

sigma

La inteligencia mecanizada en los seguros: nociones para una transformación integral del negocio

- 01 Resumen
- 04 Inteligencia
mecanizada:
sentando un
entendimiento común
- 09 Implementación de un
sistema de inteligencia
mecanizada
- 17 La inteligencia
mecanizada
en los seguros
- 24 Despliegue progresivo
en toda la organización
- 34 Conclusión

Resumen

La inteligencia mecanizada ofrece un considerable potencial para el aumento de ingresos y el ahorro de costes.

En ciertas áreas de la cadena de valor de los seguros, ya se aplican como práctica habitual métodos de inteligencia mecanizada convencionales, pero estos podrían verse reemplazados por enfoques más avanzados.

No obstante, el despliegue en toda la organización de sistemas basados en la inteligencia mecanizada sigue siendo limitado.

La inteligencia mecanizada (MI) afecta a numerosos sectores, ofreciéndoles un considerable potencial para la generación de ingresos y el ahorro de costes. Hasta la fecha, en el ámbito de los seguros la inteligencia mecanizada ha traído mejoras en áreas tales como el análisis de clientes y la tramitación de siniestros, basándose sobre todo en la tecnología de aprendizaje automático (ML). Sin embargo, el margen de beneficios para el sector va mucho más allá: entre otras cosas, la inteligencia mecanizada puede ayudar a las aseguradoras a procesar de forma más eficiente el texto procedente de contratos, documentos, correos electrónicos y otras herramientas de comunicación *online*, así como a analizar los enormes volúmenes de datos procedentes de la economía digital y acumulados por los dispositivos del Internet de las Cosas (IoT). Las aseguradoras pueden utilizar esa información para mejorar el diseño, la tarificación y la distribución de coberturas, así como para ampliar su alcance a nuevos mercados.

Algunos métodos de inteligencia mecanizada convencionales, tales como la regresión logística, se han convertido en herramientas estándar de la industria aseguradora para el diseño de modelos de evaluación y predicción de riesgos. Aun así, por lo general esas herramientas únicamente favorecen una productividad parcial y excesivamente específica. Se pueden obtener beneficios transformadores para toda la organización con una mayor inversión en ingeniería de datos. Esta concentración en la ingeniería de datos también resulta necesaria para materializar el potencial para toda la organización de un aprendizaje automático (ML) y una inteligencia artificial (IA) más avanzados. Las primeras compañías en adoptar esos enfoques están registrando resultados positivos en determinadas áreas, tales como una mayor rapidez en la liquidación de siniestros, unas prácticas de venta cruzada (*cross-selling*) y venta adicional (*up-selling*) más selectivas, y una mejor calificación de riesgos. Las tecnologías fundacionales necesarias para llevar a cabo labores de inteligencia mecanizada continúan evolucionando con rapidez a medida que los algoritmos se vuelven más fáciles de usar y baratos. Como consecuencia, esperamos que algunos procesos que actualmente resultan rentables con la inteligencia mecanizada convencional puedan verse suplantados por nuevos enfoques de aprendizaje automático e inteligencia artificial, inaugurando así nuevas vías de crecimiento.

Sin embargo, más allá de esos progresos, aún queda mucho para el despliegue en toda la empresa de sistemas basados en inteligencia mecanizada en el sector asegurador. Revisando los datos de las encuestas, hemos descubierto que menos del 10% de las empresas de todos los sectores han sido capaces de pasar de las pruebas piloto con la inteligencia mecanizada a su despliegue en múltiples procesos, y algunos de los motivos principales son la disponibilidad y la calidad de los datos. Muchos enfoques de aprendizaje automático e inteligencia artificial requieren grandes cantidades de datos de elevada calidad para entrenar los algoritmos. Incluso la inteligencia mecanizada convencional se ve dificultada por la calidad de los datos. Hoy en día, numerosas áreas de interés para los sistemas basados en inteligencia mecanizada están funcionando con conjuntos de datos que no están completos, depurados o actualizados, lo cual confirma la importancia de la ingeniería de datos. Sin esas capacidades, el rendimiento de los modelos/algoritmos ha demostrado ser lento y costoso en relación con los procesos humanos existentes. Por el contrario, si se despliegan correctamente, los modelos/algoritmos pueden proporcionar un considerable retorno sobre la inversión, pero, a día de hoy, no están preparados para su despliegue a escala empresarial. La COVID-19 ha obligado tanto a los consumidores como a las empresas a incrementar su actividad digital, lo cual ha acelerado la necesidad de cambiar a modelos de negocio con una mayor orientación digital, reafirmando así el valor de una inteligencia mecanizada transformadora.

Resumen

Los problemas con la calidad y el tratamiento de los datos están generando interés en nuevas áreas del potencial de la inteligencia mecanizada.

No solo importan los modelos, hay toda una serie de aspectos que influyen en el éxito del despliegue a escala empresarial de sistemas basados en la inteligencia mecanizada.

En los últimos años, los problemas relacionados con la calidad y el tratamiento de los datos han provocado el desarrollo de nuevos enfoques, tales como el aprendizaje por refuerzo (*reinforcement learning*) y la modelización de conjuntos (*ensemble modelling*). Los denominados modelos/algoritmos híbridos, basados, por ejemplo, en una combinación de conocimientos procedentes de la física y el aprendizaje automático y enfoques de inferencia causal, son menos sensibles a la calidad de los datos y a las deficiencias en la potencia de cálculo. Estas son solo dos de las numerosas áreas en las que innovadoras investigaciones tratan de abordar problemas específicos de rendimiento de los modelos y capacidad de interpretarlos, aportando soluciones que podrían pasar a formar parte de futuras aplicaciones de inteligencia mecanizada para los seguros.

En suma, la viabilidad de la inteligencia mecanizada se suele evaluar basándose en pruebas de concepto/ensayos piloto a pequeña escala de modelos/algoritmos, pero eso no es suficiente. Es necesaria una perspectiva más holística, dado que la mayoría de las veces los fallos en la implementación resultan atribuibles a limitaciones organizativas, no a problemas del modelo. Los criterios para evaluar un nuevo proceso deberían incluir la integración de los costes y los beneficios tanto directos (de desarrollo y operación) como indirectos (organizativos y de oportunidad). Si bien los directores de datos (CDO) y los científicos de datos se están convirtiendo en algo habitual en las aseguradoras, una estrategia incompleta de datos a escala organizativa y una inapropiada arquitectura tecnológica subyacente limitarán su eficacia. El diseño del sistema, los planes de implementación y los criterios de éxito deberían centrarse en el contexto de los flujos de trabajo empresariales, el apoyo a la toma de decisiones y la productividad de la compañía. También deben tenerse en cuenta los riesgos normativos relativos a la innovación tecnológica en los seguros, en particular en torno a la privacidad y el uso de los datos. Es importante señalar que un proyecto de inteligencia mecanizada también necesita unas comunicaciones claras y comprensibles en todas sus facetas con el fin de garantizar el respaldo de la alta dirección y la necesaria financiación.

Glosario: terminología clave sobre aprendizaje automático

Término	Descripción
Algoritmos	Una lista de instrucciones que puede poner en práctica un ordenador.
Inteligencia mecanizada	Un conjunto de programas y procesos que permiten a una máquina (por ejemplo, un ordenador) aplicar datos e información para resolver problemas.
Ajuste de curvas convencional	Una forma básica de inteligencia mecanizada, por ejemplo, los modelos lineales generalizados. Estos se basan en suposiciones para entender cómo se relacionan entre sí ciertas variables con el fin de <i>crear la curva que mejor se adapte</i> a la relación existente entre determinados datos concretos. Además, el ajuste de curvas convencional puede captar algunos tipos de relaciones no lineales.
Aprendizaje automático (ML)	Algoritmos que aprenden de los datos y analizan relaciones más complejas, interdependientes y no lineales entre variables. Se utiliza habitualmente en la clasificación, la regresión y el reconocimiento de patrones.
Inteligencia Artificial (IA)	La IA va más allá del aprendizaje automático al facilitar la <i>aplicación adaptativa de la comprensión</i> . Con estos algoritmos, las máquinas pueden almacenar y aplicar sus aprendizajes de manera flexible, incluso a contextos no previstos en un principio.
Aprendizaje supervisado	Entrenar a una máquina <i>utilizando datos que están etiquetados</i> , es decir, ya marcados con la respuesta correcta. Esos datos etiquetados hacen las veces de supervisor: la máquina infiere relaciones a partir de esa muestra, lo que luego utiliza para correlacionar nuevos ejemplos.
Aprendizaje no supervisado	El aprendizaje no supervisado se utiliza cuando <i>no se dispone de datos etiquetados</i> . Al no disponer de un maestro que entre a la máquina, esta tiene que descubrir por su cuenta estructuras ocultas en los datos no etiquetados. Se emplea para el agrupamiento (<i>clustering</i>) y la asociación.
Agrupamiento y asociación	Un algoritmo de agrupamiento trata de descubrir <i>agrupamientos intrínsecos</i> entre los datos, por ejemplo, agrupar a los tomadores de un seguro por su comportamiento de compra. Un problema de asociación es cuando una aseguradora trata de descubrir <i>reglas que describan</i> los datos, por ejemplo, los tomadores que contratan la póliza X también suelen contratar la póliza Y.
Aprendizaje por refuerzo	Algoritmos orientados a objetivos (agentes) que responden a la pregunta: <i>¿cómo se puede optimizar esto?</i> Por ejemplo, <i>¿cómo puede optimizarse la inversión en marketing para obtener el máximo rendimiento de la inversión (ROI)?</i> Aprende a través de la interacción con su entorno.
Aprendizaje de conjuntos	Utiliza <i>una combinación de múltiples algoritmos</i> para obtener un mejor rendimiento predictivo del que podría obtenerse de cualquiera de los algoritmos por sí solo.
Ingeniería de datos	La ingeniería de datos es el proceso de recopilación, tratamiento, almacenamiento y transformación de datos con fines analíticos.
Aprendizaje profundo	Imita al cerebro humano para <i>aprender sin supervisión humana</i> con datos no estructurados y no etiquetados.
Falso positivo	Una predicción que indica erróneamente que una condición o atributo concreto está <i>presente</i> .
Falso negativo	Una predicción que indica erróneamente que una condición o atributo concreto está <i>ausente</i> .
Aprendizaje automático basado en la física	Aprendizaje automático que incorpora, en un algoritmo/proceso de aprendizaje automático, <i>un modelo (por ejemplo, hidrodinámico) construido utilizando una teoría científica válida basada en el conocimiento de los sistemas físicos</i> , todo ello con el fin de proporcionar más estructura al modelo de lo que sería normal para un modelo de aprendizaje automático menos restringido (por ejemplo, aprendizaje supervisado o no supervisado). Con frecuencia, este enfoque híbrido es más fácil de interpretar y diagnosticar.
Redes generativas antagónicas	Las redes generativas antagónicas (GAN) introducen patrones de aprendizaje en los datos de manera que el <i>modelo puede generar nuevos ejemplos</i> que parecen lo suficientemente creíbles para pertenecer al conjunto de datos original. A continuación, los datos originales y los datos generados se pueden enfrentar unos a otros en el contexto de redes neuronales que compiten para desarrollar mejores modelos.
Inferencia causal	En inteligencia mecanizada, la inferencia causal hace referencia a enfoques que proporcionan más estructura para el control y la predicción mediante el desarrollo de capacidades que identifican los verdaderos desencadenantes de resultados <i>para hacer que un proceso de inteligencia mecanizada sea más robusto a las cambiantes circunstancias</i> , por ejemplo, tratar de organizar los desencadenantes causales de la obesidad para distinguir lo que se puede controlar en distintas subpoblaciones o analizar que opciones de diseño generan más clics en un sitio web.

Fuente: Swiss Re Institute

Inteligencia mecanizada: sentando un entendimiento común

Inteligencia mecanizada (MI) es un término genérico que abarca una serie de técnicas de tratamiento y manipulación de datos, que van desde la regresión logística convencional al más sofisticado aprendizaje profundo. Por lo general, los métodos de inteligencia mecanizada más avanzados se clasifican como aprendizaje automático (ML) e inteligencia artificial (IA). En la actualidad, resulta más sencillo ampliar técnicas convencionales para mejorar los procesos empresariales existentes. Sin embargo, en los últimos años se ha producido un crecimiento exponencial de la facilidad de uso y la eficacia de los algoritmos, y el aprendizaje automático y la inteligencia artificial, más sofisticados, podrían acabar suplantando a los enfoques convencionales.

La inteligencia mecanizada engloba programas y procesos que utilizan datos para permitir a una máquina resolver problemas.

El aprendizaje automático y algunos tipos de IA son enfoques analíticos más complejos del tratamiento de datos.

Tratamiento de la información y de los datos

Con frecuencia, el término inteligencia mecanizada (MI) se utiliza como sinónimo de inteligencia artificial (IA), un término cuya definición es igualmente variable y/o vaga. Con el fin de establecer un marco de referencia coherente a los efectos del presente informe y del debate público, definimos inteligencia mecanizada como un conjunto de programas y procesos que permiten a una máquina (la mayoría de las veces un ordenador) aplicar datos e información para resolver problemas. En la mayor parte de los casos, es necesaria la intervención humana para hacer que el proceso basado en inteligencia mecanizada resulte útil. Dentro de esta definición amplia de la inteligencia mecanizada, incluimos las siguientes categorías:

- **Ajuste de curvas convencional o enfoques estadísticos tradicionales**, tales como los modelos lineales generalizados (por ejemplo, la regresión lineal o logística). Estos enfoques se basan en suposiciones para entender cómo se relacionan entre sí ciertas variables con el fin de crear la curva o función matemática que mejor se adapte a la relación existente entre determinados datos concretos. Hay que tener en cuenta que el ajuste de curvas convencional también puede captar algunos tipos de relaciones no lineales.
- **Aprendizaje automático**: Algoritmos que aprenden de los datos y analizan relaciones más complejas, interdependientes y no lineales entre variables. Se utiliza habitualmente en la clasificación, la regresión y el reconocimiento de patrones.
- **Inteligencia Artificial**: va más allá del aprendizaje automático al facilitar la aplicación adaptativa de la comprensión. En la IA, los algoritmos imitan cualidades humanas tales como la capacidad de responder a situaciones que, por su contexto, resultan ambiguas. Con estos algoritmos, las máquinas pueden almacenar y aplicar sus aprendizajes de manera flexible, incluso a contextos no previstos en un principio. En este sentido, la IA más avanzada se denomina a veces computación neuromórfica o cognitiva. Algunos métodos de inteligencia artificial más modernos parecen reflejar una nueva clase de inteligencia en red denominada inteligencia de colmena.

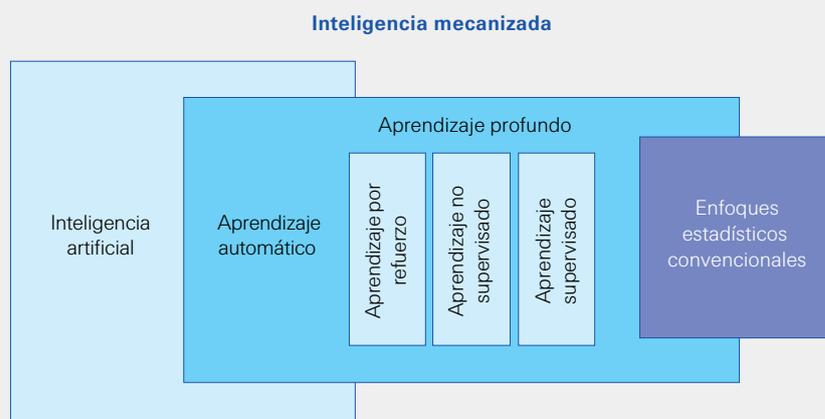
El ajuste de curvas convencional, el aprendizaje automático y la inteligencia artificial pueden ser independientes e interdependientes. Tal y como muestra la Figura 1, la IA suele incorporar métodos tanto de aprendizaje automático como de ajuste de curvas convencional. Dentro del aprendizaje automático, el aprendizaje supervisado ha sido ampliamente adoptado: en él, se utiliza la inteligencia humana para incorporar en cada elemento de los datos de muestra etiquetas con significado que ayudan a un algoritmo a comprender los datos. El aprendizaje no supervisado es el método empleado cuando no se dispone de datos etiquetados, como detectar agrupamientos de datos (por ejemplo, en seguros, agrupar a tomadores por su comportamiento de compra) o anomalías (por ejemplo, detección de fraudes, en colaboración con expertos en siniestros humanos)¹.

