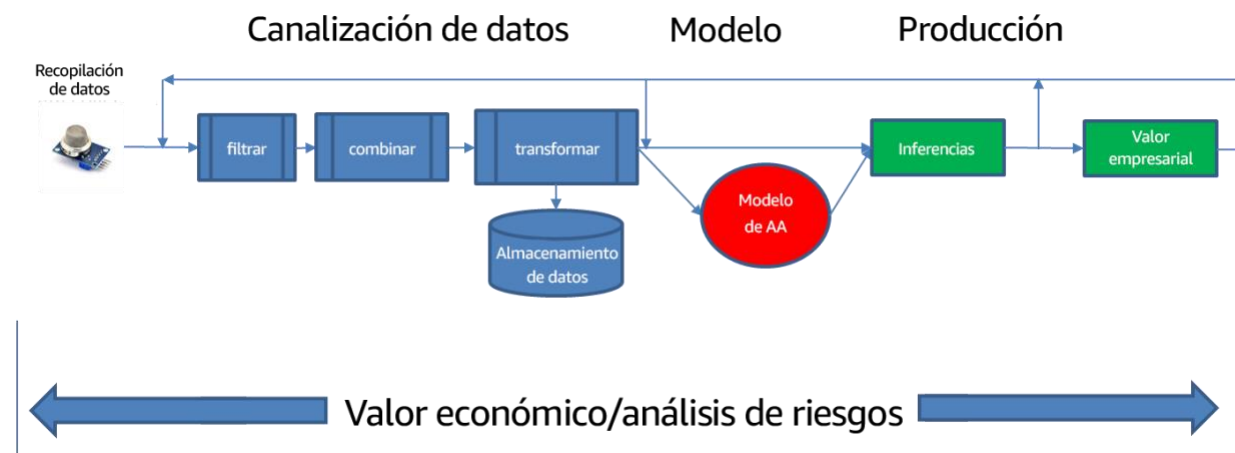


Figura 1: diagrama del proceso económico de los proyectos de AA

Se deben tener en cuenta varias consideraciones en relación con el diagrama:

- En primer lugar, especifique la fase actual del proyecto (investigación o desarrollo), luego evalúe, analice y financie según corresponda. Mientras que el objetivo de algunos proyectos de AA es lograr mejoras de producción explícitas, otros son más especulativos, con posibilidades de *alto riesgo*. El modelo económico para el proyecto debe ser coherente con el tipo de proyecto.

Asegúrese de que la gerencia de la empresa y los científicos de datos estén de acuerdo en si el proyecto es especulativo y está orientado a la investigación o si utiliza una técnica bien conocida en un entorno bien conocido.

- Evalúe y analice la fuente de los datos, el modelo de AA y la calidad esperada de las inferencias de producción. Para obtener más información, consulte las secciones

- *Calidad de los datos* y *Desde la investigación hasta la producción*.
- Conserve un modelo de costo/beneficio y repita las evaluaciones a medida que se registren cambios. Por ejemplo, cambios introducidos en el contexto empresarial externo o la incorporación de un origen de datos costoso pueden modificar el modelo de costo/beneficio inicial.
- Conozca, evalúe y monitoree los riesgos del proyecto. Genere resúmenes e informes regulares para las partes interesadas.

El modelo de retorno de inversión también introduce información clave a la actividad de modelado de AA. ¿Qué nivel de calidad de inferencia se requiere para respaldar el valor esperado? ¿Cuál es el costo de los diferentes tipos de errores (falsos positivos, falsos negativos)? Estos valores pueden actuar como limitaciones al momento de entrenar y evaluar posibles modelos.

Para garantizar que el proyecto siga su rumbo, se debe aplicar la evaluación de los riesgos y del valor económico de manera regular. Además, todos los involucrados deben conocer los cambios vinculados con la meta, la estrategia o el riesgo.

Compruebe los supuestos

Los proyectos de AA funcionan bajo un cierto conjunto de suposiciones, muchas de las cuales no se declaran ni se verifican. En la mayoría de los proyectos exitosos, este conjunto de supuestos es válido. Los siguientes ejemplos son algunos de los supuestos que frecuentemente se consideran como verdad:

- Las variables relevantes para el problema se registran y están disponibles en los datos.

Por ejemplo, la mayor influencia de los tiempos del tráfico para una tienda podría ser el cronograma escolar local, que posiblemente no esté registrado en el conjunto de datos de estadísticas históricas de tráfico. Los datos utilizados para entrenar un modelo de AA, por lo general, se registraron para un problema empresarial diferente... con diferentes supuestos.⁹

- Los conjuntos para entrenamiento, validación y pruebas representan correctamente la *realidad*.

¿Los conjuntos son muestras grandes y representativas de las poblaciones acerca de las cuales el modelo necesita realizar predicciones? ¿La variable de destino que el modelo predice representa el resultado real que el modelo de AA está intentando predecir, o hay un proxy para ese resultado? ¿Los métodos de extracción utilizados para generar estos conjuntos de datos son los mismos que para los datos de producción? ¿Qué nivel de semejanza existe entre los *datos de muestra* y los datos reales? ¿Las semejanzas cuentan con el respaldo de hechos comprobables? ¿Los orígenes de error o los tratamientos son los mismos?

- Los datos de entrenamiento, validación y pruebas registrados en un punto en el tiempo siguen siendo válidos.

Como los sistemas ascendentes cambian, los datos que producen podrían tener características diferentes, lo que modifica la validez del modelo.¹⁰ Los cambios temporales en la naturaleza o las influencias del sistema que se está modelando también pueden afectar la validez de los datos de entrenamiento, validación o prueba.

- El modelo de AA es válido.

Por ejemplo, las suposiciones de que se seleccionó el modelo adecuado, de que los *casos excepcionales* se representaron lo suficientemente bien y de que se realizó el análisis estadístico correcto.¹¹

- La transferencia de aprendizaje supone que el modelo de origen es adecuado y que el aprendizaje es realmente transferible.¹²
- Las correlaciones que se encontraron son relevantes. Por ejemplo, el índice de divorcios en Maine se correlaciona en gran medida con el consumo per cápita de margarina. ¿Es relevante para el problema?¹³ La correlación no es causalidad.

- Un modelo de AA se puede crear e implementar en producción dentro de las limitaciones temporales impuestas por la gerencia o el caso empresarial. De lo contrario, deben considerarse otros caminos o flexibilizarse los límites de tiempo.
- Los cambios conceptuales o de modelos suceden relativamente despacio o pueden corregirse de manera adecuada con nuevos entrenamientos de modelos mientras se sigue sosteniendo el modelo económico.¹⁴
- La propiedad operativa tiene justificación económica. La ventaja económica general del sistema justifica el costo de contratar profesionales de AA, etiquetar datos o investigar errores, mantener el modelo, identificar cambios en modelos cuando estos ocurren y repetir los entrenamientos según sea necesario.

Una práctica recomendada consiste en considerar de forma activa los supuestos que el proyecto está realizando y comprobar su validez. Es conveniente tener en cuenta estos supuestos y cuestionarse si se aplican de forma explícita a su situación.

Si son adecuadas, vale la pena documentar dicha evaluación y sus causas al principio del proyecto, y después revisarlas periódicamente para comprobar su validez. Los requerimientos imprevistos, un mayor conocimiento del ámbito del problema y de los datos disponibles, o del problema empresarial, o las modificaciones de los datos con el transcurso del tiempo pueden modificar dicha evaluación.

Si los supuestos no son adecuados entonces un análisis de la situación podría modificar la estrategia o destacar acciones que se podrían tomar para corregir las suposiciones incorrectas. Por ejemplo, una tarea o un proyecto podrían adquirir orígenes de datos, recursos o conexiones adicionales a otros equipos.

Calidad de los datos

La calidad del modelo de AA está directamente relacionada con la calidad de los datos utilizados para crearlo. Una parte importante del componente *investigación* de los proyectos de AA consiste en evaluar la calidad de los datos y si es adecuada para el problema. Como la evaluación de la calidad de los datos sigue siendo más un arte que una ciencia, algunos métodos útiles son:

- Documentar el flujo y el catálogo de datos
- Calcular el impacto de la calidad de los datos

Documentar el flujo y el catálogo de datos

Con frecuencia, los orígenes de los datos y el proceso que se utiliza para extraerlos mientras se crea y prueba el modelo de AA inicial son muy diferentes de aquellos que se usan en producción para obtener inferencias. Por ejemplo, la investigación inicial ("¿es posible?") se llevará a cabo con frecuencia en datos filtrados y posiblemente enriquecidos, que se extrajeron de un lago de datos para mayor comodidad y velocidad de acceso. La presunción implícita es que los datos utilizados en producción serán los mismos y que se pueden suministrar lo suficientemente rápido como para poder actuar. Esta presunción se debe probar para garantizar que el modelo de AA funcione según lo previsto.

Un método sencillo para identificar posibles desafíos consiste en diagramar claramente el flujo de los datos que se utiliza para crear el modelo, de manera tal que se muestre la procedencia de todos los datos y de qué manera se transforman. A continuación, se presenta un ejemplo de cómo realizar anotaciones en el diagrama de canalización con esta información:

- Operaciones de filtrado de datos importantes que se hayan realizado
- Registros omitidos, como un recuento real o como un porcentaje
- Principales errores encontrados en los datos, como "registros duplicados encontrados y omitidos"
- Las presunciones realizadas en aquel momento, como "los datos se extrajeron para EE.UU. únicamente, se presume que el proceso es similar para otros países"

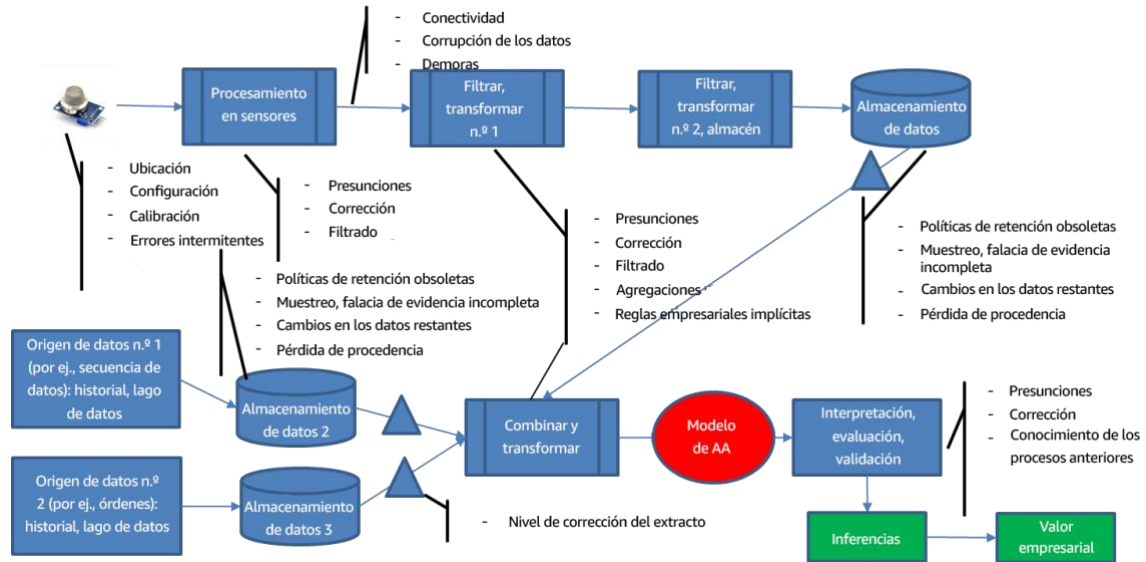


Figura 2: esquematización del flujo de los datos y de las fuentes de error potenciales

Tal y como se muestra en Figura 2, las características de los datos de origen también se pueden registrar en una tabla de *catálogo de datos*, como

Tabla 1. Este catálogo documenta el conocimiento vigente del origen de datos, comunica a las partes interesadas cuales son los orígenes de datos que se van a utilizar y algunos hechos básicos sobre ellos. Además, ayuda a identificar posibles desajustes y preocupaciones, o clarificar malentendidos. Por ejemplo, en

Tabla 1, el cambio en el formato del almacenamiento de orígenes de datos n.º 2 añade potencialmente una tarea de conversión o regularización a la lista de tareas.

Tabla 1: catálogo de datos de muestra durante la fase de investigación

Origen	Contenido	Duración	Cantidad	Comentarios
Origen de datos n.º 1: lago de datos	Datos de secuencias de clics	Enero de 2018 a enero de 2019	1.6 MILLONES	Dirección IP de usuario únicamente; nombre de usuario desconocido
Origen de datos n.º 2: lago de datos	Historial de órdenes	1 de junio 2016 al 3 de octubre de 2018	55 000 órdenes	Formato almacenado en cambio el 1 de enero de 2018 Orden final únicamente (sin historial de cambios) Órdenes con errores se eliminan
Datos de sensores	Lecturas de sensores de fábricas Los datos de streaming se agrupan en lotes y se almacenan	Período de retención de historial de 90 días únicamente	50/s; 5000/s previstos	Filtrado de datos desconocido; ¿se perciben datos atípicos que se estén omitiendo?

También debe crear diagramas del flujo y el catálogo de datos que se vayan a utilizar en un entorno de producción. Tome nota de las similitudes y diferencias entre los dos flujos de datos.

- Si son iguales entonces es probable que sean vulnerables a los mismos errores. ¿Los errores son importantes?
- Si no son iguales entonces se aplicaron diferentes orígenes y procesamientos. ¿Alguna de estas diferencias afecta el modelo? ¿Cómo lo sabe?

Comparta los diagramas y resúmenes con los expertos y los patrocinadores del proyecto. Explique las diferencias y logre acuerdos que parezcan razonables para todas las partes interesadas. Si la brecha entre las dos es demasiado grande (una evaluación muy subjetiva) entonces considere otras estrategias de obtención de datos que sean más representativas de los mismos, que el punto de enlace de la inferencia de AA recibirá en circunstancias de producción.

A mayor cantidad de orígenes de datos implicados, mayores serán las diferencias entre los orígenes de datos que deben combinarse, y a mayor cantidad de pasos de transformación de datos implicados, mayor será el desafío en relación con la calidad de los datos.

Estimación del impacto de la calidad de los datos

Durante el entrenamiento de AA inicial, es común empezar con los datos filtrados (por ejemplo, de un lago de datos) o filtrar los datos antes de ejecutar el entrenamiento. Algunos ejemplos son:

- Al combinar los datos, estos podrían omitirse si no se encuentran coincidencias.
- Los registros con un valor nulo o extremo podrían omitirse.

A menudo, se realizan muchos pasos de filtrado y transformación individuales antes de que los datos se utilicen para el entrenamiento de AA.

Sin embargo, cuando el modelo se utiliza en producción, los datos que se envían para realizar inferencias son, por lo general, de un origen diferente, e ingresan al punto de enlace de inferencia del modelo a través de una ruta diferente, tal y como se describe en [Documentar el flujo y el catálogo de datos](#). El modelo se creó para trabajar correctamente con datos de entrada *filtrados*. ¿Cómo puede asegurarse que el rendimiento del modelo en un entorno de producción sea similar? A continuación, se muestran dos estrategias que se combinan: comparar estadísticas y validar el modelo en relación con datos de entrada sin filtrar.

Comparación de estadísticas

Para asegurarse que el modelo presente un buen rendimiento en entornos de producción, agregue un punto de comprobación formal que se aleje del modelo de AA y compare los datos de origen de entrada con los datos que realmente usó el modelo de AA para el entrenamiento. Asegúrese de evaluar los datos desde una perspectiva cuantitativa y cualitativa.

- Evaluación cuantitativa: revise los totales, las duraciones de los datos y la precisión de los datos de entrada.
 - Comparar los totales le permite identificar, controlar y marcar la pérdida de datos, además de realizar pruebas contra valores razonables. ¿Qué porcentaje de los datos de origen se utilizó realmente para crear y probar el modelo? ¿Existe algún tipo de inclinación potencial como resultado de datos omitidos accidentalmente debido a una combinación? ¿El subsistema de almacenamiento de datos filtra, promedia o agrega resultados después de un cierto período de tiempo (por ejemplo, para los mensajes de registro)?