¹ Una de las tareas clave consiste en detectar cualquier agrupamiento o comportamiento de grupo específico en los datos observados.

Otros tipos de aprendizaje automático más novedosos están aún en sus primeras etapas de desarrollo.

El aprendizaje por refuerzo (RL) ofrece una mayor adaptabilidad y se ha aplicado con éxito en herramientas de realidad aumentada, como en los videojuegos². Sin embargo, en otros sectores este campo se encuentra aún en sus primeras etapas de desarrollo. Los algoritmos de aprendizaje por refuerzo no se limitan a los datos existentes, sino que buscan soluciones optimizadas basándose en recompensas o penalizaciones asociadas a cada una de las acciones emprendidas. El aprendizaje por refuerzo se puede combinar con simulaciones y aumento de datos o generación de datos artificiales (*data augmentation*) para compensar la existencia de datos incompletos, desordenados, no estacionarios o sesgados.

Figura 1
Esquema que muestra el solapamiento de diversas áreas dentro de la inteligencia mecanizada



Fuente: FSB, Swiss Re Institute

Resulta más sencillo ampliar modelos de inteligencia mecanizada convencionales para mejorar los procesos existentes en una empresa.

El objetivo de la inteligencia mecanizada, en particular cuando se despliega en empresas, es complementar o emular la deducción, el razonamiento y la resolución de problemas del ser humano. Una solución basada en inteligencia mecanizada puede tener más éxito y resultar más transformadora si se construye sobre un enfoque convencional, como la regresión logística, aun cuando los modelos de aprendizaje automático o inteligencia artificial funcionen mejor a la hora de predecir resultados, dado el mayor número de variables que pueden analizar. Ello es debido a que resulta más fácil ampliar el modelo convencional para mejorar los procesos existentes en una organización. La Figura 2 clasifica distintas técnicas de inteligencia mecanizada en función de unos criterios de complejidad: capacidad de interpretar los resultados de los modelos, facilidad de implementación, estabilidad de los modelos ante cambios en los datos, y velocidad de ejecución. Estos factores determinan el éxito en el despliegue de una solución de inteligencia mecanizada. Consideramos que, a medida que los algoritmos se vuelven más rápidos y baratos, los modelos de aprendizaje automático e inteligencia artificial, más sofisticados, podrían acabar suplantando a los métodos convencionales.

² El aprendizaje por refuerzo es un área del aprendizaje automático que se ocupa de cómo los agentes de software deben escoger sus acciones en un entorno para maximizar la noción de recompensa acumulada.

Figura 2
Espectro de complejidad de distintas categorías de inteligencia mecanizada

Complejidad	Enfoques/algoritmos*	Interpretación	Implementación	Estabilidad	Velocidad de ejecución	Categoría
Baja	Regresión lineal	Mayor	Mayor	Mayor	Mayor	Aprendizaje supervisado
	Clasificadores bayesianos ingenuos	Mayor	Mayor	Mayor	Mayor	Aprendizaje supervisado
	Aprendizaje basado en instancias	Menor	Menor	Mayor	Menor	Aprendizaje supervisado
	Máquinas de vectores de soporte	Menor	Menor	Menor	Menor	Aprendizaje supervisado
	Árboles de decisión	Mayor	Mayor	Menor	Mayor	Aprendizaje supervisado
	Random forest	Menor	Menor	Menor	Menor	Aprendizaje supervisado
	Potenciación de gradientes	Menor	Menor	Menor	Menor	Aprendizaje supervisado
	Aprendizaje profundo (CNN, RNN, NLP, BERT [^] , etc.)	Menor	Menor	Menor	Menor	Supervisado/semisupervisado
	Redes generativas antagónicas (GAN)	Menor	Menor	Menor	Menor	Supervisado/no supervisado/semisupervisado
	Árboles de clasificación óptimos	Mayor	Menor	Mayor	Menor	Aprendizaje supervisado
Alta	Aprendizaje por refuerzo	Menor	Menor	Menor	Menor	Aprendizaje por refuerzo
	Aprendizaje de conjuntos	Menor	Menor	Menor	Menor	Combinación de técnicas

Mayor Menor

* Es posible que ciertos enfoques/algoritmos resulten más o menos apropiados que otros para resolver determinados tipos de problemas. Notas: Interpretación se refiere a la transparencia del algoritmo y a la capacidad de explicarlo. Implementación se refiere al esfuerzo necesario para desarrollar algoritmos y al volumen y la complejidad de los datos necesarios para entrenar los modelos. Estabilidad se refiere a la sensibilidad de su funcionamiento a los cambios en los datos y los supuestos. Velocidad de ejecución se refiere al tiempo necesario para completar la ejecución de principio a fin, desde la incorporación de los datos hasta los resultados finales.

[^] El codificador bidireccional BERT (*bidirectional encoder representations from transformers*) es una mejora sustancial del procesamiento del lenguaje natural (NLP). Las CNN son redes neuronales convolucionales; las RNN son redes neuronales recurrentes; las GAN son redes generativas antagónicas.

Fuente: Swiss Re Institute

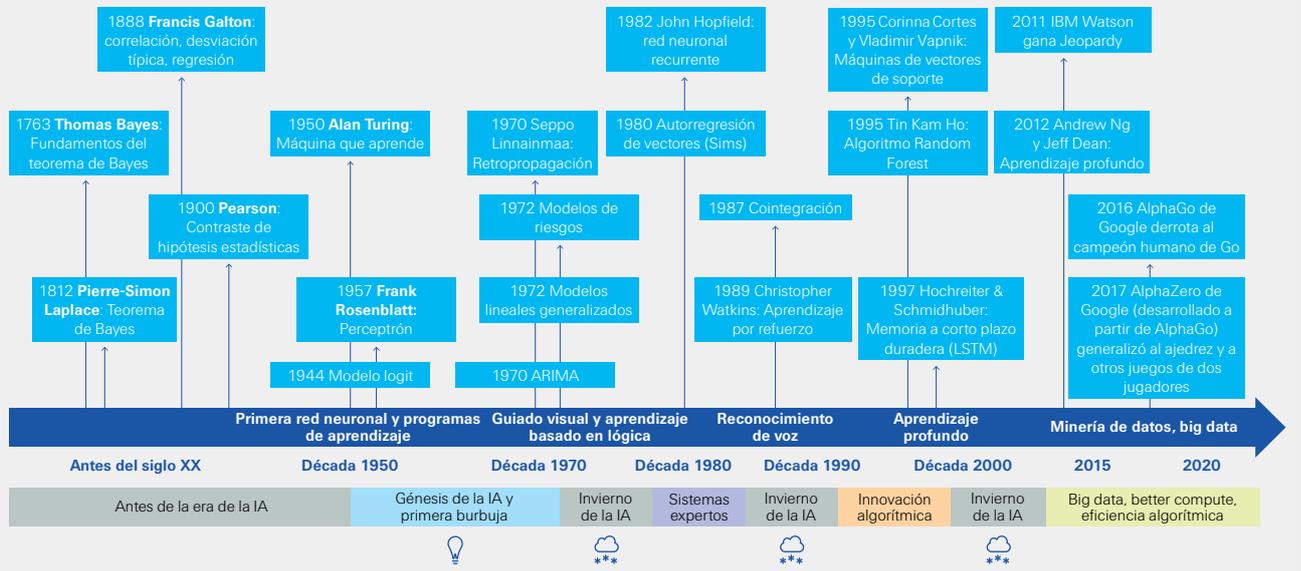
Cuidado con las modas

La evolución de la IA ha pasado por periodos de mayor y menor interés.

Como término, la inteligencia artificial se acuñó por vez primera en la década de 1950. Desde entonces, esta técnica ha proliferado bastante, con intervalos de reducción del interés y, por ende, de la financiación («inviernos de la IA»). A comienzos de la década de 1990, se produjo un aumento del interés con el desarrollo de las redes neuronales³. Sin embargo, no se materializó por completo todo su potencial, lo cual condujo a otro invierno de la IA en la década de 2000, que tan solo hemos superado en los últimos diez años.

³ Una red de neuronas artificiales imita las conexiones y respuestas asociadas del cerebro humano.

Figura 3
Cronologías del desarrollo de la inteligencia mecanizada



Fuente: Swiss Re Institute

Los periodos de interés también pueden generar una cierta burbuja.

Aun así, todo parece indicar que el gasto en IA crecerá con fuerza en los próximos años.

Mejoras exponenciales en la eficiencia de los algoritmos podrían hacer que el despliegue de técnicas de inteligencia mecanizada más avanzadas resulte más rentable.

En los últimos años, se ha producido un notable avance de las capacidades en materia de inteligencia artificial y aprendizaje automático debido a las mejoras en la capacidad de procesamiento, la evolución de la computación en la nube (*cloud computing*), la explosión de datos y la transformación digital, lo cual también ha provocado, en nuestra opinión, la aparición de una moda injustificada. Por ejemplo, un estudio de 2019 reveló que dos quintas partes de las denominadas *start-ups* de IA de Europa que afirman utilizar la IA en realidad no lo hacen y, cuando lo hacen, a menudo los usos que hacen de la IA son bastante básicos⁴. En algunos casos, se han incluido menciones a la inteligencia artificial y el aprendizaje automático en los argumentarios comerciales para mejorar las oportunidades de obtener financiación, si bien el nivel de sofisticación de la IA que se vende es aún bastante rudimentario.

Con frecuencia, el gasto en tecnología sigue la moda. Según estimaciones de International Data Corporation (IDC), el gasto en sistemas de IA alcanzará los 98 000 millones de USD en 2023 (lo cual supone una tasa de crecimiento anual compuesta [CAGR] del 27 % desde 2019)⁵. Esas encuestas no reflejan necesariamente todo el gasto en inteligencia mecanizada, pues parte de este se agrupa con los presupuestos generales de TI, por lo que resulta difícil obtener una estimación completa. Últimamente, muchas de las categorías de la inteligencia mecanizada han pasado por el pico de las expectativas sobredimensionadas (la moda o burbuja), y algunas están cayendo al abismo de la desilusión⁶. En lo que respecta a los seguros en particular, no ha habido grandes cambios en los últimos 30 años. Si acaso, el sector está a punto de entrar en la «rampa de consolidación».

No obstante, las tecnologías fundacionales necesarias para facilitar el exitoso despliegue de la inteligencia mecanizada en toda la empresa continúan evolucionando con rapidez a medida que los algoritmos se vuelven más rápidos, certeros y baratos⁷. La consecuencia será que algunos procesos empresariales que

⁴ *The State of AI Divergence*, MMC Ventures, marzo de 2019.

⁵ *Worldwide Spending on Artificial Intelligence Systems Will Be Nearly USD 98 Billion in 2023*, IDC, septiembre de 2019.

⁶ *Hype Cycle for Artificial Intelligence*, Gartner, 25 de julio de 2019.

⁷ A. Agrawal, J. Gans et al., *Prediction Machines: The Simple Economics of Artificial Intelligence*, 2018.

Inteligencia mecanizada: sentando un entendimiento común

ya son rentables con la inteligencia mecanizada convencional podrían, de pronto, serlo aún más con una inteligencia mecanizada más moderna (por ejemplo, el aprendizaje automático y la inteligencia artificial). La Figura 4 (izquierda) muestra lo que ha sido un aumento exponencial de la eficiencia (véase el eje Y) de los algoritmos (por ejemplo, AlexNet, ShuffleNet) a lo largo de los últimos años, superando con creces la tasa de mejora de las capacidades según la ley de Moore⁸. Por ejemplo, la capacidad de procesamiento de algoritmos más modernos, tales como EfficientNet en 2019, en una tarea de visión artificial supera con creces a la de AlexNet en 2012⁹.

Figura 4
Incremento de la eficiencia logarítmica (izquierda) y avance de la implementación de la IA (derecha)



Nota: un teraflop se refiere a la capacidad de un procesador para calcular 1 billón de operaciones de coma flotante por segundo
Fuente: D. Hernandez *et al.*, *Measuring the Algorithmic Efficiency of Neural Networks*, 2020.

Fuente: Swiss Re Institute (basada en múltiples encuestas, datos anonimizados, normalizados y adaptados para hacerlos comparables)

Hasta la fecha, las empresas que son nativas digitales han sido las más exitosas a la hora de desplegar una inteligencia mecanizada transformadora.

Hemos analizado una serie de encuestas (véase la Figura 4 derecha) y hemos descubierto que algunas empresas (menos del 10%) han logrado aprovechar proyectos piloto exitosos para desplegar la inteligencia mecanizada en múltiples procesos de toda la organización. La implementación de una inteligencia mecanizada capaz de transformar toda la empresa requiere una inversión inicial en la digitalización de las operaciones de toda la organización. Eso sentará las bases para que las empresas: (1) apliquen la inteligencia mecanizada a la automatización de los procesos; e (2) introduzcan nuevas propuestas que trasciendan los silos existentes para integrar los datos. Algunos ejemplos de implementaciones avanzadas son los de plataformas/empresas nacidas con la inteligencia artificial que dan prioridad a todo lo digital, como Uber y Airbnb. Entre estas también se incluyen empresas que empezaron con tecnología tradicional (por ejemplo, Microsoft o Amazon), pero que, desde entonces, han invertido mucho en su capacidad en materia de inteligencia mecanizada¹⁰. Las empresas de sectores más tradicionales, tales como los servicios financieros (incluidos los seguros), están tratando de no quedarse atrás. Para obtener beneficios a gran escala de la inteligencia mecanizada, primero tienen que digitalizar sus operaciones y eliminar los silos de datos. Esperamos ver avances en esa dirección a lo largo de la próxima década.

⁸ Según la ley de Moore, la velocidad y la capacidad de los ordenadores se duplican cada dos años.

⁹ En 2020, con algoritmos más eficientes, requería 44 veces menos potencia de cálculo que en 2012 entrenar a una red neuronal al nivel de AlexNet. En el mismo periodo de tiempo, la ley de Moore predice una mejora de 11 veces.

¹⁰ *AI from exploring to transforming: Introducing the AI Maturity Framework*, Element AI, mayo de 2020.

Implementación de un sistema de inteligencia mecanizada

La aplicabilidad y la implementación de la inteligencia mecanizada no son uniformes en todos los sectores. El éxito de la implementación depende de la disponibilidad de datos, los requisitos de capacidad de interpretación, la complejidad del sistema y la regulación. De hecho, el éxito de la implementación requiere un sólido argumento de negocio, unos arquitectos y desarrolladores de sistemas competentes, unos reglamentos que la apoyen, una dirección comprometida, y una estrategia de datos orientada a la producción que abarque toda la empresa. En el entorno de menor crecimiento tras la COVID-19, el ROI será una consideración clave cuando se evalúen los proyectos de analítica. Resulta fundamental la inversión en capacidad de ingeniería de datos para que las implementaciones tengan éxito.

Criterios de éxito

Entre las cosas que hay que plantearse se incluye...

Cuando las empresas se plantean el despliegue de sistemas basados en la inteligencia mecanizada, hay muchas cosas que deben tenerse en cuenta: qué herramientas de inteligencia mecanizada implementar; cómo solventar las limitaciones derivadas de los sistemas legados; dónde encontrar personal para resolver las deficiencias de capacidad; y cómo garantizar que se obtienen más beneficios que costes. La Tabla 1 presenta cuatro criterios fundamentales que pensamos que las empresas deberían analizar cuando se disponen a adoptar tecnologías relacionadas con la inteligencia mecanizada.