- Revisar la duración de los datos le permite determinar a qué período de tiempo está destinado cada conjunto de datos. ¿Se incluyeron todos los ciclos comerciales potencialmente relevantes (por ejemplo, Black Friday o Día del Soltero para la venta minorista)?
- Cuantifique la precisión mediante la comparación de la desviación estándar, mediana y promedio del origen de los datos contra los datos utilizados para entrenar el modelo. Calcule el número o porcentaje de los valores atípicos (outliers). Para las variables clave o los datos dimensionales inferiores, los diagramas de caja pueden suministrar una evaluación visual rápida de razonabilidad.
- Evaluación cualitativa: la exactitud tiene la misma importancia que la precisión, pero probablemente solo pueda evaluarse cualitativamente. Por ejemplo, en función de su experiencia, y quizá de algunas actividades de exploración de muestras, ¿cuán seguro está del nivel de exactitud de los datos? ¿Hay suficientes registros de errores? Por ejemplo, ¿los operadores informan si este sensor siempre funciona al máximo?

Las acciones que se tomarán en función de esta evaluación son muy diversas. Un resultado frecuente es segmentar los datos en función de algunos factores descubiertos durante el análisis e implementar una acción diferente en cada segmento. Por ejemplo, en el informe [Improving Data Quality in Intelligent Transportation Systems](#)¹⁵ (Cómo mejorar la calidad de los datos en sistemas de transporte inteligentes), se identificaron configuraciones erróneas en un conjunto de sensores y se enviaron a reparación, mientras que otro subconjunto se utilizó para el análisis del tránsito.

Validación del modelo en relación con datos de entrada sin filtrar

Una técnica sencilla pero eficiente para validar el modelo de datos consiste en tomar un subconjunto de los datos que se eliminaron durante cada paso de filtrado o transformación de los datos sin procesar y compararlo con los datos que finalmente se utilizaron para entrenar el modelo, y enviar dichos ítems al punto de enlace de inferencia de AA. A continuación, evalúe las inferencias resultantes. ¿El punto de enlace ofrece respuestas razonables en todos los casos? Utilice los resultados para identificar dónde deberían agregarse las comprobaciones y el control de errores. ¿El control de errores debería agregarse al punto de enlace de inferencia? ¿O se debería obligar a las aplicaciones que están llamando al punto de enlace de inferencia a identificar y eliminar datos de entrada problemáticos o a controlar los datos de salida problemáticos?

Una práctica similar consiste en tomar ejemplos que el modelo de AA haya clasificado o predicho de forma incorrecta, e ingresarlos en una prueba integral del proceso dentro del cual se realicen las inferencias de AA.

Estrategias para aplicar

Estos son algunos de los métodos y prácticas recomendadas que ayudan a administrar y mitigar estos riesgos, y que permiten realizar un uso óptimo de las oportunidades.

Las categorías descritas son:

- Dotar al proyecto de personal de forma adecuada
- Evaluar el valor económico
- Usar tablero de control como técnica de gestión de riesgos
- Usar estrategias de inversión de incremento gradual

Dotar al proyecto de personal

Existe cierta confusión acerca de los tipos de profesionales que trabajan en AA. El NTSC¹⁶ señala que la fuerza laboral vinculada con la IA incluye varios tipos de profesionales muy diferentes entre sí:

- Una cierta cantidad de *investigadores* de IA que llevan a cabo avances fundamentales en el sector. Para los investigadores, el entrenamiento de IA es interdisciplinario por naturaleza y, a menudo, requiere conocimientos sólidos en ciencias de la computación, estadística, lógica matemática y teoría de la información.
- Un mayor número de *especialistas* que perfeccionan los métodos de IA para aplicaciones específicas. Para los especialistas, el entrenamiento normalmente implica tener conocimientos en ingeniería de software y en el área de aplicación.
- Un número mucho mayor de *usuarios* que utilizan dichas aplicaciones en situaciones específicas. Para los usuarios, estar familiarizado con tecnologías de IA es fundamental para aplicar las tecnologías de IA de manera confiable.

La mayoría de los proyectos de AA cuentan con personal considerado *especialista* según esta definición. Estos especialistas pueden subclasificarse en científicos de datos e ingenieros de datos:

- Con frecuencia, los científicos de datos tienen una formación en matemática aplicada y estadística, y realizan análisis avanzados
- Generalmente, los ingenieros de datos tienen una formación en programación y análisis, y se especializan en tecnologías de big data¹⁷

Como máximo, hasta el 80 % del esfuerzo se implementa en la ingeniería y el acceso a los datos¹⁸; el equipo del proyecto no debe estar conformado únicamente por científicos de datos, aunque esa sea la especialidad en la que la mayoría de las personas piensa primero. Si bien la combinación exacta dependerá del tamaño del proyecto, de su potencial impacto y visibilidad, y de los riesgos implicados, las siguientes funciones deben estar representadas en el equipo.

- **Comité de dirección:** el comité de dirección debe incluir a las partes interesadas en el negocio y al *propietario* financiero de los beneficios y riesgos. El comité toma decisiones sobre el rumbo del proyecto y su aplicabilidad a las oportunidades comerciales, incluida la potencial cancelación de un proyecto si el modelo económico no muestra resultados positivos. También puede incorporar especialistas externos, como asesores del área legal, de recursos humanos y relaciones públicas, según sea necesario, para gestionar o mitigar los riesgos. El comité de dirección puede tener el nivel de formalidad que se necesite, en función de la estructura de la organización y de los compromisos financieros implicados.
- **Expertos (SME):** el éxito del proyecto depende de conocimientos acerca de cómo se recopilan los datos, de los sistemas implicados, del procesamiento previo que se haya realizado y algunas veces de los antecedentes de por qué los datos son de una determinada manera o de las suposiciones integradas (por ejemplo, los valores de datos inferiores a x se eliminan antes de que lleguen a este sistema). Este conjunto de habilidades y conocimientos está estrechamente vinculado con los procesos empresariales implicados y los sistemas y métodos existentes que se utilizan para generar los datos. Los expertos identifican posibles orígenes de datos de entrada, comprenden e interpretan los datos de origen, validan si hay conflictos con la *fuentes de la verdad*, evalúan la calidad de los datos y ofrecen asesoramiento sobre la implementación.
- **Científicos de datos:** estos especialistas proveen conocimientos estadísticos y especializados en AA. Crean modelos de AA más complejos y realizan la evaluación estadística del rendimiento del modelo. El diseño experimental riguroso es fundamental, especialmente para las compañías con bases de usuarios de gran tamaño o que pertenecen a industrias con niveles altos de regularización. A menudo, se necesita una cantidad muy baja de científicos de datos en comparación con otras funciones.

- **Ingenieros de datos, de desarrollo de aplicaciones y de infraestructura:** estos especialistas se encargan de la obtención de datos, de las tareas de ETL (extracción, transformación, carga) y de crear la línea de flujo de los datos. Este grupo incluye a los desarrolladores de aplicaciones, que son responsables de integrar el modelo en una aplicación y de usar las inferencias en el contexto de un proceso empresarial. Por lo general, se necesitan más ingenieros de datos que científicos de datos. A menudo, el trabajo de ingeniería de datos se enfoca en la primera etapa del proyecto, en la obtención de datos para los científicos de datos y en la creación de una línea de flujo de datos inicial. Posteriormente, los ingenieros de datos o los ingenieros de desarrollo de aplicaciones toman un modelo de AA inicial, lo ponen en producción y crean los flujos de datos necesarios para admitir las inferencias en el entorno de producción.

Evaluación del valor económico

Un primer paso clave en el proyecto de AA es crear un modelo económico del valor esperado del proyecto. Este modelo proporcionará contexto para informar las decisiones del proyecto, lo que cambia el enfoque de la tecnología de AA a su impacto en el negocio.