Tabla 1

Criterios para una exitosa implementación de la inteligencia mecanizada en toda la empresa a largo plazo

Criterios de éxito	Deficiencias actuales	Cómo son los proyectos exitosos
 <p>ROI positivo a largo plazo para los procesos integrales</p>	Subestimación de los costes de implementación, mal diseño de los nuevos procesos y flujos de trabajo adaptados a la inteligencia mecanizada, problemas de escalabilidad derivados de una mala planificación.	La arquitectura de los procesos y flujos de trabajo se ajusta a las fortalezas de la inteligencia mecanizada desplegada, los gastos recurrentes se detallan en el plan de implementación, se da prioridad a las cuestiones de integración, la seguridad y la privacidad se incorporan a la planificación desde el principio.
 <p>Estrategia de datos orientada a la producción</p>	Insuficiente inversión en la incorporación y el tratamiento de los datos, ausencia de una detallada custodia y administración de los datos, insuficiente número de ingenieros de datos.	Enfoque apropiado en la estrategia de datos, la ingeniería de datos, las herramientas de datos y la modelización de datos.
 <p>Usos que encajan con el contexto empresarial y normativo</p>	Entre otras cosas, los casos de uso no tienen en cuenta las limitaciones de los datos y los problemas organizativos que impiden que la inteligencia mecanizada agregue valor.	El despliegue aprovecha las fortalezas de la inteligencia mecanizada en el contexto de los procesos organizativos y los flujos de trabajo existentes. El plan de implementación incluye una clara correspondencia entre la inteligencia mecanizada y los puntos débiles de la organización, los datos y la viabilidad técnica se evalúan desde el principio.
 <p>Compromiso de la dirección</p>	La alta dirección no ha sido debidamente informada sobre la propuesta de despliegue de la inteligencia mecanizada, deficiente implementación por parte del personal de primera línea, mala coordinación e implicación de las unidades de negocio, y escasa comprensión de las operaciones de la inteligencia mecanizada.	Informes detallados y periódicos a la dirección, disposición para cambiar el proceso con el fin de dar cabida a los nuevos hallazgos, inversión constante y continuidad del talento para extraer valor.

Fuente: Swiss Re Institute

Rendimiento de la inversión a largo plazo

...el rendimiento de la inversión.

Para garantizar un rendimiento de la inversión (ROI) positivo a largo plazo en relación con el gasto en la transformación mediante la inteligencia mecanizada de procesos integrales que afectan a toda una empresa, hay varios factores que deben tenerse en cuenta:

- **Beneficios netos de la transformación de los flujos de trabajo en comparación con los gastos recurrentes:** Los beneficios del ejercicio de transformación en términos de reducción de costes, aumento de los ingresos y nuevas oportunidades de negocio deben ser mayores que los costes de integración organizativa, tanto directos (de desarrollo y operación) como indirectos (costes organizativos y de oportunidad). En una encuesta reciente, el 93 % de los encuestados de aseguradoras estadounidenses que estaban llevando a cabo el proceso de transformación mediante la inteligencia mecanizada manifestaron cierta preocupación en relación con los costes de implementación y el rendimiento de la inversión (ROI)¹¹. Muchos cálculos del ROI únicamente tienen en cuenta el coste de las soluciones de los proveedores, no los costes adicionales para el negocio (por ejemplo, tratamiento de los datos, entrenamiento, etc.). Además, el ROI es un cálculo cambiante, ya que los nuevos datos que van surgiendo (por ejemplo, la regulación y los cambios en el coste de datos clave) pueden hacer que las estimaciones iniciales de coste/beneficio resulten imprecisas. La Figura 5 presenta una serie de consideraciones clave en materia de costes/beneficios para la implementación de tales sistemas.

Figura 5

Consideraciones en materia de costes/beneficios para la implementación de sistemas basados en la inteligencia mecanizada



Fuente: Adaptación de V. M. Megler, *Managing ML Projects, Balance Potential with the Need for Guardrails*, febrero de 2019.

¹¹ *State of Artificial Intelligence and Machine Learning in the Insurance Industry Study*, LexisNexis® Risk Solutions, 3 de diciembre de 2019.

- **Rendimiento y eficiencia de los procesos integrales rediseñados:** La implementación de la inteligencia mecanizada debe examinarse a fondo en términos tecnológicos y en lo que respecta a las motivaciones y las limitaciones del negocio. Por ejemplo: (1) un nuevo proceso basado en la inteligencia mecanizada debería ser, al menos, tan preciso y robusto como el proceso actual, y más eficiente en su aprovechamiento del tiempo; y (2) el nuevo proceso debería generar nuevas oportunidades de negocio sostenibles. En ocasiones, las expectativas en lo que respecta al coste de realinear los recursos humanos para adaptarse a los beneficios previstos pueden no ser demasiado realistas. Por ejemplo, evidencias circunstanciales indican que, a veces, los sistemas de detección de fraudes de la inteligencia mecanizada señalan muchos más nuevos casos de los que el personal existente es capaz de verificar. Por tanto, las métricas que utilicemos deberán estar vinculadas a resultados de negocio realistas, en lugar de centrarse en el mero rendimiento del modelo.
- **Inversión necesaria para mantener la calidad y la solidez del sistema:** Un criterio clave para el éxito de los sistemas basados en la inteligencia mecanizada es la existencia de un marco eficaz de monitorización continua de la gestión del ciclo de vida del modelo. Con frecuencia, el desarrollo del modelo –incluso para la inteligencia mecanizada más avanzada– es el aspecto más sencillo y menos costoso del despliegue de la inteligencia mecanizada en una empresa. Sin embargo, es muy probable que la integración de un nuevo sistema de inteligencia mecanizada en una organización requiera un rediseño de los procesos y flujos de trabajo y represente la mayor parte de los costes de implementación del sistema. Además, mantener la integridad, seguridad y privacidad de un nuevo sistema requerirá un gran presupuesto al principio (aunque, para sistemas bien diseñados, estos costes de operación deberían disminuir con el tiempo).
- **Manejo de excepciones:** En el entorno posterior a la COVID-19, es posible que los modelos arrojen resultados inesperados debido a los enormes cambios en el comportamiento de los consumidores, los insumos de datos y la forma en que se gestionan los negocios. Sin embargo, el renovado auge de la digitalización creará una mayor cantidad de conjuntos de datos diversos para continuar afinando los modelos de inteligencia mecanizada, y ampliará el abanico de información de entrenamiento disponible para mejorar la capacidad de manejo de excepciones. Por otro lado, es posible que las empresas que ya están invirtiendo cuantiosas sumas, pero que ahora se enfrentan a cierta presión en materia de costes, prioricen sus proyectos con más cuidado y decidan continuar con aquellos que ya están arrojando un ROI positivo o están a punto de hacerlo. Hay varias áreas que seguirán recibiendo atención e inversiones, incluyendo las capacidades de automatización y detección de fraudes.

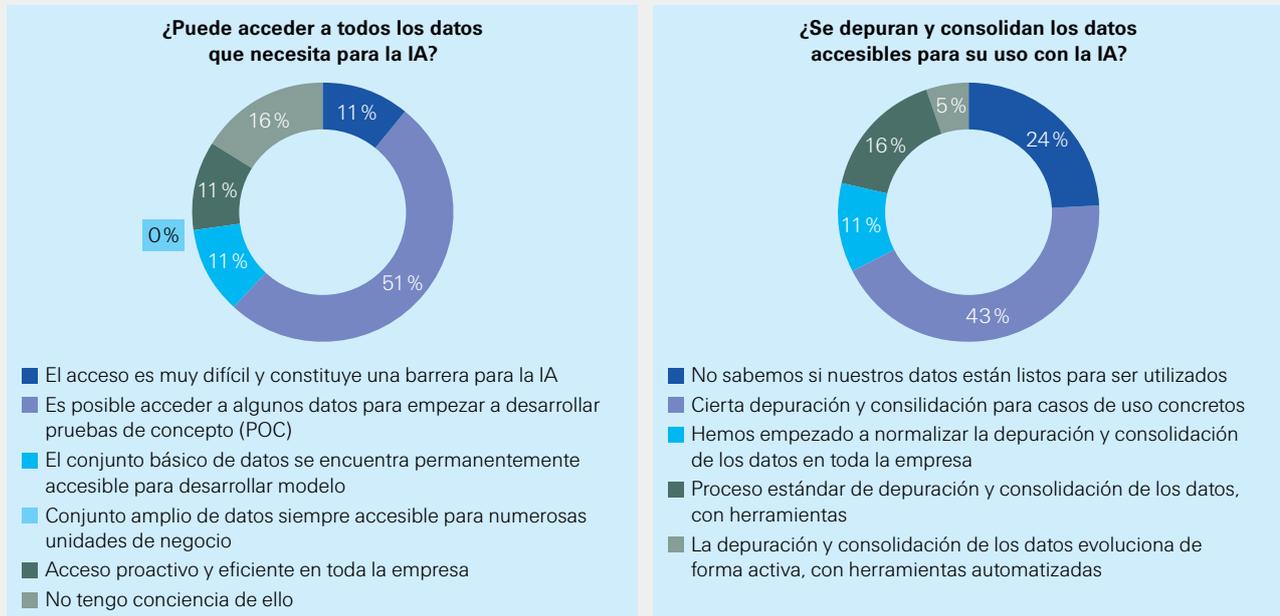
Estrategia de datos orientada a la producción

El rendimiento de un sistema basado en la inteligencia mecanizada depende mucho de la gestión de la cadena de valor de los datos.

A menudo, la implementación falla debido a una deficiente ingeniería de datos. En un proceso empresarial integral, unos algoritmos de baja calidad con una ingeniería de datos de alta calidad tenderán a superar a unos algoritmos de alta calidad con una ingeniería de datos de baja calidad. En la industria de los servicios financieros, las empresas suelen empezar por desarrollar un algoritmo y, luego, invierten poco en ingeniería de datos. Para tener un efecto transformador en toda la organización, deberían hacer lo contrario. La Figura 6 muestra las conclusiones de una encuesta reciente sobre los bajos niveles de madurez de las aseguradoras en lo que respecta al acceso y tratamiento de los datos para los modelos de IA¹².

¹² Encuesta con los responsables de la toma de decisiones en grandes organizaciones de EE. UU y Canadá. Véase Element AI, mayo de 2020, *op. cit.*

Figura 6
Madurez de los datos en las aseguradoras



Fuente: *The Five Dimensions of Enterprise AI, Element AI*, mayo de 2020, solo encuestados del sector de los seguros.

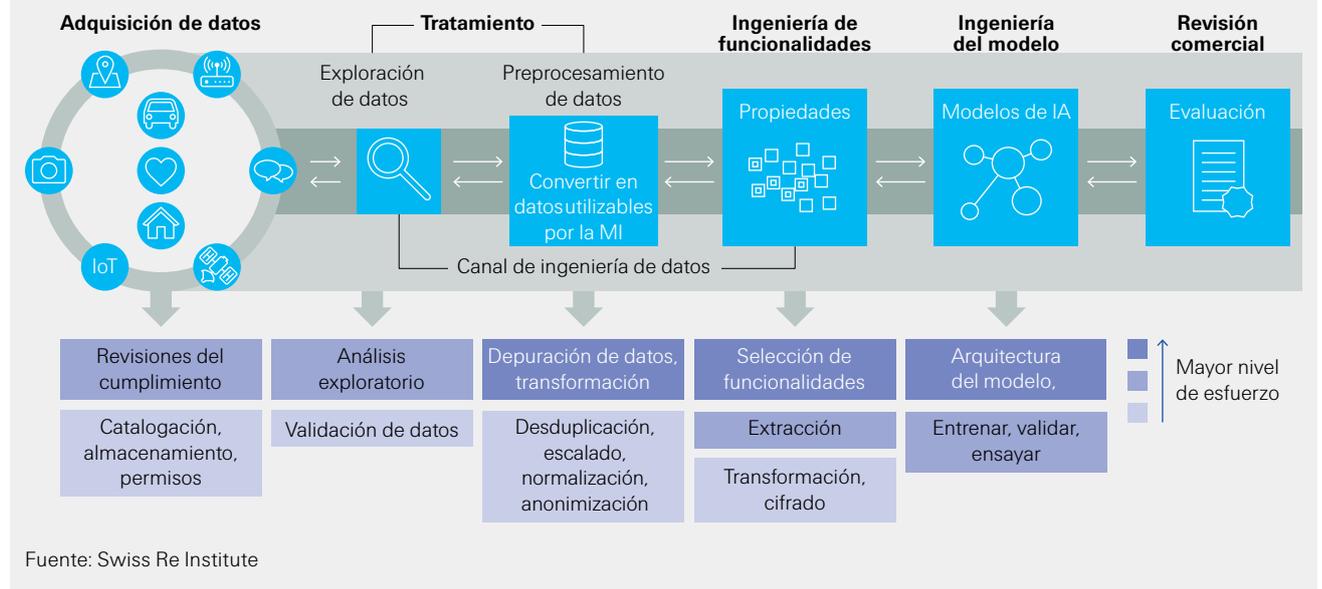
La falta de estrategias de datos puede restar eficacia a las funciones de los recién creados directores de datos (CDO).

Parte de la inteligencia artificial más innovadora que se está desarrollando (por ejemplo, el aprendizaje por refuerzo y la modelización de conjuntos) se puede entrenar de forma fiable sin amplios conjuntos de datos de entrenamiento de elevada calidad. En esos casos, los sistemas utilizan simulaciones y algoritmos de generación de datos artificiales (*data augmentation*), además de sintetizar la experiencia y los conocimientos sobre la materia¹³. Sin embargo, estos nuevos enfoques aún no están listos para su despliegue a escala empresarial y casi todas las implementaciones exitosas de sistemas basados en la inteligencia mecanizada siguen dependiendo en gran medida de la calidad y la cantidad de los datos. En este sentido, la capacidad y las herramientas disponibles a día de hoy para procesar datos estructurados y no estructurados abren la puerta a nuevas oportunidades en materia de inteligencia mecanizada. Para optimizar el potencial, es esencial una estrategia de datos y una arquitectura del sistema que abarque toda la empresa, tal y como la que aparece representada en la Figura 7. La falta de dichas estrategias y arquitecturas dificultará la eficacia de las funciones de los directores de datos (CDO) recién creados, que también son críticas. Por ejemplo, en una encuesta reciente, menos del 10% de los CDO de todos los sectores afirmaron ser capaces de medir el valor financiero de sus activos de información y datos¹⁴.

¹³ Integrar de este modo la experiencia y los conocimientos sobre la materia refleja un enfoque bayesiano de actualización del aprendizaje automático y la inteligencia artificial en el sentido de que se incorporan al algoritmo *a priori* subjetivos para reducir el alcance del espacio de parámetros evaluado, lo cual puede contrarrestar (suponiendo que los *a priori* sean fiables) las deficiencias de los datos.

¹⁴ *Gartner Survey Finds Chief Data Officers Are Prioritizing the Right Things, But Higher Strategic Focus Is Required*, Gartner, 10 de junio de 2019.

Figura 7
Esquema de la estrategia de datos para la inteligencia mecanizada



Con frecuencia, la ingeniería de datos se duplica en distintos departamentos.

Entre las aseguradoras que invierten en una arquitectura de datos, una característica común de las malas estrategias es una ingeniería de datos duplicada entre distintos equipos. En estos casos, los científicos de datos rara vez confían en un proceso de custodia y tratamiento centralizado. En algunos casos no existe un proceso de custodia y tratamiento centralizado, al menos no uno del que los científicos de datos estén al tanto, lo cual les lleva a crear sus propios procesos, a menudo duplicando tareas. IDC descubrió que los profesionales de los datos dedican el 67 % de su tiempo a buscar y tratar datos¹⁵. En otra encuesta específica del sector asegurador, nueve de cada diez empleados de las cien mayores compañías de EE. UU. afirmaron que la gestión de unos volúmenes de datos cada vez mayores era su principal desafío¹⁶.

Las aseguradoras también carecen de exhaustivas ontologías de datos que definan las relaciones entre estos.

En nuestra opinión, una capacidad centralizada de incorporación y tratamiento de datos puede generar un considerable rendimiento de la inversión al superar estas ineficiencias. Esta es un área en la que las aseguradoras, en particular, aún tienen un largo camino por recorrer. Una encuesta reciente reveló que nada menos que el 75 % de las aseguradoras carecen de una taxonomía que les permita armonizar los distintos tipos de datos¹⁷. La mayoría tampoco tienen exhaustivas ontologías de datos que definan las relaciones pluridimensionales existentes entre los datos clasificados en una taxonomía de datos (o en múltiples taxonomías), un problema que está condenado a complicarse aún más a medida que aumenten el número y la diversidad de las fuentes de datos.

¹⁵ *End-User Survey Results: Deployment and Data Intelligence in 2019*, IDC, noviembre de 2019, extraído de «Talend Accelerates Path to Revealing the Intelligence in Data», 27 de febrero de 2020.

¹⁶ LexisNexis® Risk Solutions, *op. cit.*

¹⁷ *Building New Data Engines for Insurers*, BCG, 5 de noviembre de 2018.

Muchas de las implementaciones fallidas son consecuencia de un desajuste entre los algoritmos y el uso que se les da.