La complejidad del modelo económico, y de sus componentes, puede variar según corresponda. El objetivo es registrar la ecuación de costo/beneficio deseada detrás del problema que el proyecto de AA abordará, independientemente del nivel de detalle necesario para respaldar la toma de decisiones. Crear un modelo económico también permite al personal del proyecto de AA obtener las restricciones o los impulsores clave del negocio que el modelo debe cumplir (como: "debe tener el mismo nivel de exactitud que el proceso actual", o "debe proveer transparencia en relación con la manera en la que se toman las decisiones"). Estas restricciones se convierten en requisitos para el sistema de AA, los riesgos que se deben administrar o los criterios de decisión sobre si el modelo es lo suficientemente bueno como para continuar. Determinar si un modelo es suficiente para respaldar el caso empresarial podría ser más exigente que definir si el modelo es bueno.

Otro aspecto del proyecto de AA es evaluar el costo de los errores. Una característica implícita con la velocidad y el volumen de muchos modelos de AA es que la intervención y supervisión humanas que existen en la actualidad se eliminan. ¿Cuál es el costo de los errores? Si hay un costo para cada error, ¿cuánta tolerancia existe antes de que el modelo económico deje de ser positivo? Si se producen *cambios en el modelo*, el número de errores podría aumentar. ¿Cuál es la gravedad de ese problema? Tal y como se muestra en Figura 3, el cálculo de los costos de los errores puede demostrar que un modelo que de otra manera parecería rentable (en función de otras métricas buenas) no sea viable económicamente.

N=16 500	Previsto: No	Previsto: Sí	Conteo
Real: No	(Verdadero negativo) 5000	(Falso positivo) 1000	6000
Real: Sí	(Falso negativo) 500	(Verdadero positivo) 10 000	10 500
Conteo	5500	11 000	

Índice de clasificación, exactitud	0,90
Recuperación	0,95
Precisión	0,91
Valor F	0,92

VALOR USD	Costo por	Número	Totales
Verdadero negativo	0	5000	0
Falso negativo	-1000	500	-500 000
Falso positivo	-11 000	1000	-11 000 000
Verdadero positivo	1000	11 000	11 000 000
TOTALES		16 000	-500 000

Figura 3: Evaluación del impacto de los costos de los errores

Podría ser apropiado utilizar aspectos del modelo económico para modificar el modelo de AA en sí. Por ejemplo, si los costos de diferentes tipos de errores, como falsos negativos o falsos positivos, son muy diferentes, dicha información se puede utilizar para entrenar un modelo con más resultados satisfactorios. Un ejemplo de este tipo de enfoque se muestra en la publicación de blog [Training models with unequal economic error costs using Amazon SageMaker](#).¹⁹ En este caso, los costos diferenciales de los errores modifican el modelo de AA utilizado para predecir el cáncer de mama, lo que genera menos falsos negativos (no deseados y costosos) al costo de más falsos positivos, sin dejar de producir un modelo más asequible en general.

Experiencias recientes en las que se crearon modelos económicos en etapas iniciales de proyectos demostraron que estos pueden modificar radicalmente el rumbo y el enfoque del proyecto. En un caso, se descubrió que el costo del procesamiento necesario era tan reducido que un modelo de AA más grande e integral reemplazó al sistema de destino que se había planificado en un principio. En otro caso, el costo de obtención de los datos y su fragilidad prevista debido a la rápida evolución de los orígenes de datos, rápidamente puso en evidencia que el proyecto no era económicamente viable. En un tercer caso, la recopilación de datos para crear una versión inicial del modelo económico demostró que el problema que el proyecto de AA

debía abordar podría tratarse con un método mucho más sencillo y directo. En cada caso, presentar el modelo económico permitió a los administradores y ejecutivos responsables tomar decisiones rápidas.

Usar tableros de control para gestionar y mitigar riesgos

Un elemento esencial de la administración de proyectos es la gestión de riesgos. La gestión de riesgos depende de la identificación de los riesgos que se gestionan en el proyecto y, a continuación, de la mitigación y monitorización de dichos riesgos. Un método principal que ayuda en este proceso es el uso de tableros de control.

Los tableros son un mecanismo aparentemente simple que se puede utilizar para identificar, gestionar e informar los riesgos. Se pueden usar para garantizar que los líderes del proyecto hayan analizado los ítems de riesgo potenciales y registrado posibles mitigaciones. Los riesgos identificados se pueden resumir e informar. Los tableros proporcionan un método para comunicar problemas técnicos a los ejecutivos responsables, lo que garantiza que los riesgos identificados se comuniquen a los niveles adecuados. Se incluyen ejemplos de tableros en la siguiente sección.

Concepción del proyecto

Al comienzo del proyecto, converse acerca de cada ítem del tablero con los patrocinadores y defina si el problema se aplica al proyecto o no.

- Si la respuesta es negativa, documente los motivos.

Esta acción registra el hecho de que sí se analizó este riesgo y por qué no se aplicó. Si con posterioridad descubre que el riesgo sí se aplica, puede volver a revisar los motivos, identificar los errores y modificar el proceso relacionado con el tablero. Por ejemplo, si identifica una suposición errónea, puede desarrollar una prueba de esa suposición e incluirla para la próxima vez. Podría optar por incluir estos ítems en una lista de *no se aplica*, lo que puede facilitar poder centrarse en el resto de los ítems en cuestión.

- Si la respuesta es positiva, establezca el impacto potencial (tal vez únicamente como una orden de magnitud) e identifique qué mitigaciones o acciones debería implementar.

¿Se trata de un riesgo relativamente menor que el equipo puede controlar? O bien, ¿es un riesgo que debe incluir a otros equipos como, por ejemplo, el área de legal y de recursos humanos? ¿Existen procesos específicos que deberían aplicarse, como, por ejemplo, pasos de validación o pruebas adicionales? Estas mitigaciones podrían manejarse dentro del proceso de AA o encontrarse fuera del alcance del equipo de ciencia de datos.

Si usted o su equipo de proyecto creen que los riesgos son importantes (especialmente si identificaron problemas éticos o morales potenciales) lo correcto es derivarlos al equipo gerencial correspondiente de su organización. Por ejemplo, si identifica un problema que podría afectar al personal, lo correcto sería entrar en contacto con el área de recursos humanos y solicitarle asesoramiento. Los miembros de esta área podrían sugerir mitigaciones, como ofrecer nuevas formaciones al personal u ofrecer ayuda en relación con la reubicación del personal reemplazado. Se sugiere que a los problemas los gestionen grupos que tengan una responsabilidad asociada y que estos se involucren rápidamente para que puedan ofrecer asesoramiento, planificar sus respuestas y, de ser necesario, proveer directivas al equipo de AA. Como suele suceder con otras formas de automatización, el AA puede afectar muchos asuntos que se encuentran fuera del alcance de la autoridad de los científicos de datos que crean los modelos de AA.

A continuación, es posible administrar y monitorizar los riesgos identificados a medida que el proyecto avance. Muchos de dichos riesgos deberían convertirse en tareas del plan del proyecto a abordar con estrategias de administración normales del proyecto. Es posible que algunas de estas tareas se encuentren fuera del alcance del equipo del proyecto actual.

Operaciones del proyecto

Al momento de prepararse para cada revisión o para cada informe de proyecto programado:

- Actualice el estado de cada riesgo de la lista *sí aplica riesgo*. Determine si las mitigaciones vigentes son adecuadas o si deben implementarse acciones adicionales. Revise los planes de mitigación según sea necesario.
- Revise rápidamente la lista *no aplica riesgo* para verificar si los motivos aún son los mismos. Si resulta necesario volver a evaluar algún ítem, páselo a la lista *activos*.

A medida que el proyecto avance, la naturaleza de los riesgos y las mitigaciones deberían cambiar. Si bien al principio del proyecto muchos ítems podrían tener planes de mitigación desconocidos o inciertos, mostrados por estado *amarillo* o *rojo*, a medida que el proyecto avance, un número cada vez mayor de estos riesgos debería mitigarse y el estado de más ítems se convertirá en *verde*. Si el proyecto avanza y los ítems se transforman en *rojo* o no

cambian, el proyecto debe revisarse en detalle, los problemas subyacentes deben identificarse y resolverse, o el proyecto debería reenfocarse o, potencialmente, cancelarse.

Ejemplos de tableros de control

Los tableros de ejemplo se dividen en cinco temas:

- **Contexto del proyecto:** aborda el entorno social, empresarial y normativo del proyecto.
- **Finanzas:** identifica los costos y beneficios del problema que se está intentando resolver con AA y del sistema de AA que se está desarrollando
- **Calidad de los datos:** destaca las áreas que con frecuencia son problemáticas en los proyectos de AA y que pueden desencaminar el proyecto con facilidad (la falta de una señal que existe en los datos o creer que una señal existe, cuando en realidad no es así) si no se las identifica y resuelve
- **Procesos del proyecto:** aborda procesos del proyecto de AA que se omiten fácilmente debido al entusiasmo de desarrollar y probar el algoritmo y de identificar resultados prometedores
- **Resumen:** registra áreas de riesgo claves para informarlas al área ejecutiva

Los temas del tablero se pueden personalizar en función de una industria, una organización o un equipo. Estos tableros de muestra no son exhaustivos ni específicos para un país, industria o compañía. Ofrecen un punto de partida útil y deberían modificarse cuando se cambien los problemas comunes en los proyectos de AA. Pueden ser adaptadas mediante la incorporación, eliminación o modificación de ítems para que se apliquen mejor al contexto en el que están siendo utilizadas.

Cada categoría es, por sí misma, un tema complejo que a menudo tiene una enorme cantidad de investigación asociada. Incluimos un ejemplo en cada caso de los proyectos en los que puede surgir un problema. Para estimular los debates, también ofrecemos algunos ejemplos de artículos o documentos técnicos populares que abordan el tema. Si se considera que una categoría afecta al proyecto entonces podría considerar realizar una consulta a un experto en la materia.

En la sección [Apéndice](#), puede encontrar versiones vacías de los tableros.

Contexto del proyecto

El *contexto del proyecto* aborda el entorno social, empresarial y normativo del proyecto.

Tabla 2: ejemplo de tablero de control: contexto del proyecto

Categoría	Ejemplo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
Ética	Armas dirigidas a sistemas Vigilancia predictiva ²⁰ IA que imita a los humanos ²¹			
El modelo toma decisiones con consecuencias importantes	Negar préstamos o el ingreso a un país Evaluaciones de riesgo criminal en arrestos, fianzas, veredictos			
Privacidad	Debe cumplirse con HIPAA/GDPR			
Legitimidad, inclinaciones ²²	Raza identificada como factor de riesgo para préstamos Puestos de trabajo reemplazados ocupados de manera desproporcionada por minorías			
Riesgo de mala prensa	Aplicación de etiquetado de fotos etiqueta afroamericanos como <i>gorila</i> Vehículo autónomo mata peatón ²³			
Necesidad de transparencia y capacidad de auditoría	Las recomendaciones deben poder verificarse de manera independiente ²⁴			
Aplicabilidad/éxito del AA para esta aplicación	Bots de chat para asistentes de lenguaje natural y comprensión de conversaciones de formato libre			
Desarrollo/pruebas de mundo cerrado e implementación de mundo abierto	Robot de laboratorio y entorno de casa abierta (niños, mascotas, escaleras)			
Impacto de las inferencias del modelo de AA	Automóvil autónomo ve un peatón, pero lo ignora como falso positivo			

Finanzas

El tablero sobre *finanzas* identifica los costos y los beneficios del problema que está intentando resolver con el AA y del sistema de AA que está desarrollando.

Tabla 3: ejemplo de tablero de control: finanzas

Categoría	Ejemplo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
Modelo financiero creado	Modelo con rentabilidad prevista disponible para revisión			
Rendimiento en alza potencial	Mayor retención de clientes de 5 % Menor costo por transacción de 5 %			
Posible riesgo a la baja	Menor retención de clientes (10 %) Mayor costo por transacción (5 %)			
Desventaja del peor de los casos	Algoritmo comercial automatizado genera un gran colapso financiero			
Responsabilidad	Vehículo autónomo mata peatón			
Costo de crear un modelo	6 meses, equipo de 2 ²⁵			
Costo de mantenimiento del modelo	Constante, 10 horas/mes			
Calidad de las predicciones del modelo en relación con las expectativas	El modelo económico asume un 100 % de predicciones correctas, pero un 85 % de los resultados es correcto			
Incertidumbre en relación con las predicciones del modelo	La predicción puede tener un nivel de exactitud de +/- 10 % Los puntos de datos extremos generaron malas predicciones			

Calidad de los datos

El éxito de un proyecto de AA depende de la señal inherente en los datos y de lo que se extrae de ellos. El tablero de control de *calidad de los datos* destaca las áreas que con frecuencia son problemáticas en los proyectos de AA y que pueden desencaminar el proyecto con facilidad (la falta de una señal que existe en los datos o creer que una señal existe, cuando en realidad no es así) si no se las identifica y resuelve

Tabla 4: ejemplo de tablero de control: calidad de los datos

Categoría	Ejemplo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
Precisión de los datos de entrada ²⁶	Los datos de prueba y producción tienen las mismas características; valores atípicos descartados tanto del modelo como de producción			
Exactitud de los datos de entrada	Valores de los sensores calculados como +- 5 % en relación con los actuales			
Volúmenes de datos y duración	Datos del modelo disponibles durante 3 meses (pero el ciclo comercial es de 1 año) 50 % de los datos n.º 3 de origen descartados			
Orígenes de datos y procesamiento previo validados	Origen de datos n.º 1 ahora sometido a controles de calidad adicionales Se detectaron imperfecciones en el extracto de datos n.º 2; es necesario realizar un nuevo entrenamiento			
Canalización de datos del modelo y producción	Las inferencias de producción utilizarán un origen de datos diferente al usado para entrenar el modelo			
Cambios en los datos con el transcurso del tiempo: procesos considerados	El sistema ascendente modifica la lógica y el significado de los datos ingresados al modelo ²⁷			

Procesos de proyectos

El tablero de control de *procesos del proyecto* aborda procesos del proyecto de AA que se omiten fácilmente debido al entusiasmo de desarrollar y probar el algoritmo y de identificar resultados prometedores

Tabla 5: ejemplo de tablero de control: procesos del proyecto

Categoría	Ejemplo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
Investigación o desarrollo	Investigación, que da lugar al desarrollo si es positiva			
Disponibilidad y capacidades del equipo del proyecto	El equipo no tiene capacidades de desarrollo de aplicaciones de producción			
Plazos del proyecto	Los plazos establecidos asumen que los datos están disponibles y que son correctos y suficientes para el modelo			
Pruebas para inclinaciones aplicadas	Los índices de reincidencia son los mismos en todas las poblaciones			
Análisis <i>long tail</i> realizado	Grupos minoritarios en desventaja porque el sistema se entrena en grupos mayoritarios			
Análisis estadístico validado ²⁸	El análisis estadístico incorrecto muestra correlaciones donde no existen, lo que genera inferencias incorrectas			
Análisis económico de métricas de modelos	Los resultados del modelo siguen estando dentro del rango de las estimaciones del valor económico del proyecto			
<i>Control de nivel de compromiso del equipo</i> ²⁹	<i>Control de intuición del equipo:</i> el equipo desea ser un cliente del sistema			

Categoría	Ejemplo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
Procedimientos de validación y verificación completados	Prueba completada: garantías de privacidad, pruebas A/B Evaluación de seguridad completada			
Integración con procesos y sistemas existentes	Nuevas interfaces o API necesarias Modificaciones del proceso de los usuarios necesarias			
Instrumentación y monitorización vigentes	El punto de enlace del modelo está preparado para introducir datos nuevamente al proceso de entrenamiento El proceso de monitorización que identifica cambios en el modelo está definido			
Revisiones del modelo de producción	Planificar para volver a entrenar y relanzar modelos vigentes y financiados			

Resumen

El tablero de *resumen* registra áreas de riesgo claves para informarlas al área ejecutiva. Se puede preparar para una presentación ante el comité de dirección y otros ejecutivos interesados. Esta planilla simple puede presentar un resumen sólido de las preocupaciones del equipo de un proyecto, lo que permite a la alta gerencia enfocarse en problemas clave. Este tablero de resumen cuenta con el respaldo de la documentación más detallada que proveen las planillas individuales. En el siguiente ejemplo de tablero de resumen se muestra una sola línea para cada planilla detallada. Otros ejemplos de líneas que podría incluir son categorías de riesgo importante, como, por ejemplo, legales o de inclinaciones.