Factores que debemos tener en cuenta para adaptar la implementación a los usos previstos

El éxito de una implementación basada en la inteligencia mecanizada requiere una correspondencia entre los resultados deseados y los algoritmos y técnicas más adecuados para la empresa en cuestión. No todos los algoritmos resultan apropiados para todos los casos de uso, y muchas de las implementaciones fallidas son consecuencia de un desajuste entre los algoritmos y el uso que se les da. Los métodos estadísticos tradicionales bien calibrados pueden ofrecer resultados similares, en términos de precisión, a los de los modelos avanzados, lo cual indica que la calidad de los datos importa más que la innovación algorítmica. Es importante que el uso comercial y la disponibilidad de los datos determinen la selección de la técnica. Aun esforzándose por adaptar la técnica a los casos de uso, es necesario un proceso de tanteo a medida que se implementan y prueban diferentes técnicas para determinar qué enfoque funciona mejor. Con el tiempo, cabe esperar que se alcance un consenso en lo relativo a qué técnicas funcionan mejor para cada uso específico. Entre los factores que hay que tener en cuenta a la hora de seleccionar la técnica para el caso de uso concreto se incluyen los siguientes:

- **Capacidad de interpretación:** Las preguntas que hay que plantear son: ¿cuánto necesita comprender la compañía? ¿Cuánto comprendería normalmente? ¿Cuáles son los requisitos normativos y los estándares profesionales? En el sector de los seguros, alrededor de un tercio de las compañías que han adoptado la inteligencia mecanizada están preocupadas por la posibilidad de que, si los reguladores no comprenden las técnicas modernas, puedan bloquear o limitar los esfuerzos por utilizar sus nuevas aplicaciones¹⁸. Además, dependiendo del uso concreto, las empresas podrían estar obligadas a ser transparentes tanto con los reguladores como con sus clientes. Por regla general, se requiere un elevado grado de transparencia en los modelos/procesos, y la línea que separa la recopilación de datos para mejorar el servicio de la posibilidad de poner en peligro la privacidad es muy delgada, de modo que lograr el equilibrio adecuado puede repercutir en la financiación. Gartner prevé que, en 2022, los proyectos tendrán el doble de probabilidades de recibir financiación si tienen incorporada la transparencia¹⁹.
- **La selección de los casos de uso debería tener en cuenta el coste de los distintos errores:** Si bien los modelos procesan grandes volúmenes de datos con rapidez, también pueden provocar que la supervisión humana se relaje. Todo error tiene un coste, y la dirección debe decidir cuáles son los niveles aceptables de tolerancia a los errores con el fin de identificar el punto a partir del cual el valor económico puede volverse negativo. En algunos casos, es posible que todas las clases de errores tengan el mismo impacto, pero, en otros casos, un error concreto puede resultar más costoso (por ejemplo, si un vehículo autónomo ignora a un peatón o un sistema automatizado de evaluación crediticia concede crédito a una empresa que luego no paga). En otras ocasiones, el coste de una predicción falsa puede ser mayor que el ahorro asociado a una predicción verdadera. Por ejemplo, es posible que una aseguradora que desee peritar rápidamente siniestros patrimoniales mediante el análisis de imágenes aéreas basado en la inteligencia mecanizada más tarde tenga que aumentar considerablemente las reservas debido a los daños no visibles (por ejemplo, bajo un tejado).

Un falso positivo puede resultar menos costoso en una campaña de venta cruzada (el coste es un correo electrónico) que en el área de suscripción o tarificación (el coste sería aceptar riesgos agravados). La Tabla 2 muestra estas relaciones en dos escenarios distintos: 1) propensión a comprar en una campaña de venta cruzada; y 2) clasificar un riesgo de enfermedad crítica (CI) para una decisión de suscripción.

¹⁸ LexisNexis® Risk Solutions, *op. cit.*

¹⁹ *Can learnings from early projects give CIOs a head start with AI technologies?*, Gartner, 9 de febrero de 2018.

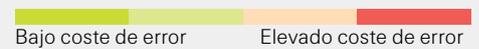
En la venta cruzada, el coste de abordar a un posible cliente poco dispuesto basándose en una predicción menos precisa de la propensión a comprar (falso positivo) es mucho menor (por ejemplo, 10 USD) que el escenario de falso positivo en la suscripción de una póliza de enfermedad crítica, cuando un riesgo clasificado como bueno es en realidad malo (por ejemplo, 1100 USD).

Tabla 2
Evaluación del impacto del coste de los errores

Propensión a comprar	Predicción (no es probable que compre)	Predicción (es probable que compre)	Escenario de venta cruzada	Número de predicciones	Ganancia (pérdida) por predicción en USD	Total ganancia (pérdida) en USD
Real (no es probable que compre)	(Verdadero negativo) 3000	(Falso positivo) 600	Verdadero positivo	6000	100	600 000
			Falso negativo	400	No abordar	-
Real (es probable que compre)	(Falso negativo) 400	(Verdadero positivo) 6 000	Falso positivo	600	(10)	(6000)
			Verdadero negativo	3000	No comprar	-
			Total	10 000		594 000

Clasificación de enfermedad crítica (CI)	Predicción (mal riesgo)	Predicción (buen riesgo)	Escenario de suscripción	Número de predicciones	Ganancia (pérdida) por predicción en USD	Total ganancia (pérdida) en USD
Real (Mal riesgo)	(Verdadero negativo) 3000	(Falso positivo) 600	Verdadero positivo	6000	100	600 000
			Falso negativo	400	No suscribir	-
Real (Buen riesgo)	(Falso negativo) 400	(Verdadero positivo) 6000	Falso positivo	600	(1,100)	(660 000)
			Verdadero negativo	3000	No suscribir	-
			Total	10 000		(60 000)

Nota: Se trata de una ilustración simplificada que podría no reflejar todos los escenarios posibles.
Fuente: Swiss Re Institute



La inteligencia mecanizada en los seguros

Las aseguradoras continúan experimentando con los nuevos enfoques de inteligencia mecanizada para complementar (y posiblemente reemplazar) las técnicas de inteligencia mecanizada convencionales que se están convirtiendo en práctica habitual en áreas tales como el análisis de clientes y la tramitación de siniestros. Sin embargo, a diferencia de lo que ocurre en sectores tales como las redes sociales, la transformación integral de los procesos de seguros mediante sistemas basados en la inteligencia mecanizada sigue siendo limitada. La disponibilidad de los datos, la capacidad de interpretar los modelos y los problemas de privacidad continúan siendo obstáculos para su adopción a gran escala. Además, el coste de los errores en la industria de los seguros puede ser prohibitivo.

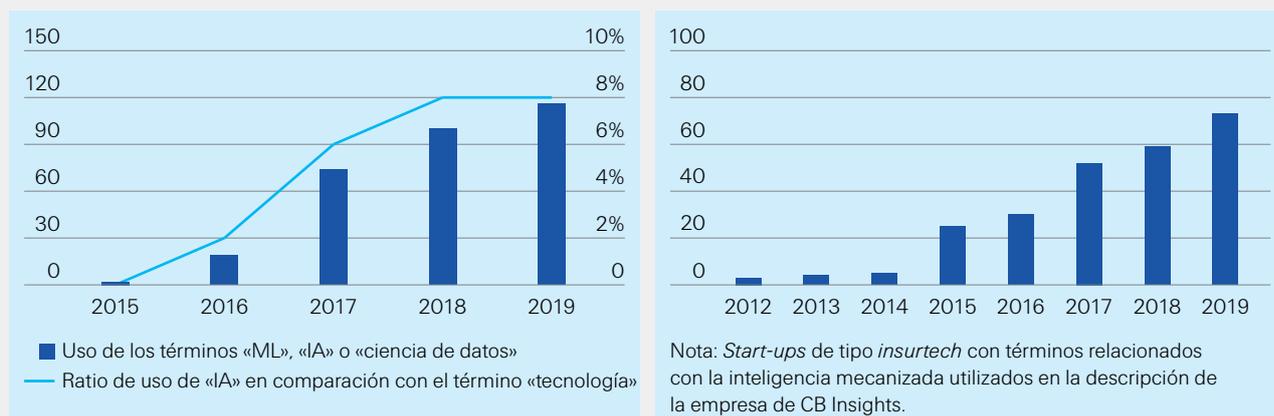
Cómo están las cosas

Los ejecutivos de seguros siguen siendo optimistas en cuanto a la inteligencia mecanizada.

El sector de los seguros se ha quedado atrás en la implementación de sistemas basados en la inteligencia mecanizada. Aun así, una encuesta de 2019 reveló que los ejecutivos del sector tenían unas expectativas muy elevadas en cuanto a la adopción del aprendizaje automático en 2021. También se mostraron optimistas en el pasado, ya que las encuestas anteriores pronosticaban unas elevadas expectativas acerca de dónde se encontrarían en 2019, aunque el año pasado la adopción real se situó muy por debajo de las predicciones²⁰. Del mismo modo, parece que las aseguradoras están empezando a hablar de forma insistente sobre la inteligencia mecanizada. La Figura 9 muestra que la mención de términos relacionados con la inteligencia mecanizada (por ejemplo, IA, aprendizaje automático y ciencia de los datos) en las memorias anuales para los inversores ha aumentado considerablemente, de dos citas en 2015 a 116 en 2019. El crecimiento de las compañías de seguros tecnológicas (*insurtechs*) que utilizan tecnología de inteligencia artificial/aprendizaje automático y las patentes relacionadas con la inteligencia mecanizada registradas por las aseguradoras en los últimos años reflejan esta tendencia.

Figura 9

Menciones relacionadas con la inteligencia mecanizada en las memorias para los inversores de las aseguradoras (izquierda) y tendencia de las *insurtechs* que utilizan tecnología de inteligencia artificial/aprendizaje automático (derecha)



Fuente: Memorias anuales de 30 de las principales aseguradoras. CB Insights, Swiss Re Institute

²⁰ Machine Learning: Today and Tomorrow, Willis Towers Watson, 25 de febrero de 2020.

Las patentes relacionadas con la inteligencia mecanizada solicitadas por aseguradoras han aumentado de forma exponencial en los últimos años.

Fuerte crecimiento de las solicitudes de patentes de inteligencia artificial/aprendizaje automático relacionadas con los seguros

Hemos analizado las bases de datos de patentes y hemos descubierto que el número de patentes relacionadas con la inteligencia mecanizada que han solicitado las aseguradoras ha aumentado desde 2010. Si nos centramos en los solicitantes de patentes más prolíficos entre las aseguradoras de EE. UU., en 2018 y 2019 más de la mitad fueron para el ramo de automotor, algunas en el ámbito de los vehículos autónomos. A medida que los procesos basados en la inteligencia mecanizada entran en los sistemas de vehículos críticos para el negocio, se amplía la demanda de una mayor innovación en la monitorización basada asimismo en la inteligencia mecanizada. Por ejemplo, numerosas solicitudes de patentes son para teledetección, procesamiento de imágenes y uso de drones para la peritación de daños.

Figura 10

Crecimiento (izquierda) y composición de las patentes (derecha, 2018) de las aseguradoras



Fuente: Base de datos de patentes de Google, Swiss Re Institute

Las innovaciones más recientes se han centrado en mejorar la atención al cliente, los siniestros y las operaciones.

En lo que respecta a los usos, la mayoría de las patentes de inteligencia mecanizada en el sector de los seguros han sido de funcionalidades diseñadas para mejorar la atención al cliente, la eficiencia en la tramitación de siniestros y la reducción de las pérdidas. Algunas se proponían generar señales de advertencia temprana, como alertar a los conductores de la presencia de peatones o ciclistas, o alertar a los operadores de los vehículos de una avería o un mal funcionamiento. Ambas reducen la frecuencia de los siniestros, así como su gravedad. Comparando China y EE. UU., según la base de datos de patentes de Google la concentración es alta en ambos mercados. Sin embargo, el número de patentes solicitadas entre 2010 y 2019 en relación con la inteligencia mecanizada se distribuyó más uniformemente en EE. UU., donde diez aseguradoras representan el 80% de la actividad; en cambio, en China menos de cinco aseguradoras representaron el 85% de las patentes solicitadas en relación con la inteligencia mecanizada.

El uso de algunas herramientas de inteligencia mecanizada convencionales es ya habitual en el sector de los seguros.

Implementación de aplicaciones de inteligencia artificial y aprendizaje automático ya activas en el sector asegurador

Algunos métodos de inteligencia mecanizada convencionales, tales como los modelos lineales generalizados, se han convertido en herramientas de uso habitual en la industria aseguradora para los modelos de evaluación y predicción de riesgos. Más recientemente, el entusiasmo por una serie de técnicas de inteligencia artificial y aprendizaje automático, tales como el aprendizaje profundo y por refuerzo, ha llevado a algunas aseguradoras a poner en marcha pruebas piloto. En unos pocos casos, los primeros en adoptar la inteligencia artificial y el aprendizaje automático están obteniendo beneficios en determinadas áreas, tales como una mayor rapidez

en la liquidación de reclamaciones, unas prácticas de venta cruzada (*cross-selling*) y venta adicional (*up-selling*) más selectivas, una mejor detección del fraude y una mejor calificación de riesgos.

- **Modernización del análisis de reclamaciones:** Gran parte de la tramitación de siniestros sigue siendo manual. En la actualidad, varias aseguradoras tienen en marcha pruebas piloto dedicadas a la clasificación, derivación, validación y comunicación con terceros, esperando que un cierto grado de automatización reduzca significativamente el coste de la tramitación de siniestros²¹. Es más probable que los sistemas basados en la inteligencia mecanizada lleven a cabo con éxito las tareas más sencillas, como evaluar pérdidas de gran volumen y tramitar partidas claramente especificadas. Entre las áreas en las que las aseguradoras registran un mayor ahorro gracias a la inteligencia mecanizada se encuentran aquellas en las que la información está mejor estructurada, como, por ejemplo, la documentación en formatos normalizados.
- **Detección de fraudes y mitigación de siniestros:** Las técnicas de aprendizaje automático resultan apropiadas para casos que requieren la clasificación de grandes volúmenes de datos y la detección de anomalías, tal y como la detección de fraudes. Cada vez más, las aseguradoras están evaluando e implementando soluciones antifraude basadas en el aprendizaje automático que aumentan el volumen de datos internos con nuevas fuentes de información, incluido el Internet de las Cosas (IoT) de terceros y los datos públicos. Asimismo, las aseguradoras están utilizando el aprendizaje automático para crear propuestas de mitigación de pérdidas totalmente nuevas, lo que, a su vez, puede conducir a una disminución de la cuantía de los siniestros. Tal es la idea que se esconde, por ejemplo, tras el programa telemático de Direct Line, que utiliza el aprendizaje automático para identificar a personas que necesitan clases para mejorar su conducción²².
- **Optimización de los canales de distribución:** Otra área en la que el aprendizaje automático está encontrando aplicación es en la captación y retención de agentes. Las aseguradoras han empezado a utilizar sistemas basados en el aprendizaje automático para identificar a aquellas personas que tienen más probabilidades de convertirse en agentes de éxito. A su vez, esos sistemas pueden mejorar la asignación de clientes a cada agente. Por ejemplo, Discovery lleva a cabo una asignación automática, en tiempo real, de los agentes del centro de atención telefónica (*call centres*) a aquellos mutualistas con los que probablemente tengan una mayor afinidad. El modelo lleva en funcionamiento desde 2018 y los clientes de las llamadas para las que se estableció esa afinidad registraron un mayor índice de satisfacción²³.
- **Inteligencia mecanizada en la experiencia de cliente:** La inteligencia mecanizada se ha desplegado a escala empresarial en numerosas redes sociales y comercios minoristas online, y algunas aseguradoras han tratado de hacer lo mismo con el objeto de incrementar la eficacia del marketing dirigido. Pese a los éxitos iniciales, las aseguradoras descubrieron que es posible que lanzar indiscriminadamente iniciativas basadas en la inteligencia mecanizada no necesariamente genere los resultados esperados. Por ejemplo, evidencias anecdóticas sugieren que la publicidad digital dirigida basada en una interacción previa con un producto puede, en realidad, desanimar al cliente, lo cual indica que los modelos de inteligencia mecanizada podrían salir ganando si utilizan los conocimientos adquiridos en la economía conductual para comprender los efectos de la interacción.

²¹ «The challenge of full automation», *insuranceinsider.com*, 2 de abril de 2020.