Tabla 6: ejemplo de tablero de resumen

Tablero	Estado	Resumen
1. Contexto del proyecto	Amarillo	Riesgo de implementación no mitigado
2. Financiero	Verde	Alza potencial suficiente, bajo riesgo a la baja
3. Procesos del proyecto	Rojo	Análisis realizado insuficiente
4. Evaluación de la calidad de los datos	Amarillo	Número de errores de datos reducido debido a un nuevo origen de datos

Invertir con incrementos graduales

Le sugerimos implementar una estrategia de inversión con incrementos graduales en relación con los proyectos de AA y recomendamos realizar revisiones regulares con el comité de dirección o la gerencia responsable. El intervalo entre las revisiones debe ser lo suficientemente amplio como para que haya habido un progreso, pero corto en relación con los plazos generales del proyecto; recomendamos una regularidad mínima de dos meses para los proyectos grandes. Como mínimo, una revisión debe realizarse en momentos clave o ante un cambio de fase de proyecto.

La información para la revisión incluye:

- Documentar los planes vigentes de evaluación, estado y mitigación
- Presentar el tablero de resumen y los tableros de control detallados, si corresponde
- Presentar las canalizaciones de datos más recientes utilizadas para el desarrollo del modelo y la producción (si desea obtener más información, consulte

- *Calidad de los datos*)
- Evaluar nuevamente los factores de riesgo y los beneficios esperados cuando haya información nueva o actualizaciones
- Ofrecer una recomendación acerca del rumbo futuro del proyecto en función de los ítems anteriores

Durante esta revisión, el tablero Resumen se puede usar para enfocar el análisis en los aspectos del proyecto que necesitan más atención; los tableros de control detallados pueden suministrar documentación de respaldo. Se puede utilizar un diagrama como *Figura 4* para realizar un seguimiento de la *historia* del proyecto con el transcurso del tiempo, a medida que se modifican el riesgo y las recompensas.

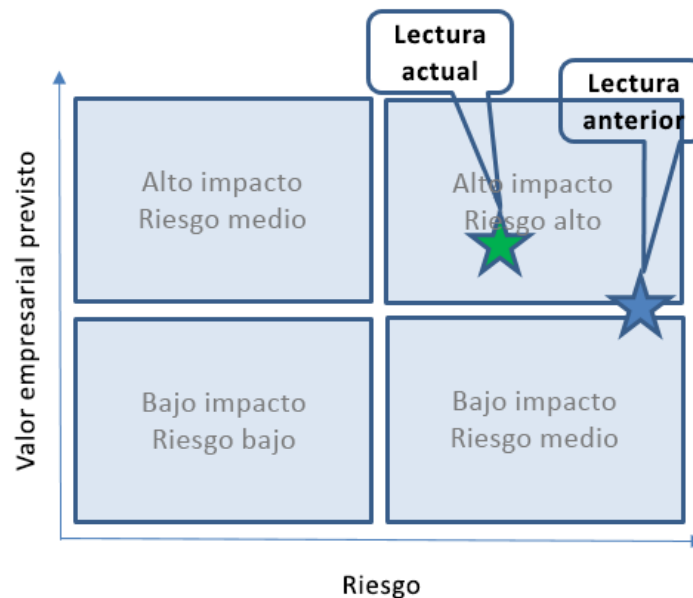


Figura 4: esquematización de la historia de riesgos y recompensas de un proyecto con el transcurso del tiempo

El resultado de la revisión debe ser una decisión. Por ejemplo, continuar invirtiendo en el proyecto, redireccionarlo o reenfocarlo, o finalizarlo. El resultado de cada revisión debe incluir:

- Una decisión formal para continuar invirtiendo, para modificar el rumbo en función de hallazgos iniciales o para cancelar el proyecto.
- Rumbo de otros equipos involucrados (como relaciones públicas, área legal, finanzas o recursos humanos)

- Rumbo de mitigaciones de riesgos específicos
- Aprobación de riesgos que se aceptaron

Desde la investigación a la producción

Una vez que haya desarrollado un modelo de AA que parezca producir buenos resultados, la meta es ponerlo en producción y empezar a generar predicciones. Este es el momento en que muchas compañías tienen dificultades. Las siguientes prácticas pueden facilitar dicha transición.

Pasar de la investigación al desarrollo

Existen diferencias metodológicas fundamentales entre las etapas de investigación y desarrollo:

- **Investigación:** durante esta fase, muchas estrategias y análisis se prueban y descartan rápidamente. Algunas ideas se analizan parcialmente y, a continuación, se dejan de lado. Con frecuencia, se utiliza un bloc de notas de Jupyter o Zeppelin como historial de las estrategias que se probaron, en vez de los blocs de notas físicos que los investigadores solían utilizar para documentar su investigación. No se invierte tiempo en escribir código de recuperación de errores ni en escribir subrutinas, ya que no se sabe si el código se utilizará alguna vez.
- **Desarrollo:** durante esta fase, existen *requerimientos*, que se producen como resultado de la etapa de investigación. Se conoce un método para resolver el problema. Sin embargo, el código en el bloc de notas del investigador no suele ser de calidad de producción. Generalmente, es necesario rediseñar el código del investigador para lograr que este sea adecuado para un entorno de producción.

Si bien los modelos de AA se crean para identificar patrones estadísticos frecuentes en una población (*vista del portafolio*), el punto de enlace de inferencia en producción está evaluando y actuando en un caso individual. Se trata de una perspectiva diferente entre la investigación y la producción.

Lamentablemente, el método para comunicar los requerimientos al equipo de desarrollo suele ser facilitar el bloc de notas de Jupyter o Zeppelin del investigador o un conjunto de secuencias de comandos escritas en Python o R. Si el equipo de desarrollo vuelve a desarrollar y optimizar el código para producción mientras el equipo de investigación continúa trabajando a partir de su bloc de notas básico, existe el problema de las versiones del código y de la identificación de los cambios.

Si bien la comprensión de este desafío aún es preliminar, los siguientes métodos parecen prometedores:

- Motive a los científicos de datos para que comprendan la fase de implementación y a los ingenieros para que comprendan la fase de investigación. Desarrollar una comprensión integral es invaluable.
- Motive a los científicos de datos para que consideren los requisitos de producción y la complejidad técnica de la fase de desarrollo al momento de considerar diseños de modelos en la fase de investigación.³⁰ Por ejemplo, si el requisito es para inferencias en tiempo real, ¿el modelo es lo suficientemente ligero para admitirlo?³¹
- Hemos descubierto que la integración de los ingenieros de datos con los científicos de datos puede realizarse correctamente. Estos ingenieros de datos trabajan para extraer los datos que los científicos de datos necesitan y los preparan para ellos. Esto permite a los científicos de datos enfocarse en su mayor valor, al mismo tiempo que el ingeniero de datos conoce los acuerdos que se realizaron durante el proceso de creación de modelos, en comparación con los datos de producción.
- Las rotaciones de tareas son otro método para fomentar este entendimiento mutuo. Por ejemplo, un científico de datos podría convertirse en un ingeniero de datos durante aproximadamente 3 meses.
- Las pruebas funcionales deben ser diseñadas por los científicos de datos para imponer que se produzcan los mismos resultados (o resultados similares definidos estadísticamente) por parte del código de producción en los mismos datos. El científico de datos selecciona un conjunto de datos representativo para realizar pruebas. Para probar funciones deterministas, como el diseño de características, los resultados de producción deben ser equivalentes a las funciones escritas por los científicos de datos. Si una serie de entrenamiento se incluye en la prueba, entonces se debe llegar a un acuerdo en relación con la tolerancia estadística con base en criterios de gestión de riesgos. A continuación, el equipo de producción implementará las pruebas en el entorno de producción e incluirá las pruebas en cualquier control de calidad de producción.