²² *Direct Line Group saves young drivers over £50 million in motor premiums*, Direct Line, 1 de febrero de 2019.

²³ *Insurance trend #1: Get to know me*, EFMA, 14 de noviembre de 2019.

- **Suscripción:** Dado el nivel de confianza necesario para desplegar nuevas tecnologías en el área de suscripción, los sistemas de suscripción totalmente basados en la inteligencia artificial y el aprendizaje automático aún no presentan los niveles de precisión necesarios para ser utilizados a gran escala, lo cual también significa que no se puede confiar en que la inteligencia mecanizada reemplace por completo las evaluaciones de riesgos, salvo en los ramos más sencillos. Dicho esto, algunos ejemplos relacionados con el aprendizaje supervisado pueden complementar y/o, en último término, reemplazar partes de los procesos existentes en la industria aseguradora. Entre ellos se incluyen mecanismos más inteligentes para la clasificación y derivación, que pueden ser más eficaces que las actuales reglas de negocio, por ejemplo, seleccionar la profundidad de la investigación (suscripción completa frente a suscripción simplificada), renunciar de forma segura a la presentación de pruebas adicionales (pruebas de laboratorio, certificados médicos) o realizar derivaciones al nivel jerárquico adecuado dentro de la organización (suscriptor junior frente a responsable médico)²⁴.
- **Tarificación:** Esto está sujeto a la aprobación del regulador, y el enfoque tradicional consiste en aplicar un modelo lineal generalizado (GLM) al histórico de siniestros y primas. Modelos de tarificación más precisos basados en novedades técnicas de aprendizaje automático no se pueden aplicar en producción de inmediato, dado que los resultados pueden ser difíciles de explicar tanto interna como externamente a los reguladores. También podría haber otras limitaciones al uso de los datos, tales como el coste y la falta de acceso a los mismos.

Deficiencias de las implementaciones existentes

El reto de ampliar los modelos de inteligencia artificial y aprendizaje automático sigue suponiendo un obstáculo para el despliegue de las nuevas tecnologías de inteligencia mecanizada a escala empresarial para los flujos de trabajo más importantes de la cadena de valor de los seguros. A continuación se enumeran los procesos en los que la inteligencia mecanizada podría implementarse a gran escala y los obstáculos asociados que aún existen y que impiden una mayor adopción:

1. Recopilación y tratamiento de los datos relevantes tanto estructurados como no estructurados. A este respecto, los obstáculos son, entre otros, los reglamentos e incentivos en materia de protección de datos (por ejemplo, compañías o agentes que no están dispuestos a compartir los datos relevantes), unos procesos de acceso fragmentados, unos contratos de utilización de los datos inadecuados y unos procesos de tratamiento de los datos que aún resultan difíciles de sistematizar.
2. Evaluación, comprensión y procesamiento de la información de entrada relevante. Las técnicas de procesamiento del lenguaje natural (NLP) siguen siendo inadecuadas, dadas las dificultades existentes para interpretar los aspectos tácitos y sutiles de la información, y la cantidad y la calidad de los datos siguen sin ser las apropiadas.
3. Aprobación de la suscripción y tarificación: La automatización inteligente que integre humanos y máquinas sigue suponiendo un enorme desafío de diseño. Por su parte, los ejecutivos y suscriptores experimentados no confían en los algoritmos, dados los ejemplos existentes de errores «obvios».
4. Monitorización de las carteras de riesgos y gestión de los siniestros: Sigue habiendo problemas para mejorar la eficiencia en lo que respecta a la creación de sistemas de menor coste que tengan un mejor equilibrio entre falsos positivos

²⁴ *What's new? The next wave of insurance automation complemented with new technologies*, Swiss Re, 25 de noviembre de 2019.

Sigue habiendo desafíos para generalizar el uso de las nuevas herramientas de inteligencia mecanizada.

y falsos negativos que los métodos basados en la intervención humana. Las arquitecturas de procesamiento de datos siguen tratando los datos en «embalses», en lugar de los «ríos» necesarios para acelerar el tiempo entre la recopilación y el uso de los mismos. Los datos que no se transforman en información que permita actuar merman casi de inmediato la utilidad de los sistemas basados en la inteligencia mecanizada.

5. Mejora de la asignación de capital entre segmentos de responsabilidad civil: Los modelos de predicción siguen sin ser capaces de respaldar de manera fiable una mejor asignación de capital. En numerosos segmentos de responsabilidad civil, los datos son incompletos y están sesgados, y los sistemas todavía están diseñados en torno a los procesos actuales, que no están preparados para la inteligencia mecanizada.

Una mala integración de los sistemas basados en la inteligencia mecanizada en el conjunto de los procesos puede perjudicar a los resultados del proyecto.

A día de hoy, los datos recopilados de los dispositivos del IoT tienen una limitada integración en la suscripción y la tarificación.

Una mala integración de la inteligencia mecanizada merma el potencial de despliegue del sistema

Con frecuencia, el diseño y la gestión del sistema fallan cuando las aseguradoras tratan de implementar la inteligencia mecanizada en los procesos interdepartamentales existentes. El motivo es que se dedican muy pocos recursos a la integración de los modelos y algoritmos en los flujos de trabajo, lo que provoca una deficiente coordinación interdepartamental. En una entrevista con Swiss Re Institute, una aseguradora que intentaba eliminar las preguntas de suscripción innecesarias afirmó que aprovechaba los datos de las transacciones bancarias para ofrecer una suscripción acelerada a los clientes potenciales. El modelo de suscripción basado en la inteligencia mecanizada funcionó bien a la hora de clasificar a las personas en riesgos normales y agravados. Sin embargo, el departamento de marketing no invirtió en un ejercicio de propensión a comprar ni modificó su proceso de ventas, lo que anuló la ventaja del sistema.

Otro problema es que es posible que el valor de los nuevos datos (especialmente los recogidos de dispositivos portables [*wearables*]) a efectos de suscripción y tarificación no necesariamente genere una mayor precisión en la suscripción (véase la Figura 11). Por ejemplo, puede que registrar el número de pasos que uno da al caminar no mejore de forma sensible su salud. En muchos casos, el resultado es el contrario: una persona que camina más también puede creerse con licencia para más porque está en mejor forma. En este sentido, ha habido cierta tendencia a sobrevalorar hasta qué punto la recopilación y el análisis de estos datos cambia realmente los perfiles de riesgo. El sector continuará esforzándose por adoptar los datos del Internet de las Cosas sin comprender claramente qué relación guardan esos datos sobre el comportamiento con los verdaderos antecedentes del riesgo.

Figura 11
Grado de dificultad para incorporar nuevas fuentes de datos a los procesos



Fuente: Swiss Re Institute

Recomendaciones para las actuales iniciativas en materia de inteligencia mecanizada

Suponemos que una exitosa implementación en los procesos integrales de sistemas basados en la inteligencia mecanizada generará numerosos beneficios para las aseguradoras en términos de productividad, lo cual, en último término, aumentará la rentabilidad. Sin embargo, muchas compañías tienen aún un largo camino por delante para estar completamente «preparadas para la inteligencia mecanizada», lo cual no elimina el beneficio positivo que pueden aportar los proyectos de inteligencia mecanizada existentes, que a menudo se realizan a pequeña escala. A continuación se ofrecen algunas recomendaciones para mejorar las probabilidades de éxito de las iniciativas actuales.

Centrarse primero en aquellos componentes de un proceso que sean sensibles a la inteligencia mecanizada.

Invertir de forma gradual. Las aseguradoras deberían empezar por centrarse en aquellos pasos del proceso más susceptibles a la inteligencia mecanizada, en lugar de acometer transformaciones a gran escala. Si quieren tener éxito, las implementaciones de sistemas basados en la inteligencia mecanizada deberían comenzar con objetivos claramente definidos y alcanzar hitos claros y concisos, en lugar de apuntar a la automatización total. Algunos procesos, incluso en ramos de mayor volumen, pueden ser demasiado complejos para su total automatización. Un buen ejemplo es el seguro de automotor: un accidente puede incluir varios siniestros más pequeños, cada uno de un tipo diferente (por ejemplo, lesiones corporales, daños en el vehículo, alquiler de coches), en los que intervienen diferentes partes y proveedores y que, por tanto, requieren de intervención humana experta.

Seleccionar casos de uso que complementen el esfuerzo de los empleados.

La inteligencia mecanizada se puede implementar en áreas con menos restricciones normativas. Si bien la sustitución total de algunos procesos de seguros puede requerir la aprobación de los organismos reguladores, es posible complementar los procesos existentes, con escasas restricciones normativas, con una inteligencia mecanizada selectiva. En este sentido, lo importante es cómo se despliega un sistema basado en la inteligencia mecanizada: numerosas implementaciones de la inteligencia mecanizada para complementar procesos humanos fracasan al añadir costes de proceso sin mejorar la eficiencia o la rentabilidad globales. Involucrar al personal en las discusiones sobre el proceso de

rediseño e introducir pequeños elementos del despliegue puede marcar la diferencia entre una implementación exitosa y una fallida.

Utilizar enfoques más novedosos, como el aprendizaje profundo, para complementar técnicas más convencionales.

Combinar enfoques nuevos y modelos convencionales. Algunos métodos de inteligencia mecanizada más novedosos (por ejemplo, el aprendizaje profundo) se pueden utilizar para complementar otros más convencionales (por ejemplo, los modelos lineales generalizados). Los métodos de inteligencia artificial o aprendizaje automático pueden mejorar el tratamiento de los datos, favorecer un mejor diseño del proceso y solventar debilidades en algunos aspectos de la inteligencia mecanizada convencional (por ejemplo, incorporar los resultados de datos no estructurados). Las aseguradoras deberían utilizar modelos sencillos e interpretables como base de referencia para la inteligencia artificial o el aprendizaje automático, especialmente en aquellas áreas que están reguladas. Por ejemplo, una gran aseguradora estadounidense reconoció que, dado que el sector depende tanto de los modelos lineales generalizados, sus experimentos con el aprendizaje profundo siguen centrándose en la elaboración de un plan de tarificación multivariante. En este caso, el resultado fue utilizar el aprendizaje profundo para desarrollar nuevas perspectivas, y la implementación final incorporó esas perspectivas para mejorar el proceso de los modelos lineales generalizados²⁵.

Los centros de excelencia deberían fomentar las conexiones entre los equipos centralizado y locales.

Fomentar la colaboración entre los equipos de ciencia de datos centralizado y distribuidos. Los programas de buenas prácticas aportan uniformidad entre divisiones. En numerosas aseguradoras, si un equipo de análisis de una división desarrolla un algoritmo exitoso para un problema concreto, hay poca estructura que facilite su adaptación en otras divisiones. Aseguradoras más grandes, como QBE, están creando guías que todas las divisiones pueden consultar y que incluyen algoritmos para acelerar la liquidación de siniestros, identificar fraudes, mejorar las reservas para siniestros pendientes y determinar cuándo los siniestros se pueden convertir en demandas²⁶.

²⁵ *Trick or Treat? Application of Neural Networks in Insurance*, KPMG, 10 de enero de 2019.

²⁶ «QBE, Unlocking the secrets to technological transformation», *Claims Magazine*, abril de 2019.

Despliegue progresivo en toda la organización

A medida que hemos ido comprendiendo cómo los sistemas basados en la inteligencia mecanizada pueden mejorar la incorporación y el tratamiento de los datos y complementar los análisis existentes, se ha generalizado el reconocimiento de la aplicabilidad de los nuevos enfoques, entre los cuales se incluyen, por ejemplo, los modelos híbridos basados en la física/el aprendizaje automático y los algoritmos de inferencia causal para mejorar la capacidad predictiva de los sistemas de inteligencia mecanizada. Sin embargo, con frecuencia el fracaso en la implementación de sistemas de inteligencia mecanizada a escala empresarial es debido a limitaciones organizativas más amplias. Por ello, las aseguradoras deberían centrarse más en la confianza, la tecnología, el talento y la tenacidad.

Innovación y nuevos enfoques

La nueva e innovadora inteligencia mecanizada puede mejorar los enfoques existentes.

A menudo, las técnicas de inteligencia mecanizada más avanzadas requieren más y mejores datos, y mayor potencia de cálculo. La falta de una o de ambas puede frenar la implementación a escala empresarial de los sistemas basados en la inteligencia mecanizada. Con frecuencia, las dificultades son específicas de los modelos o algoritmos, lo que a su vez puede (no siempre) ser el motivo del fracaso del despliegue. Allí donde la mejora de la calidad de los datos y/o la potencia de cálculo plantea desafíos, un modo alternativo de solucionar los problemas del modelo, que recientemente ha sido objeto de investigación, consiste en desarrollar un nuevo enfoque menos sensible a estos problemas. Algunos ejemplos son el aprendizaje por refuerzo o la modelización de conjuntos, como modelos híbridos basados en la física y el aprendizaje automático. La Tabla 3 muestra algunas áreas de innovación interesantes dentro de la inteligencia mecanizada que tienen el potencial para ayudar a superar los principales problemas de los enfoques existentes.

Tabla 3

Esquema que muestra los positivos avances en inteligencia mecanizada

Avance fundamental	Problema que resuelve
Combinar modelos basados en la física con el aprendizaje automático	Mejora la precisión de los modelos de inteligencia mecanizada y la capacidad de interpretarlos, al tiempo que mejora la capacidad predictiva y de manejo de excepciones de los modelos basados en la física. Numerosas aplicaciones en actividades de mantenimiento críticas, sistemas de alerta temprana, etc.
Avances en el uso del aprendizaje automático para la inferencia causal	Una toma de decisiones más informada con un mayor nivel de confianza. Mejor comprensión del efecto de las intervenciones. Enormes aplicaciones en áreas sensibles, como la asistencia sanitaria, la defensa e incluso los seguros.
Avances en herramientas de visualización para el apoyo a la toma de decisiones	Mejora la capacidad de interpretar y diagnosticar sistemas de inteligencia mecanizada complejos. Aplicaciones en el procesamiento del lenguaje natural, el procesamiento de imágenes, etc.
Mejores técnicas de interpretación de modelos	Mejora la capacidad de interpretar las actuales técnicas de inteligencia mecanizada de caja negra, al tiempo que mejora la precisión de técnicas más interpretables, pero, a día de hoy, de escasa precisión, como CART.
Automatización inteligente: rediseño de flujos de trabajo	Tratamiento automatizado de los datos, descubrimiento e intercambio de conocimientos e información. Prototipado de modelos en lenguajes de producción. Potencial para ahorrar un tiempo considerable tanto en el desarrollo como en el mantenimiento continuo.
Analítica que protege la privacidad	Gobiernos, empresas y círculos académicos unen fuerzas para contribuir a mejorar la ponderación de los parámetros del modelo y, por tanto, el rendimiento del mismo sin comprometer la privacidad de los datos.

Source: Swiss Re Institute

Con frecuencia, los sistemas de inteligencia artificial y aprendizaje automático basados en los datos no incorporan los conocimientos físicos y científicos.

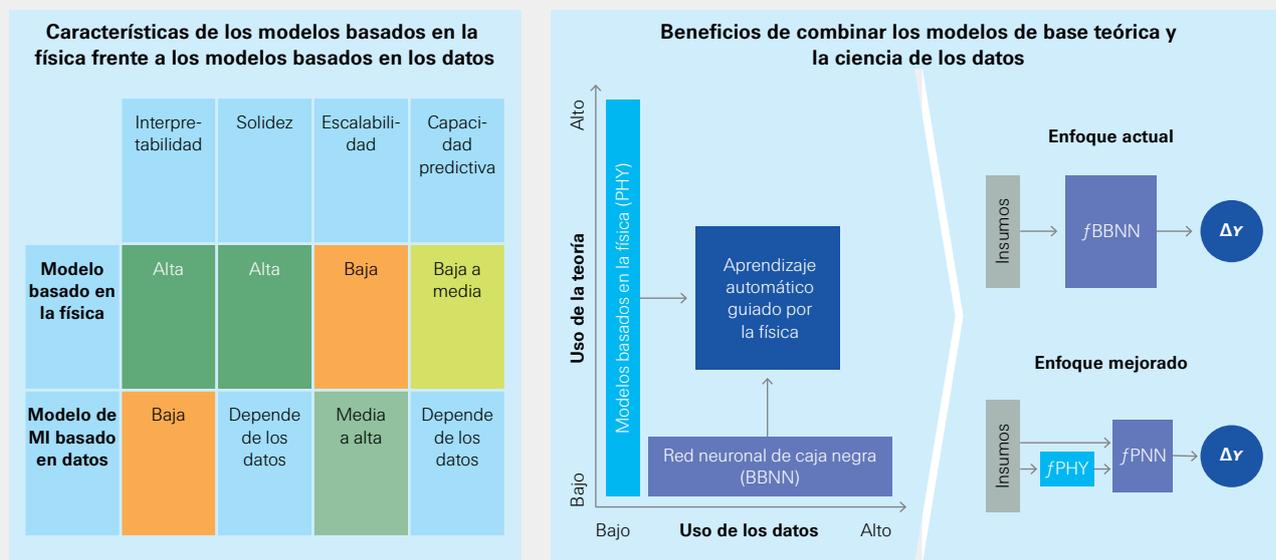
La comunidad está explorando el espacio existente entre los modelos basados en la física y los modelos de aprendizaje automático.