Modelo de AA como parte del ecosistema de software

El modelo de AA que desarrolla es un componente de un ecosistema de software más grande. Como se describe en la publicación [But What Is This 'Machine Learning Engineer' Actually Doing?](#)³², aún deben aplicarse todas las prácticas de administración e ingeniería de software normales, incluida la seguridad, el registro y la monitorización, la administración de tareas, el control de versiones de la API, etcétera.

Este ecosistema se debe administrar con prácticas de ingeniería de software y la nube. Por ejemplo:

- Pruebas A/B e integrales
- Control de las versiones de API, si se utilizan en varias versiones del modelo
- Fiabilidad y conmutación por error
- Mantenimiento constante
- Prácticas recomendadas para la infraestructura en la nube, como integración e implementación continuas (CI/CD)

Las consideraciones especiales en relación con los siguientes puntos se pueden justificar cuando un modelo de AA se entrega en un entorno de producción:

- Aplicar disciplinas de ingeniería de software.
Agregar código de recuperación de errores y garantizar que existan pruebas para datos de entrada inesperados. Realice las mismas pruebas unitarias, controles de calidad y pruebas de aceptación del usuario que se realizan para otros sistemas. Si el sistema de AA pasó de la fase de investigación a la de desarrollo, es posible que algunas de estas prácticas de ingeniería de software esperadas se hayan aplicado de manera incoherente.
- Controle, identifique y explique los cambios en los orígenes de datos.
Los datos podrían cambiar con el paso del tiempo. Los cambios en el software que produce un origen de datos pueden tener efectos directos.
- Realice una monitorización y una evaluación permanentes de los resultados.

Evalúe las expectativas en relación con los resultados del sistema de AA. Cree métodos para comprobar el índice de error y las clases de errores en relación con las expectativas del proyecto. Si el índice de error general es el mismo, ¿las mismas proporciones de las diferentes clases de error siguen siendo las mismas? ¿Ocurren cambios en el modelo?

- Cree métodos para recopilar datos de inferencias de producción que se puedan utilizar para mejorar los futuros modelos.

Conclusión

En este documento técnico se proporcionan algunas buenas prácticas comprobadas para maximizar el éxito de sus proyectos de AA. Se explica de qué manera los proyectos de AA pueden adaptarse a un marco económico bien comprendido. La identificación de las clases de riesgos que se aplican al proyecto específico permite administrarlas con técnicas de gestión de riesgos. Utilizar una estrategia de inversión en proyectos con incremento gradual, que incluya revisiones regulares del proyecto en relación con el modelo económico definido para el proyecto y los riesgos identificados, provee a la dirección ejecutiva información acerca de los riesgos que están aceptando y los posibles resultados del proyecto. Estas buenas prácticas pueden ayudarlo a asegurarse de que su proyecto de AA cumpla con los resultados esperados.

En las palabras de Andy Jassy:

No son solo los servicios y los modelos de AA correctos los que le permiten implementar el aprendizaje automático a escala de la manera que desea; sino que también se trata de ubicarlos en el sistema correcto que sea seguro, completo, rentable, y que tenga rendimiento operativo y los controles de acceso adecuados, lo que le permitirá obtener los resultados empresariales que desea.

Revisiones del documento

Fecha	Descripción
Febrero de 2019	Primera publicación

Apéndice: ejemplos de tableros de control

En esta sección se incluye un conjunto de tableros de control vacíos que puede utilizar en sus proyectos.

Contexto del proyecto

El *contexto del proyecto* aborda el entorno social, empresarial y normativo del proyecto.

Tabla A.1: ejemplo de tablero de control: contexto del proyecto

Categoría	Requisito o riesgo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
Ética				
	El modelo toma <i>decisiones con consecuencias importantes</i>			
	Privacidad			
	Legitimidad, inclinaciones			
	Riesgo de mala prensa			
	Necesidad de transparencia y capacidad de auditoría			
	Aplicabilidad/éxito del AA para esta aplicación			
	Desarrollo/pruebas de mundo cerrado e implementación de mundo abierto			
	Impacto de las inferencias del modelo de AA			

Finanzas

El tablero de control sobre *finanzas* identifica los costos y los beneficios del problema que está intentando resolver con el AA y del sistema de AA que está desarrollando.

Tabla A.2 : ejemplo de tablero de control: finanzas

Categoría	Requisito o riesgo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
	Modelo financiero creado			
	Rendimiento en alza potencial			
	Posible riesgo a la baja			
	Desventaja del peor de los casos			
	Responsabilidad			
	Costo de crear un modelo			
	Costo de mantenimiento del modelo			
	Calidad de las predicciones del modelo en relación con las expectativas			
	Incertidumbre en relación con las predicciones del modelo			

Procesos de proyectos

El tablero de control de *procesos del proyecto* aborda procesos del proyecto de AA que se omiten fácilmente debido al entusiasmo de desarrollar y probar el algoritmo y de identificar resultados prometedores.

Tabla A.3: ejemplo de tablero de control: procesos del proyecto

Categoría	Requisito o riesgo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
	Investigación o desarrollo			
	Disponibilidad y capacidades del equipo del proyecto			
	Plazos del proyecto			
	Pruebas para inclinaciones aplicadas			
	Análisis <i>long tail</i> realizado			
	Análisis estadístico validado			
	Análisis económico de métricas de modelos			
	<i>Control de nivel de compromiso</i> del equipo			
	Procedimientos de validación y verificación completados			
	Integración con procesos y sistemas existentes			
	Instrumentación y monitorización vigentes			
	Revisiones del modelo de producción			

Calidad de los datos

El tablero de control de *calidad de los datos* destaca las áreas que con frecuencia son problemáticas en los proyectos de AA y que pueden desencaminar el proyecto con facilidad si no se las identifica y resuelve

Tabla A.4: ejemplo de tablero de control: calidad de los datos

Categoría	Requisito o riesgo	¿Problema para el proyecto? (S/N)	Estado (rojo, amarillo, verde)	Observaciones: aplicabilidad, estado, mitigaciones
	Precisión de los datos de entrada			
	Exactitud de los datos de entrada			
	Volúmenes de datos y duración			
	Orígenes de datos y procesamiento previo validados			
	Canalización de datos del modelo y producción			
	Cambios en los datos con el transcurso del tiempo: procesos considerados			

Resumen

Tabla A.5: ejemplo de tablero de control: resumen

Tablero	Estado	Resumen
1. Contexto del proyecto		
2. Finanzas		
3. Procesos del proyecto		
4. Evaluación de la calidad de los datos		

Notes

- ¹ Fleming, Reetika y Phil Ferscht. "How to Avoid Your Looming Machine Learning Crisis". HFS Research, julio de 2018. https://1pcll3wzgyqw5kf62erficsw-wpengine.netdna-ssl.com/wp-content/uploads/2018/07/RS_1807_HfS-POV-Machine-Learning-Crisis.pdf.
- ² Dr. Polonski Vyacheslav. "AI Solutionism". Towards Data Science, 21 de junio de 2018. <https://towardsdatascience.com/risks-of-ai-solutionism-dangers-of-machine-learning-and-artificial-intelligence-in-politics-and-government-728b7577a243>.
- ³ Bonnington, Christina y Rachel Withers. "It Was a Big Year for A.I." *Slate*, 28 de diciembre de 2017. <http://www.slate.com/technology/2018/06/why-doctors-offices-still-use-fax-machines.html>
- ⁴ "Preparing for the Future of Artificial Intelligence". Consejo Nacional de Ciencia y Tecnología, octubre de 2016
- ⁵ "Preparing for the Future of Artificial Intelligence". Consejo Nacional de Ciencia y Tecnología, octubre de 2016
- ⁶ "AI Expert Andrew Ng Wants to Improve Manufacturing". *Fortune*, 24 de abril de 2018. <http://fortune.com/2018/04/24/data-sheet-andrew-ng-ai-manufacturing/>.
- ⁷ Jordan, Michael I. "Artificial Intelligence: The Revolution Hasn't Happened Yet", 18 de abril. <https://medium.com/@mijordan3/artificial-intelligence-the-revolution-hasnt-happened-yet-5e1d5812e1e7>.

- ⁸ Biewald, Lukas. "Why Are Machine Learning Projects so Hard to Manage?" *Medium* (blog), 28 de enero de 2019. <https://medium.com/@l2k/why-are-machine-learning-projects-so-hard-to-manage-8e9b9cf49641>.
- ⁹ Por ejemplo: Hollingsworth, Eric. "Unintentional Data", 12 de octubre de 2017. <http://www.unofficialgoogledatascience.com/2017/10/unintentional-data.html>.
- ¹⁰ Jordan, Michael I. "Artificial Intelligence — The Revolution Hasn't Happened Yet", 18 de abril. <https://medium.com/@mijordan3/artificial-intelligence-the-revolution-hasnt-happened-yet-5e1d5812e1e7>.
- ¹¹ Por ejemplo, el problema de las pruebas múltiples, como se lo describe con humor en XKCD: <https://xkcd.com/882/>
- ¹² Por ejemplo: Yosinski, Jason, Jeff Clune, Yoshua Bengio y Hod Lipson. "How Transferable Are Features in Deep Neural Networks?" *ArXiv:1411.1792 [Cs]*, 6 de noviembre de 2014. <http://arxiv.org/abs/1411.1792>. Karpathy, Andrej. "CS231n Convolutional Neural Networks for Visual Recognition". Acceso: 3 de agosto de 2018. <http://cs231n.github.io/transfer-learning/>.
- ¹³ Por ejemplo: "15 Insane Things That Correlate With Each Other". Acceso: 4 de enero de 2019. <http://tylervigen.com/spurious-correlations>.
- ¹⁴ https://en.wikipedia.org/wiki/Concept_drift
- ¹⁵ Megler, V. M., Kristin Tufte y David Maier. "Improving Data Quality in Intelligent Transportation Systems". *ArXiv:1602.03100 [Cs]*, 9 de febrero de 2016. <http://arxiv.org/abs/1602.03100>.
- ¹⁶ "Preparing for the Future of Artificial Intelligence". Consejo Nacional de Ciencia y Tecnología, octubre de 2016
- ¹⁷ Anderson, Jesse. "Data Engineers vs. Data Scientists". O'Reilly Media, 11 de abril de 2018. <https://www.oreilly.com/ideas/data-engineers-vs-data-scientists>
- ¹⁸ Anderson, Jesse. "Data Engineers vs. Data Scientists". O'Reilly Media, 11 de abril de 2018. <https://www.oreilly.com/ideas/data-engineers-vs-data-scientists>
- ¹⁹ Megler, Veronika y Scott Gregoire. "Training Models with Unequal Economic Error Costs Using Amazon SageMaker". *Amazon Web Services* (blog), 18 de septiembre de 2018. <https://aws.amazon.com/blogs/machine-learning/training-models-with-unequal-economic-error-costs-using-amazon-sagemaker/>.

- ²⁰ Julia Angwin, Jeff Larson. "Machine Bias Risk Assessments in Criminal Sentencing". Text/html. ProPublica, 23 de mayo de 2016.
<https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing>
- ²¹ Vincent, James. "Google's AI Sounds like a Human on the Phone — Should We Be Worried?" The Verge, 9 de mayo de 2018.
<https://www.theverge.com/2018/5/9/17334658/google-ai-phone-call-assistant-duplex-ethical-social-implications>. Statt, Nick. "Google Now Says Controversial AI Voice Calling System Will Identify Itself to Humans". The Verge, 10 de mayo de 2018.
<https://www.theverge.com/2018/5/10/17342414/google-duplex-ai-assistant-voice-calling-identify-itself-update>
- ²² Por ejemplo: Corbett-Davies, Sam y Sharad Goel. "The Measure and Mismeasure of Fairness: A Critical Review of Fair Machine Learning". *ArXiv:1808.00023 [Cs]*, 31 de julio de 2018. <http://arxiv.org/abs/1808.00023>. Bolukbasi, Tolga, Kai-Wei Chang, James Y. Zou, Venkatesh Saligrama y Adam T. Kalai. "Man Is to Computer Programmer as Woman Is to Homemaker? Debiasing Word Embeddings". En *Advances in Neural Information Processing Systems*, 4349–4357, 2016.
<http://papers.nips.cc/paper/6228-man-is-to-computer-programmer-as-woman-is-to-homemaker-debiasing-word-embeddings.pdf>; Snyder, Kieran. "Language in Your Job Post Predicts the Gender of Your Hire". Textio Word Nerd, 21 de junio de 2016.
<https://textio.ai/gendered-language-in-your-job-post-predicts-the-gender-of-the-person-youll-hire-cd150452407d>.
- ²³ "Software In Fatal Self-Driving Uber Crash Reportedly Recognized Woman, Then Ignored Her". HuffPost South Africa, 8 de mayo de 2018.
https://www.huffingtonpost.co.za/2018/05/08/software-in-fatal-self-driving-uber-crash-reportedly-recognized-woman-then-ignored-her_a_23429459/ [Tenga en cuenta que existen artículos posteriores que profundizan en los detalles del accidente: el vehículo sí vio al peatón, pero no tenía ningún mecanismo para informar al conductor la acción que el sistema asumió que el conductor tomaría. El ejemplo resulta útil de todas maneras.]
- ²⁴ Por ejemplo: en 2018, la Unión Europea comenzó a aplicar una ley que exige que cualquier decisión tomada por una máquina debe poder explicarse inmediatamente, bajo pena de multas.

- ²⁵ Amadeo, Kimberly. "How a 1998 Bailout Led to the 2008 Financial Crisis". The Balance. Acceso: 29 de enero de 2019. <https://www.thebalance.com/long-term-capital-crisis-3306240>.
- ²⁶ <https://labwrite.ncsu.edu/Experimental%20Design/accuracyprecision.htm>
- ²⁷ Por ejemplo, Jordan, Michael. "Artificial Intelligence — The Revolution Hasn't Happened Yet". *Medium* (blog), 19 de abril de 2018. <https://medium.com/@mijordan3/artificial-intelligence-the-revolution-hasnt-happened-yet-5e1d5812e1e7>
- ²⁸ Young, S. Stanley y Alan Karr. "Deming, Data and Observational Studies: A Process out of Control and Needing Fixing". *Significance* 8, n.º 3 (septiembre de 2011): 116–20. <https://doi.org/10.1111/j.1740-9713.2011.00506.x>
- ²⁹ Jordan, Michael I. "Artificial Intelligence — The Revolution Hasn't Happened Yet", 18 de abril. <https://medium.com/@mijordan3/artificial-intelligence-the-revolution-hasnt-happened-yet-5e1d5812e1e7>.
- ³⁰ Por ejemplo, "Evaluamos algunos de los métodos nuevos sin conexión, pero los beneficios en exactitud adicional que medimos no parecen justificar el esfuerzo de ingeniería necesario para incorporarlos en un entorno de producción." Blog, Netflix Technology. "Netflix Recommendations: Beyond the 5 Stars (Part 1)". *Medium* (blog), 6 de abril de 2012. <https://medium.com/netflix-techblog/netflix-recommendations-beyond-the-5-stars-part-1-55838468f429>.
- ³¹ Por ejemplo, en Blog, Netflix Technology, se explica cómo combinar modelos para crear recomendaciones en los niveles sin conexión, conexión intermedia y en tiempo real. "System Architectures for Personalization and Recommendation". *Medium* (blog), 27 de marzo de 2013. <https://medium.com/netflix-techblog/system-architectures-for-personalization-and-recommendation-e081aa94b5d8>.
- ³² Consulte el diagrama de: Dudek, Tomasz. "But What Is This 'Machine Learning Engineer' Actually Doing?" *Medium* (blog), 27 de mayo de 2018. <https://medium.com/@tomaszdudek/but-what-is-this-machine-learning-engineer-actually-doing-18464d5c699>.