Combinar modelos basados en la física con enfoques basados en los datos

Los sistemas de inteligencia artificial y aprendizaje automático basados únicamente en los datos no son robustos. Cuando las aseguradoras pasan de «detectar y restaurar» a «predecir y prevenir», puede que descubran que los sistemas de inteligencia artificial y aprendizaje automático basados en los datos para aplicaciones complejas no son tan claros, puesto que no incorporan los conocimientos *físicos* y *científicos* en el aprendizaje y la predicción. A menudo, los datos disponibles son insuficientes, ruidosos y/o sesgados, lo cual hace que resulte aún más importante compensarlo con modelos *de base teórica*. El uso de datos (por lo general inadecuados) con los actuales algoritmos de inteligencia artificial y aprendizaje automático produce resultados incongruentes, con el resultado de que los modelos entrenados no generalizan bien en pruebas fuera de la muestra.

Por el contrario, los modelos basados en la física puramente matemáticos pueden no captar toda la gama de interacciones complejas que caracterizan los sistemas físicos que interesan a las aseguradoras (por ejemplo, el clima, el comportamiento, la resiliencia urbana, la salud, etc.). Para llenar ese vacío, algunas aseguradoras y desarrolladores de tecnología están explorando modelos híbridos basados en la física y en algoritmos de inteligencia artificial/aprendizaje automático: esa hibridación se denomina ciencia de los datos de base teórica o aprendizaje automático basado en la física o aprendizaje automático que incorpora las leyes de la física. Métodos de inteligencia artificial más novedosos, tales como el aprendizaje por refuerzo, las redes generativas antagónicas (GAN), la computación neuromórfica y las técnicas de simulación basadas en agentes ampliarán aún más las posibilidades de este cruce híbrido de modelos basados en la física e inteligencia mecanizada.

Figura 12
Dicotomía entre los modelos de base teórica y los modelos de ciencia de los datos



Nota: PNN se refiere a redes neuronales basadas en la física

Fuente: A. Karpatne et al., *Theory-guided data science: A new paradigm for scientific discovery*, Cornell University, 2016

Despliegue progresivo en toda la organización

La exitosa combinación de ambos requiere líneas de comunicación claras

La Figura 12 es una perspectiva bidimensional de la dicotomía entre los modelos basados en la física y los de la ciencia de los datos. Los modelos basados en la teoría científica (eje Y) pueden tener lagunas de conocimiento con respecto a ciertos procesos que son demasiado complejos de entender o demasiado difíciles de observar directamente. En el otro extremo del espectro, los modelos basados en datos (eje X) utilizan grandes volúmenes de datos, pero son indiferentes a las teorías científicas subyacentes. Un enfoque complementario puede aprovechar la extraordinaria capacidad del aprendizaje automático para extraer patrones de los datos, al tiempo que se beneficia del conocimiento científico. Esa integración requerirá unas líneas de comunicación claras entre las distintas disciplinas.

Esta combinación se está probando en áreas tales como la predicción de averías.

Este enfoque combinado se está probando en áreas tales como la predicción de averías y de la vida útil restante de sistemas industriales. Se trata de áreas en las que los modelos basados en la física pueden ser incompletos y los modelos basados en los datos pueden verse obstaculizados por la escasa representatividad de los datos de entrenamiento. Los investigadores utilizan modelos de rendimiento basados en la física para inferir parámetros del modelo no observables relacionados con la salud del equipo, los cuales pueden combinarse con las lecturas de los sensores para generar un modelo de predicción basado en los datos²⁷.

Los sistemas basados en la inteligencia mecanizada aprenden las conexiones, pero por lo general no son capaces de razonar la causa y el efecto.

Avances en la combinación de herramientas de inferencia causal con la inteligencia mecanizada

Una suposición básica de la estadística clásica y el aprendizaje automático es que la distribución de los datos de entrenamiento es la misma que la distribución de los datos en la práctica, lo cual a menudo no ocurre en la vida real, ya que, por ejemplo, una nueva regulación o cualquier otra intervención pueden cambiar la distribución de los datos. Una propiedad general de los modelos causales es que son resistentes a tales cambios y, por tanto, más interpretables.

Tres niveles de causalidad: ver, hacer e imaginar.

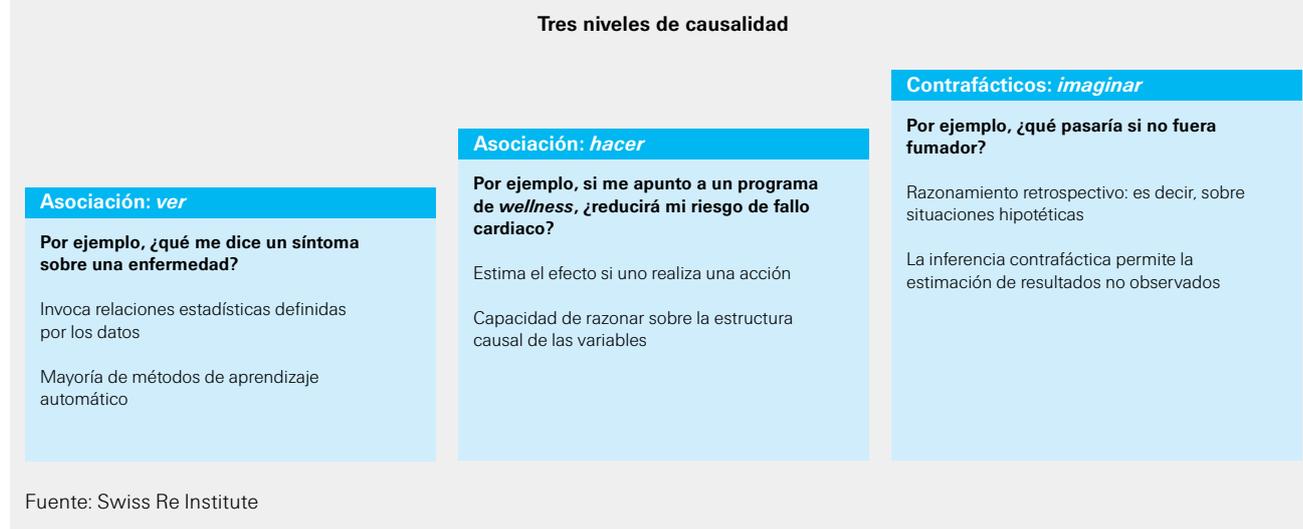
La Figura 13 muestra tres niveles en la escalera de la causalidad. El nivel 1 es asociativo y pregunta: «el hecho de ver X ¿cómo cambiará mi creencia en Y?». Por ejemplo, ¿qué me dice un síntoma concreto sobre la presencia de una enfermedad? El nivel 2 explora preguntas que no pueden responderse únicamente a partir de los datos pasados, dado que las preguntas abordan los cambios de comportamiento en respuesta a ciertas intervenciones («¿qué le ocurre a Y si hago X?»). El nivel 3 supone imaginar, respondiendo a preguntas contrafactuales o hipotéticas como: «¿qué habría pasado si hubiera actuado de forma distinta?».

La inferencia causal favorece una inteligencia más adaptativa...

El cambio a este paradigma de inferencia causal crea una inteligencia más adaptativa, que encaja con una definición más precisa de la IA. El libro del año 2000 del científico de la computación Judea Pearl (*Causality: Models, reasoning, and inference*, Cambridge University Press, 2013) y el más reciente *The Book of Why* (Basic Books, 2018) exploran una serie de técnicas que se pueden utilizar conjuntamente con diversas técnicas de inteligencia mecanizada para extraer conexiones causales, en lugar de limitarse a identificar asociaciones. Cabe señalar que surgen asociaciones de casi todos los métodos de inteligencia mecanizada, desde las técnicas convencionales hasta los más recientes algoritmos de inteligencia artificial y aprendizaje automático.

²⁷ M.A. Chao, C. Kulkarni, O. Fink, et al., *Fusing Physics-based and Deep Learning Models for Prognostics*, Cornell University, 2 de marzo de 2020.

Figura 13
Niveles de causalidad necesarios en los seguros



...y puede, por tanto, mejorar la capacidad predictiva de los sistemas de inteligencia mecanizada.

Las herramientas de visualización de datos ayudan a los científicos no especializados en datos a comprender el resultado de los sistemas basados en la inteligencia mecanizada.

La inferencia causal surge de la formulación de hipótesis sobre las relaciones causales de una serie de factores en el contexto de grafos acíclicos dirigidos (DAG) basados en la mejor comprensión científica disponible²⁸. A continuación, se pueden utilizar diferentes técnicas para «podar» el grafo con el fin de distinguir los factores causales de los de confusión. La inferencia causal, combinada con otras técnicas de inteligencia mecanizada, puede constituir una poderosa herramienta para mejorar la capacidad predictiva de determinados modelos y alimentar sistemas de gestión de riesgos más robustos. Esta combinación se deriva fácilmente de la hibridación de modelos basados en la física con enfoques de inteligencia mecanizada más modernos, ya que las teorías científicas proporcionan orientación sobre las interrelaciones entre variables en las que debería centrarse el entrenamiento, el ajuste o la estimación de los modelos de inteligencia mecanizada relevantes.

Utilizar la visualización para generar información que permita actuar

Incluso si una empresa implementa con éxito un sistema basado en la inteligencia mecanizada, a menudo el resultado queda restringido a la discusión entre los científicos de datos de la empresa, lo cual limita la influencia del sistema. Unos procesos de toma de decisiones inflexibles y un software inmaduro hacen difícil que los científicos de datos transformen los resultados del sistema en información práctica que los responsables de la toma de decisiones puedan utilizar para emprender acciones. En una encuesta reciente, más del 70% de las aseguradoras de EE. UU. afirmaron que les preocupaba que el personal no especializado en ciencia de datos no comprendiera los resultados de la inteligencia artificial y el aprendizaje automático²⁹. Las aseguradoras tendrán que desarrollar herramientas de visualización y apoyo a la toma de decisiones más adaptadas que funcionen para sus necesidades específicas. Una recomendación que podría parecer ilógica es incluir diseñadores no técnicos como parte del equipo de implementación de los sistemas basados en inteligencia mecanizada. Ese personal no técnico debería trabajar con los responsables de la toma de decisiones ejecutivas desde el principio del proyecto, no solo al final. Muchos sistemas muy potentes no se utilizan de forma productiva porque el resultado es confuso para los responsables de la toma de decisiones.

²⁸ El marco causal del grafo acíclico dirigido hace posible la representación de relaciones causales y contrafactuales entre variables.

²⁹ LexisNexis® Risk Solutions, *op. cit.*

Despliegue progresivo en toda la organización

En la actualidad, las herramientas de inteligencia de negocio estándar permiten crear presentaciones visuales a medida que se pueden utilizar para comunicar las conclusiones del modelo.

Hoy en día, se da más importancia a la capacidad de explicar la inteligencia artificial y el aprendizaje automático, especialmente para técnicas con una mayor precisión.

Los árboles de decisión son interpretables, pero pueden tener una menor precisión.

Los árboles de clasificación óptimos mejoran la precisión, al tiempo que mantienen la capacidad de interpretación.

En 2019 se añadieron numerosas funcionalidades nuevas a las herramientas de visualización basadas en conocidas bibliotecas de visualización de JavaScript, tales como D3, jQuery y R. Gartner predice que, para 2022, el 40 % del desarrollo y la calificación de modelos de aprendizaje automático se llevará a cabo en herramientas (por ejemplo, herramientas de inteligencia de negocio [BI]) que no tienen el aprendizaje automático como objetivo principal³⁰. Por ejemplo, Microsoft ha hecho posible la integración de *scripts* de Python en PowerBI, su popular herramienta de BI³¹. AutoML ya se encuentra disponible en herramientas de visualización y de BI y, actualmente, soporta modelos de clasificación y regresión³². Es probable que en el futuro haya otros tipos de modelos, y la posibilidad de exportar modelos de aprendizaje automático a entornos informáticos interactivos como Jupyter Notebooks, permitiendo mejorar los modelos «sobre la marcha».

Avances en la capacidad de explicar los modelos y las técnicas de interpretación

A medida que las nuevas herramientas de inteligencia mecanizada demuestran su potencial productivo en el contexto empresarial, se hace más hincapié en la necesidad de «inteligencia artificial y aprendizaje automático explicables». Es decir, los algoritmos con unos niveles de precisión más altos (relevantes para usos empresariales específicos) necesitan una mayor explicación antes de que resulten aceptables en un abanico más amplio de contextos empresariales. Si quieren tener éxito, las implementaciones de sistemas críticos para la toma de decisiones que abarquen toda la empresa requerirán capacidad de explicar e interpretar. En los últimos años se ha avanzado mucho en la explicación de modelos complejos, como demuestran los valores SHAP (Shapley Additive exPlanations) y las Local Interpretable Model-Agnostic Explanations (LIME). También se están proponiendo árboles de clasificación óptimos para mejorar la precisión, al tiempo que se soluciona el problema de la capacidad de interpretación (véase *Caso práctico: árboles de clasificación óptimos*). Aún no está claro si estos enfoques serán suficiente para los reguladores y las unidades de gobernanza interna de las aseguradoras.

Caso práctico: árboles de clasificación óptimos

Los árboles de decisión son altamente interpretables y explicables a un público no técnico. Sin embargo, tales modelos pueden carecer de estabilidad: un ligero cambio en los datos puede provocar un enorme cambio en la estructura del árbol, haciendo que resulten menos apropiados para áreas reguladas como la tarificación de seguros. Otro defecto es que cada división del árbol se decide de forma independiente, sin tener en cuenta el posible impacto de las futuras divisiones en el árbol, lo cual puede dar lugar a árboles que no captan adecuadamente las características subyacentes de los conjuntos de datos, provocando tal vez un rendimiento deficiente a la hora de clasificar los datos futuros.

Una solución útil, asociada con un enfoque descendente (*top-down*), consiste en crear el árbol en un solo paso (es decir, decidir conjuntamente todos los nodos del árbol). De ese modo, cada división se determina con toda la información sobre las demás divisiones del árbol. En 2017, Bertsimas y Dunn propusieron una técnica denominada árboles de clasificación óptimos con el fin de mejorar la precisión del árbol de decisión³³: esta técnica utiliza la programación entera mixta (MIP) para aprender los árboles de clasificación óptimos. La MIP viene con un paquete de solucionadores (*solvers*) y algoritmos estándar que se pueden utilizar para podar de forma eficaz el espacio de búsqueda.

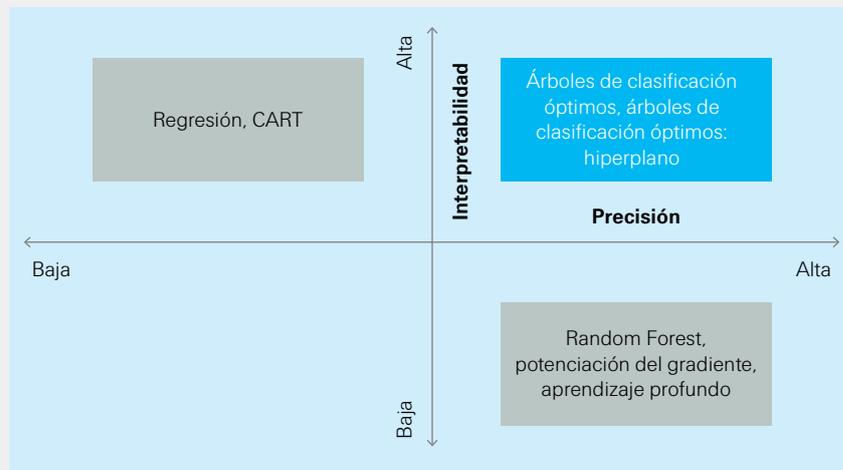
³⁰ Gartner Magic Quadrant for Analytics and Business Intelligence Platforms, Gartner, febrero de 2020.

³¹ «A Tour of Artificial Intelligence Features in Power BI», *blue-granite.com*, 5 de diciembre de 2019.

³² AutoML es una funcionalidad de aprendizaje automático que permite a desarrolladores con conocimientos limitados de aprendizaje automático entrenar modelos específicos para sus necesidades de negocio.

³³ D. Bertsimas, J. Dunn, «Optimal Classification Trees», *Machine Learning*, vol. 106, julio de 2017.

Figura 14
 Cómo se distribuyen las técnicas en lo relativo a capacidad de interpretación y precisión



Fuente: D. Bertsimas y J. Dunn, *Machine Learning under a Modern Optimization Lens*, Dynamic Ideas, 2019

Ahora es posible realizar el prototipado de modelos en el mismo lenguaje de programación empleado en el despliegue.

Unas mejores herramientas pueden, a su vez, mejorar los flujos de trabajo existentes para el tratamiento de datos.

Automatización inteligente: rediseño de flujos de trabajo

El campo de los proveedores de ciencia de datos ha madurado y ahora es capaz de cubrir las necesidades de los científicos de datos tanto expertos como aficionados a la hora de construir, entrenar, implementar y gestionar modelos analíticos³⁴. Las técnicas de inteligencia mecanizada se utilizan cada vez más para simplificar procesos analíticos tales como la preparación de los datos, el descubrimiento de información y el intercambio de esta. Las modernas técnicas de inteligencia artificial y aprendizaje automático aún se enfrentan al reto de que los prototipos de programas de lenguaje no se pueden ampliar a una escala empresarial, pero cabe esperar que los nuevos avances ayuden a superar tales obstáculos. Así pues, será posible realizar el prototipado de modelos en los mismos lenguajes orientados a la inteligencia artificial y el aprendizaje automático que se utilizan para el despliegue a nivel industrial. Por ejemplo, recientemente Amazon Sagemaker anunció una biblioteca y una API de código abierto para prototipar modelos de aprendizaje profundo en Java³⁵. Con ello, los ingenieros internos esperan ahorrar un 30% del tiempo de desarrollo³⁶.

Los inadecuados flujos de trabajo de tratamiento de datos siguen dificultando de forma considerable la exitosa implementación a escala empresarial de sistemas basados en la inteligencia mecanizada. Afortunadamente, ahora se empieza a disponer de herramientas más adecuadas para mejorar el tratamiento de datos existente. Estas plataformas mejoran la recopilación, etiquetado e incorporación de los datos a modelos de aprendizaje supervisado y flujos de trabajo normalizados. Nuevas bibliotecas y paquetes de software más sofisticados permiten disponer de modelos capaces de generalizar mejor, lo cual significa que se puede resolver un conjunto más amplio de problemas (por ejemplo, Tensor Flow para los modelos de aprendizaje automático). Sin embargo, pese a la disponibilidad de mejores herramientas, las opiniones son variadas: algunas plataformas hacen posible una perfecta integración de diversas herramientas, mientras que otras siguen luchando con un sinfín de herramientas que no necesariamente pueden funcionar juntas.

³⁴ *Solution Criteria for Data Science and Machine Learning Platforms*, Gartner, 6 de septiembre de 2019.

³⁵ *Introducing Deep Java Library: Develop and deploy Machine Learning models in Java*, Amazon Web Services, 3 de diciembre de 2019.

³⁶ S. Sivasubramanian, *Leadership session: Machine learning*, Amazon AI Amazon Web Services, diciembre de 2019.

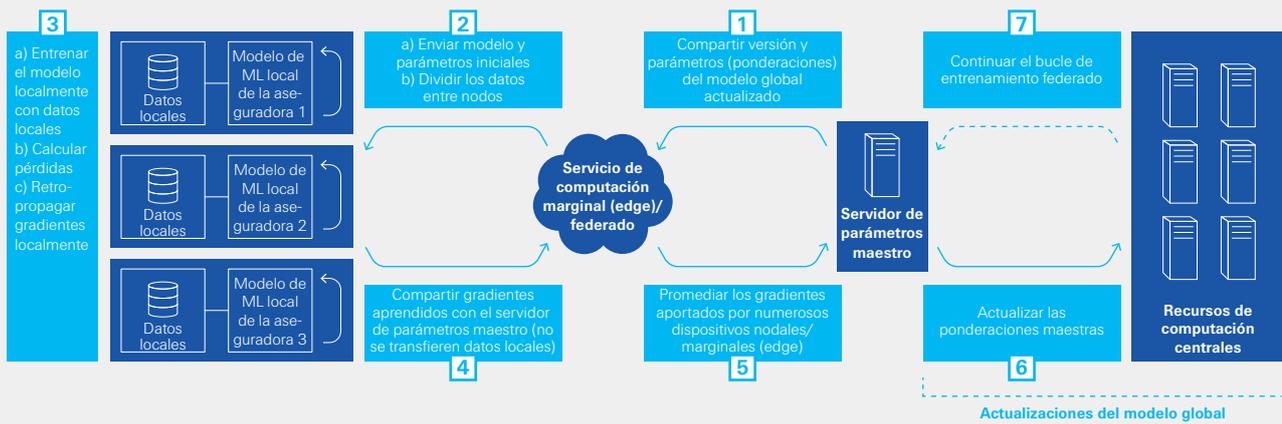
Despliegue progresivo en toda la organización

Nuevos protocolos ofrecen una mejor protección de la privacidad de los datos que las técnicas de anonimización estándar.

Analítica que protege la privacidad

Dado que el rendimiento de los sistemas basados en inteligencia mecanizada suele aumentar con más datos, los actores del sector saldrían ganando si compartieran esos datos. Dicho esto, los protocolos de anonimización estándar no son suficientemente seguros, pero nuevos protocolos están creando nuevas oportunidades. Unos protocolos seguros con la participación de múltiples actores pueden abrir la puerta a análisis derivados de datos no públicos de múltiples compañías de seguros. Estos nuevos protocolos hacen posible un mayor nivel de protección de la privacidad de los datos, más allá de lo que resulta habitual con las técnicas de anonimización estándar. De ese modo, un consorcio de aseguradoras puede aportar datos para generar análisis derivados para aplicaciones de inteligencia mecanizada que beneficien a todos los contribuyentes (véase la Figura 15). Las técnicas de privacidad diferencial eliminan la posibilidad de que incluso los investigadores e ingenieros de datos que trabajan con los datos unificados puedan examinar las aportaciones individuales, al tiempo que favorecen una inteligencia mecanizada más sofisticada.

Figura 15
Aprendizaje federado para lograr una analítica que proteja la privacidad.



Fuente: Swiss Re Institute

Los modelos maestros hacen uso de los datos locales de cada aseguradora para ayudarles a aprender unos de otros sin compartir datos.

La Figura 15 muestra que, una vez creada una instancia del modelo, los parámetros y ponderaciones se envían (en los pasos 1 y 2) a través de un servicio web a las aseguradoras individuales, cada una de las cuales ejecuta el modelo global con sus datos locales (por ejemplo, registros de siniestros) con el fin de determinar la precisión del modelo maestro (paso 3). Una vez completado este proceso, cada aseguradora (paso 4) ofrece su opinión y comparte las conclusiones o gradientes de aprendizaje (es decir, lo que es diferente entre los dos modelos). Luego se combina el *feedback* de todas las aseguradoras, se envían ponderaciones actualizadas a los servicios federados y estas se reflejan en el modelo global (pasos 5 y 6). Este ciclo puede continuar hasta que se alcance un cierto nivel de precisión en el modelo maestro.

Confianza, tecnología, talento y tenacidad

A menudo, las limitaciones organizativas son el motivo del fracaso en el despliegue de sistemas basados en la inteligencia mecanizada.

Los problemas relacionados con el modelo no son la única razón del fracaso en el despliegue a escala empresarial de sistemas basados en la inteligencia mecanizada. Con frecuencia, la causa del fracaso son limitaciones organizativas, tales como una mala planificación de los casos de uso, la falta de personal con la debida formación y una mala comunicación. En el sector asegurador, vendría bien un cambio de mentalidad: las aseguradoras necesitan comprender mejor el valor que pueden

aportar los sistemas basados en inteligencia mecanizada desde una perspectiva empresarial integral. Tiene sentido llevar a cabo proyectos piloto a pequeña escala con tecnologías emergentes como parte de un proyecto inicial de I+D o de evaluaciones focalizadas. Tras ello, ha sido una tendencia habitual entre las aseguradoras poner en marcha el despliegue de la experiencia piloto en toda la compañía sin prestar la debida atención a otras cuestiones no tecnológicas relacionadas con el diseño.

Las aseguradoras también deberían centrarse en los problemas ajenos al modelo que impiden una más amplia adopción.

Para transformar con éxito sus compañías con la tecnología basada en inteligencia mecanizada, recomendamos a las aseguradoras que dejen de confiar exclusivamente en las pruebas de concepto y los proyectos piloto a pequeña escala de los distintos enfoques del modelo/algoritmo. También deben centrarse en las principales características, ajenas al modelo, de un despliegue empresarial integral: confianza, tecnología, talento y tenacidad (véase la Tabla 4).

Tabla 4
Consideraciones ajenas al modelo para la implementación a escala empresarial de sistemas basados en inteligencia mecanizada

Conclusiones principales	Implicaciones para el modelo actual	Perspectiva
Confianza: Desarrollar un marco de riesgo algorítmico y ética digital	Preparar mejor los sistemas basados en inteligencia mecanizada frente a los riesgos, por ejemplo, ataques antagónicos	Equilibrar las diferentes definiciones de imparcialidad e incorporar el autocontrol en los sistemas basados en inteligencia mecanizada desde la fase de diseño
Tecnología: Equilibrar la experiencia y los conocimientos internos y externos	Comprender que adquirir inteligencia mecanizada difiere del software tradicional para reducir los riesgos y maximizar el ROI	Desarrollar enfoques para armonizar tecnologías fragmentarias
Talento: Desarrollar talento y competencias	Identificar cómo la inteligencia mecanizada puede complementar los actuales enfoques basados en la ciencia actuarial	Animar a todo el personal a aprender sobre las nuevas herramientas relacionadas con la inteligencia mecanizada y sacar partido de los científicos de datos aficionados
Tenacidad: Fomentar una cultura dinámica e informada sobre cuestiones tecnológicas; interaccionar con los reguladores	Utilizar entornos de prueba aislados (sandbox) para probar la inteligencia mecanizada a gran escala	Educar a los reguladores. Mantener a los humanos al tanto

Fuente: Swiss Re Institute

Las aseguradoras deben alcanzar una comprensión más profunda de las consecuencias que la inteligencia mecanizada puede tener para los servicios que proporcionan.

Confianza: desarrollar un marco de riesgo algorítmico y ética digital

Decisiones capaces de cambiar vidas pueden automatizarse mediante algoritmos y, a menudo, es posible que los sesgos incorporados en los algoritmos no estén controlados y documentados de manera apropiada, lo cual puede dar lugar a una responsabilidad civil por parte de aquellas compañías que utilizan algoritmos de apoyo a la toma de decisiones que incorporan sesgos (en la mayoría de los casos, de forma involuntaria), y cuando las víctimas deciden ir a juicio. Siete de cada diez aseguradoras estadounidenses ya están preocupadas por la presencia de sesgos en los modelos de inteligencia mecanizada³⁷. Incluso si el resultado de un sistema basado en inteligencia mecanizada es el único o el principal responsable de unas consecuencias indeseadas, «fue el algoritmo» no es una excusa aceptable. En una encuesta realizada en 2019, casi el 50 % de las empresas que utilizaban soluciones de inteligencia mecanizada en distintos sectores afirmaron que disponían de un marco formalizado para analizar el uso ético, los riesgos de sesgo y las implicaciones para la confianza; y el 25 % había creado un puesto específico dentro de la alta dirección para garantizar el cumplimiento normativo³⁸.

³⁷ LexisNexis® Risk Solutions, *op. cit.*

³⁸ Encuesta global entre 2473 empresas que utilizan soluciones de IA. *IDC Survey Finds Artificial Intelligence to be a Priority for Organizations But Few Have Implemented an Enterprise-Wide Strategy*, IDC, 8 de julio de 2019.

Los marcos existentes no fueron diseñados para dirigir el comportamiento de sistemas algorítmicos de grandes dimensiones.

Con la creciente mercantilización de las categorías de inteligencia mecanizada, las aseguradoras necesitan una estrategia detallada de adquisición y transferencia de conocimientos sobre inteligencia mecanizada.

Atraer y retener a personas con competencias en materia de inteligencia mecanizada sigue siendo uno de los principales desafíos para las aseguradoras.

También hay margen para soluciones automatizadas basadas en tecnologías que detectan el sesgo y generan calificaciones de riesgo de los algoritmos, lo cual permite a las aseguradoras evaluar el riesgo de mala praxis de determinados algoritmos. Se podrían plantear soluciones de seguros para proteger a las empresas que utilizan esos algoritmos frente a cualquier responsabilidad derivada del sesgo incorporado en ellos. Las aseguradoras deberían tener más voz en el debate social sobre las cuestiones de equidad e imparcialidad en las decisiones algorítmicas y unir fuerzas con los investigadores para abordar estas cuestiones (por ejemplo, la «comunidad de aprendizaje automático FAT»³⁹). En la última década, varios académicos han publicado diversas definiciones de imparcialidad, no todas las cuales pueden satisfacerse al mismo tiempo. Dado que no resulta factible crear un estado generalizado de imparcialidad, es posible que las aseguradoras deban elegir qué condiciones cumplir y cuáles descartar.

Tecnología: equilibrar la experiencia y los conocimientos internos y externos

El soporte de TI para la inteligencia mecanizada resultará especialmente delicado mientras los equipos de tecnología tratan de gestionar el equilibrio entre: (1) la gestión del negocio frente a las crecientes demandas de diversos servicios de TI, y (2) la innovación y la investigación. Más de la mitad (59 %) de los directores de información (CIO) y los responsables de la toma de decisiones en materia de TI encuestados recientemente no fueron capaces de cumplir en todos sus proyectos en 2019, dejando por tanto proyectos pendientes para 2020⁴⁰. A medida que crece el abanico de ofertas relacionadas con la inteligencia mecanizada, las unidades de TI deberán modificar sus enfoques de adquisición diseñados para la compra de software tradicional con el fin de reflejar las particularidades de la adquisición de inteligencia mecanizada. Por ejemplo, es posible que las aseguradoras necesiten limitar los plazos de sus acuerdos a un periodo más corto (por ejemplo, no más de tres años para evitar quedar cautivos⁴¹), y tendrá que hacerse más hincapié en la flexibilidad e interoperabilidad de las herramientas/sistemas. También necesitarán crear e implementar planes de transferencia de conocimientos para garantizar la continuidad entre los proveedores externos y su propio personal, tanto en el área de TI como en el negocio propiamente dicho⁴².

Talento: desarrollar talento y competencias

Según una encuesta reciente, la falta de personal suficiente para analizar los datos es uno de los tres principales problemas que impiden a las aseguradoras centrarse más en ellos⁴³. Por otra parte, los actuarios están cada vez más concienciados de las ventajas de la inteligencia mecanizada: la inteligencia mecanizada es respaldada en importantes congresos actuariales y se presentan ponencias sobre el modo en que la ciencia actuarial puede incorporar el aprendizaje profundo en áreas tales como la modelización de la mortalidad, la constitución de reservas para siniestros pendientes, el análisis telemático y la tarificación de no vida. Pero la retención del talento en materia de inteligencia mecanizada sigue siendo un desafío: las aseguradoras invierten en programas de desarrollo de competencias para empleados, pero muchas tienen dificultades para crear oportunidades e incentivos a corto plazo que puedan aplicarse a la inteligencia mecanizada de un modo que interese a los desarrolladores de inteligencia mecanizada y científicos de datos cualificados. Alrededor de una sexta parte de los encuestados en un estudio mencionaron la dificultad para contratar y retener a personas con competencias en

³⁹ *Fairness, Accountability, and Transparency in Machine Learning*, FAT/ ML, see <https://www.fatml.org>

⁴⁰ *New report shows 3 out of 4 organizations expect negative revenue impact if they don't digitally transform in next 12 months*, MuleSoft, 13 de febrero de 2020.

⁴¹ *Lack of Focus on AI Licensing Will Result in Higher Costs, Risks and Long-Term Headaches*, Gartner, 11 de septiembre de 2019.

⁴² Gartner, *op. cit.*, 9 de febrero de 2018.

⁴³ Willis Towers Watson, 25 de febrero de 2020, *op. cit.*

materia de IA como una importante barrera para una más amplia adopción de la IA en su organización⁴⁴.

Resulta fundamental involucrar al negocio y a los ejecutivos a lo largo de todo el ciclo de desarrollo de la inteligencia mecanizada.

Tenacidad: una cultura dinámica e informada sobre cuestiones tecnológicas, e interaccionar con los reguladores

Más allá de invertir en capacidades básicas en materia de inteligencia mecanizada, las aseguradoras deben centrarse en los flujos de trabajo globales y las oportunidades de negocio que transforman, desde un punto de vista productivo, estas nuevas tecnologías. En los últimos años, numerosas aseguradoras han financiado pruebas de concepto y proyectos piloto en el campo de la inteligencia mecanizada: esos esfuerzos proporcionan una orientación preliminar, pero no transforman el negocio. De cara al futuro, los principales componentes del proyecto para hacer que los sistemas basados en inteligencia mecanizada resulten transformadores desde un punto de vista productivo van mucho más allá de la tecnología, e incluyen el diseño de la arquitectura tecnológica de la empresa, el rediseño de los flujos de trabajo del negocio, la creación junto a los ejecutivos de la visualización de los datos, y amplios programas de gestión del cambio. Tener a gente del negocio involucrada a lo largo de todo el proceso de identificación, ensayo, evaluación e implementación es clave para lograr el éxito.

Algunos asuntos requieren más debate, tal como el cumplimiento de los requisitos normativos.

Los riesgos normativos relativos a la innovación tecnológica en seguros presentan obstáculos difíciles de superar y se centran, sobre todo, en cuestiones relacionadas con la gestión y el uso de los datos. En Europa, el Reglamento General de Protección de Datos (RGPD) pone de relieve algunos aspectos importantes a la hora de gestionar la privacidad de los datos, lo que es especialmente relevante para los sistemas basados en inteligencia mecanizada, que a menudo fusionan y combinan distintas fuentes de datos para la evaluación de riesgos. Algunos asuntos requieren más desarrollo y debate, como el cumplimiento de los principios del RGPD centrados en el «uso exclusivamente con fines legítimos» y en las condiciones de uso en casos de «alto riesgo» (por ejemplo, en el ámbito médico y sanitario, la elaboración de perfiles).

Los entornos de prueba aislados podrían ayudar a superar las barreras a la adopción de la inteligencia mecanizada a escala empresarial en el ámbito de los seguros.

Además, las restricciones a las transferencias de datos transfronterizas podrían dificultar el desarrollo y la aplicación de soluciones transfronterizas, y retrasar la aprobación normativa de nuevos componentes tecnológicos como las soluciones en la nube. Dada la naturaleza compleja y sutil de muchas soluciones basadas en inteligencia mecanizada, una inadecuada comprensión de las posibilidades y los inconvenientes de la inteligencia mecanizada podría frenar la adopción por parte del sector. Hacen falta más entornos de prueba aislados –en particular, experimentos a escala empresarial– para superar las barreras normativas y promover una comprensión más profunda en relación con la gestión de la privacidad de los datos y las capacidades de la inteligencia mecanizada tanto entre los reguladores como entre los ejecutivos de las aseguradoras.

⁴⁴ *AI adoption in the enterprise 2020*, O'Reilly, 18 de marzo de 2020.

Conclusión

Las aseguradoras deben cambiar su enfoque del desarrollo de tecnología a la transformación empresarial para aprovechar el potencial de los sistemas basados en inteligencia mecanizada.

Las inversiones en capacidad de recopilación y tratamiento de datos serán un factor diferenciador clave.

También resulta fundamental comprender qué herramientas concretas son más realistas y merecen la inversión.

Las aseguradoras deberían aceptar que los plazos de ejecución de sus proyectos serán más largos de lo que muchos esperan.

La eficacia del despliegue de la inteligencia mecanizada dependerá de una serie de factores, incluyendo las actitudes culturales y regionales hacia la privacidad y la regulación.

Pese a los importantes avances, por ejemplo, en el reconocimiento de imágenes y el análisis de clientes basados en la inteligencia mecanizada, en el sector de los seguros la transformación productiva a escala empresarial basada en los sistemas de inteligencia mecanizada es limitada. Algunas tendencias tienen mucho recorrido y es muy probable que continúen con sus actuales trayectorias, como la integración de la visión artificial en los sistemas de suscripción; otras tendencias con menor proyección, como la automatización parcial de sistemas de tratamiento de datos fragmentarios, podrían cambiar con bastante rapidez.

Los datos han pasado a ser vitales en cualquier estrategia destinada a explotar al máximo el potencial de la inteligencia mecanizada en el sector asegurador. Si bien unas series temporales de datos estructurados más prolongadas y los esfuerzos por encontrar datos originales siguen siendo una parte importante del proceso, los datos no estructurados (por ejemplo, texto, audio y vídeo) se han revelado como una nueva oportunidad que aún no ha sido explotada por completo. Los actores que cuenten con unas herramientas y una organización apropiadas comenzarán a diferenciarse a medida que unos datos más originales y mejor tratados se conviertan en parte de su ventaja competitiva.

Las nuevas formas de inteligencia mecanizada en el ámbito de la inteligencia artificial y el aprendizaje automático se encuentran entre esas áreas tecnológicas sobrevaloradas que todavía tienen que lograr implementarse de un modo que resulte rentable y transformador dentro de la cadena de valor de los seguros. Por ejemplo, los *bots* conversacionales (*chatbots*), equipados con lo mejor en procesamiento del lenguaje natural, se siguen desplegando como la solución a los confusos sistemas de menús y como herramienta para reducir el tamaño de los centros de atención telefónica (*call centres*). Las predicciones sobre la transformación de la atención al cliente fueron muy poco realistas. Dicho esto, el abanico de herramientas a disposición de las aseguradoras seguirá evolucionando, así que queda mucho trabajo por hacer para determinar qué herramientas concretas de estas disciplinas deberían implementarse.

Una consideración importante es la diferencia entre el valor de una prueba de concepto focalizada y el éxito del despliegue a nivel empresarial. A las aseguradoras y a sus socios tecnológicos les convendría invertir y experimentar más con la inteligencia mecanizada a escala empresarial, cosa que muchas compañías ya están haciendo en contextos más reducidos. Hasta la fecha, los fracasos se derivan de la incapacidad para ampliar de forma rentable esos proyectos experimentales de enfoque tan limitado. Todos los implicados en el despliegue de la inteligencia mecanizada en una empresa deberían aceptar que los plazos de ejecución de los proyectos serán mucho más largos de lo que la mayoría de los ejecutivos esperan.

El cumplimiento normativo continuará siendo un componente fundamental de cualquier estrategia destinada a sacar partido de los datos y las herramientas digitales. En este contexto, un aspecto que resultará especialmente oneroso para cualquier empresa que desee ampliar su utilización de los datos, en particular en el ámbito de la adaptación y la personalización, es la privacidad de esos datos. Seguirán apareciendo nuevos reglamentos a un ritmo veloz, casi vertiginoso, ampliando la ventaja de las grandes aseguradoras que ya están preparadas para gestionar el cumplimiento. Las normas culturales, la actitud en relación con la privacidad de los datos y la regulación difieren considerablemente de unas regiones a otras: las multinacionales aseguradoras que aborden con decisión este heterogéneo y, a menudo, fragmentario panorama regulatorio en su implementación de la inteligencia mecanizada se diferenciarán claramente de sus competidores.

Generar «confianza» incluirá cómo se gestionan los datos y cómo se satisfacen las necesidades de los clientes.

Los sistemas basados en la inteligencia mecanizada han transformado de forma rentable otros sectores, y esa promesa sigue impulsando las inversiones relacionadas con esta tecnología en la industria aseguradora. Ejecutivos, arquitectos tecnológicos, directores de proyecto y analistas deben cambiar su enfoque del desarrollo de tecnología a la transformación empresarial para aprovechar este potencial de generar valor para el negocio. Entre los factores clave para el éxito se incluyen los siguientes: generar confianza entre los clientes y los reguladores, implementar tecnologías con vocación empresarial, promover culturas que retengan el talento debidamente formado en inteligencia mecanizada, y exhibir una tenacidad capaz de superar cualquier barrera.

Recientes publicaciones *sigma*

- 2020**
- N.º 1 Seguro basado en datos: ¿preparados para la próxima frontera?
 - N.º 2 Catástrofes naturales en tiempos de acumulación económica y riesgos climáticos
 - N.º 3 Efecto multiplicador: invertir en infraestructura para generar crecimiento sostenible en los mercados emergentes
 - N.º 4 El seguro mundial: capeando el temporal de la pandemia de 2020
 - N.º 5 La inteligencia mecanizada en los seguros: nociones para una transformación integral del negocio
- 2019**
- N.º 1 Mercados emergentes: un rayo de luz en un horizonte complejo
 - N.º 2 Catástrofes naturales y siniestros antropógenos en 2018: los riesgos «secundarios» pasan a primer plano
 - N.º 3 Continúa el gran viraje del seguro mundial hacia el este
 - N.º 4 Analítica avanzada: ampliando los límites del seguro de P&C
 - N.º 5 Índices de resiliencia: nociones básicas para los mercados de seguros y las economías
- 2018**
- N.º 1 Catástrofes naturales y siniestros antropógenos en 2017: un año de daños sin precedentes
 - N.º 2 Construyendo el futuro: últimos avances en el seguro de ingeniería
 - N.º 3 El seguro mundial en 2017: crecimiento sólido, aunque lastrado por mercados de vida maduros
 - N.º 4 Rentabilidad en los seguros de no vida: cuidado con la brecha
 - N.º 5 Global economic and insurance outlook 2020 (solo disponible en inglés)
 - N.º 6 Mejora de la mortalidad: comprender el pasado y describir el futuro
- 2017**
- N.º 1 Cibernética: cómo enfrentarse a un riesgo complejo
 - N.º 2 Catástrofes naturales y siniestros antropógenos en 2016: un año de extensos daños
 - N.º 3 El seguro mundial en 2016: la locomotora china avanza a toda máquina
 - N.º 4 Seguros: añadiendo valor al desarrollo en los mercados emergentes
 - N.º 5 Seguro comercial: innovación para expandir el alcance de la asegurabilidad
- 2016**
- N.º 1 Catástrofes naturales y siniestros antropógenos en 2015: Asia sufre cuantiosos daños
 - N.º 2 Asegurando los mercados frontera
 - N.º 3 El seguro mundial en 2015: crecimiento sostenido en un escenario de disparidades regionales
 - N.º 4 El seguro mutuo en el siglo XXI: ¿regreso al futuro?
 - N.º 5 Seguro y reaseguro estratégico: la tendencia creciente hacia soluciones personalizadas
- 2015**
- N.º 1 El seguro puede ayudar a mantener la salud en los mercados emergentes
 - N.º 2 Catástrofes naturales y siniestros antropógenos en 2014: las tormentas invernales y las tormentas convectivas generan la mayoría de daños
 - N.º 3 Fusiones y adquisiciones en el seguro: ¿comienza una nueva oleada?
 - N.º 4 El seguro mundial en 2014: vuelta a la vida
 - N.º 5 Infraseguros de riesgos de daños: cerrando la brecha
 - N.º 6 El seguro de vida en la era digital: se avecina una transformación fundamental
- 2014**
- N.º 1 Catástrofes naturales y siniestros antropógenos en 2013: Grandes daños causados por inundaciones y granizo; el tifón Haiyan azota Filipinas
 - N.º 2 Distribución digital en el seguro: una revolución silenciosa
 - N.º 3 El seguro mundial en 2013: camino a la recuperación
 - N.º 4 Tendencias de crecimiento de los siniestros de responsabilidad civil: riesgos emergentes y repunte de los factores económicos
 - N.º 5 ¿Quién nos cuidará? A la búsqueda de soluciones sostenibles de cuidados a largo plazo para un mundo que está envejeciendo
- 2013**
- N.º 1 Por un objetivo común: la seguridad alimentaria en los mercados emergentes
 - N.º 2 Catástrofes de la naturaleza y grandes siniestros antropógenos en 2012: un año de fenómenos meteorológicos extremos en Estados Unidos
 - N.º 3 El seguro mundial en 2012: Recorriendo el largo y difícil camino hacia la recuperación
 - N.º 4 Navegando por los últimos avances en el seguro marítimo y aerocomercial
 - N.º 5 Urbanización en los mercados emergentes: ventajas e inconvenientes para las aseguradoras
 - N.º 6 Seguro de vida: enfoque hacia el consumidor

Editado por

Swiss Re Institute
Swiss Re Management Ltd
Mythenquai 50/60
Apartado postal
8022 Zúrich
Suiza

Teléfono +41 43 285 2551
Correo electrónico institute@swissre.com

Autores

Jonathan Anchen
Dr. Jeffrey Bohn
Rajeev Sharan

Redactor de *sigma*

Paul Ronke

Redactores jefe

Dr. Jeffrey Bohn
Director de investigación e innovación

Dr. Jerome Jean Haegeli
Economista jefe del Grupo Swiss Re

Los autores desean expresar su agradecimiento a Evangelos Avramakis, Luca Baldassarre, Binay Biswal, Aakash Kiran Raverkar y Jürg Schelldorfer, y también a Julia Brandenburg, Katherine Chen, Charlie Dang, Ashish Dave, Mustafa Dinani, Yannick Even, Nate Jensen, Nuno Mesquita, Sudipto Pal, Ashok Shetty, Charilaos Tsarouchas, Francesca Volpe, Guan Wang, Kelvyn Young, los compañeros de Swiss Re Client Management and Solutions, y Gianluca Antonini de IBM, por la revisión y por aportar ideas para mejorar esta publicación.

Explore y visualice los datos de *sigma* sobre catástrofes naturales y los mercados mundiales del seguro en www.sigma-explorer.com.

© 2020 Swiss Re. Todos los derechos reservados.

El número se cerró el 30 de junio de 2020.

sigma está disponible en inglés (idioma original) y chino.

sigma se encuentra disponible en el sitio web de Swiss Re:
www.swissre.com/sigma

La versión publicada en Internet puede contener información ligeramente más actual.

Traducciones:

Español: Traductores Asociados Valencia S.L.

Diseño gráfico y producción:

Corporate Real Estate & Logistics/Media Production, Zúrich



Impresión: Multicolor Print AG, Baar

Todo el contenido de este número de *sigma* está sujeto a derechos de autor con todos los derechos reservados. La información puede utilizarse para fines privados o internos, siempre que no se suprima ninguna nota relativa a los derechos de autor o propiedad. Está prohibida la utilización electrónica de los datos publicados en *sigma*.

Únicamente está permitida la reproducción total o parcial y la utilización para fines públicos con mención de la fuente «Swiss Re, *sigma* N.º 05/2020» y con la previa autorización por escrito de Swiss Re Economic Research & Consulting. Se ruega enviar ejemplares de cortesía.

Si bien toda la información utilizada en este estudio procede de fuentes fidedignas, Swiss Re no puede garantizar la exactitud e integridad de los datos expuestos o proyecciones futuras. La información proporcionada y las proyecciones futuras realizadas tienen únicamente fines informativos y no constituyen ni representan en modo alguno la opinión de Swiss Re, especialmente en lo relativo a cualquier litigio actual o futuro. Swiss Re no se responsabiliza en ningún caso de los daños o perjuicios derivados del uso de la información que se ofrece en estas páginas, y se advierte al lector que no confíe excesivamente en estas proyecciones de futuro. Swiss Re no asume ninguna obligación de actualizar o revisar públicamente ninguna proyección futura, ni a raíz de nuevas informaciones o sucesos futuros, ni por otros motivos.

Orden n.º: 270_0520_ES

Swiss Re Management Ltd.
Swiss Re Institute
Mythenquai 50/60
Apartado postal
8022 Zúrich
Suiza

Teléfono + 41 43 285 2551
swissre.com/institute