

Del recuento de palabras a los transformadores

A mucha gente le fascina la idea de utilizar la inteligencia artificial (IA) para la comunicación entre humanos y máquinas. Aunque HAL, en la película *2001: Una odisea en el espacio*, de Stanley Kubrick, resultó ser menos útil para su tripulación humana, su encarnación moderna ha fascinado a millones de personas. Con el éxito de ChatGPT, el procesamiento del lenguaje natural (NLP) ha pasado a ocupar un lugar central en la opinión pública al convertirse en sinónimo de IA (generativa). Más recientemente,

modelos como DeepSeek han acaparado los titulares, e incluso han movido los mercados, poniendo de relieve el poder transformador de los grandes modelos de lenguaje (LLM) más allá de los chats. Pero este avance no se ha producido de la noche a la mañana. La IA generativa y el NLP moderno se basan en décadas de progreso, que comenzaron con técnicas sencillas como el recuento de palabras y los diccionarios. Acompáñenos en un viaje desde los humildes comienzos hasta el presente y el futuro.

razonablemente bajas, lo que se conoce como «incrustaciones de palabras».

Cuando de Bengio et al. (2003)² introdujeron las redes neuronales hicieron posible representar el significado de las palabras mediante vectores. Modelos como **Word2Vec** ayudaron a **extender y aplicar** este enfoque de forma generalizada. Lo interesante es que estos modelos pueden comprender no solo el **significado** de las palabras, sino también **cómo se relacionan dentro de una frase**. Por eso se consideran una de las bases del procesamiento del lenguaje natural en la actualidad.

¿Qué es un modelo transformador? Ilustración de la tecnología con ejemplos prácticos

Los primeros enfoques en el campo del NLP captaban la estructura general, pero tenían dificultades para comprender los matices. Para ir más allá de la simple coincidencia de palabras, los investigadores tuvieron que ganar la batalla contra la complejidad (la «maldición de la dimensionalidad»¹), representando las palabras como puntos en un espacio (vectorial) de dimensiones



Dr. Jörg Hofmann
Director of Quantitative
Research Systematic
Equity



Tianxiao Fan
Product Specialist
Systematic Equity

En el episodio anterior vimos cómo modelos como **GloVe** (el principal competidor de **Word2Vec**) permiten representar el significado de las palabras. También explicamos cómo el equipo de **Systematic Equity** aplica esta técnica para transformar transcripciones de *earnings calls* y documentos **10-K** en señales que ayuden a mejorar la rentabilidad ajustada al riesgo.

GloVe y otros modelos de *word embeddings* son técnicas altamente eficaces para capturar relaciones semánticas y sintácticas, mostrando una notable capacidad contextual cuando se entrenan en grandes conjuntos de datos específicos de un dominio.

Sin embargo, las incrustaciones de palabras siguen asignando a cada palabra una representación única y fija, con independencia de la frase o el contexto específico en el que aparece. Tras varios intentos fallidos por superar esta limitación, el artículo de 2017 «Attention is All You Need»⁴ introdujo finalmente los modelos transformadores, que interpretan dinámicamente las palabras basándose en el contexto que las rodea. Por ejemplo, en los modelos tradicionales de incrustación de palabras, la palabra «banco» tendría el mismo significado tanto si aparece en «*grupo de peces*» como en «*entidad financiera*». Por el contrario, los modelos transformadores pueden distinguir entre estos significados teniendo en cuenta la frase completa, entendiendo si «banco» se refiere a un grupo de peces o a una institución financiera. A diferencia de las incrustaciones de palabras estáticas, los transformadores leen como los

humanos, interpretando el lenguaje de forma adaptativa en función del contexto. Aunque son más complejos y requieren más recursos, ofrecen una comprensión más profunda y flexible del lenguaje.

En el centro de esta innovación se encuentra un mecanismo llamado autoatención, que permite al modelo sopesar la importancia de cada palabra en una frase, o incluso en un documento, en relación con todas las demás palabras. Esto significa que el modelo no solo analiza las palabras una por una, sino que tiene en cuenta cómo se relacionan entre sí todas las palabras de un artículo para comprender el significado completo.

Imagina que estás describiendo unas vacaciones: «Llevé a mi perra a la playa y a ella le encantó jugar con las olas». Un modelo transformador entiende que «ella» se refiere a «mi perra» y que «jugar con las olas» es algo divertido que ocurre en la playa. Presta atención a estas conexiones entre las frases, en lugar de interpretar cada palabra por separado. Esta capacidad de conectar palabras e ideas en grandes fragmentos de texto o incluso en documentos completos ayuda a los transformadores a comprender el lenguaje de una forma mucho más parecida a como lo haría un humano, lo que los convierte en potentes herramientas para tareas como la traducción, la síntesis y el análisis de opiniones. La tecnología de los transformadores es el componente básico de los LLM de última generación, donde el término «grande» se refiere a los miles de millones o incluso a los billones de parámetros que contienen.



Los LLM en la gestión de activos

En el sector financiero, interpretar textos complejos y ricos en matices es fundamental. Las transcripciones de las conferencias sobre resultados, los documentos presentados a los organismos reguladores y los informes de los analistas contienen información rica pero desestructurada que los métodos tradicionales de NLP tienen dificultades para analizar de forma eficaz. Por ello, el poder de los transformadores ha despertado el interés de los profesionales de la inversión, ya que los modelos de transformadores les permiten extraer información más profunda de los textos, mejorando la toma de decisiones y la evaluación de riesgos.

Hay varios LLM comerciales y de código abierto disponibles en el mercado, cada uno de ellos diseñado para satisfacer una variedad de necesidades, incluidas las específicas del sector financiero. Entre ellos, dos de los modelos más populares se basan en GPT (Generative Pre-trained Transformer) y BERT (Bidirectional Encoder Representations from Transformers). Dentro de la familia de modelos GPT, BloombergGPT⁵ está adaptado a aplicaciones financieras.

Del mismo modo, dentro de la familia de modelos BERT, FinBERT⁶ ha surgido como una versión de BERT que ha sido específicamente entrenada en análisis y comprensión de textos financieros.

BloombergGPT es un gran modelo de lenguaje desarrollado por Bloomberg, diseñado específicamente para el ámbito financiero. Su modelo contiene más de 50.000 millones de parámetros y se entrenó con un conjunto de datos de más de 700.000 millones de tokens (la unidad básica del texto). Esto incluye alrededor de 360.000 millones de tokens de sus fuentes de datos financieros (incluidos artículos de noticias, informes de investigación y datos de mercado), junto con 345.000 millones de tokens de conjuntos de datos de uso general.

Por otro lado, FinBERT es un modelo transformador compacto y de código abierto basado en la arquitectura BERT. Tal y como se describe en el artículo de Huang, Allen H., Hui Wang y Yi Yang de 2022, FinBERT se entrenó con un corpus de textos financieros estándar compuesto por 2.500 millones de tokens procedentes de informes corporativos (10-K y 10-Q), 1.300 millones de tokens de transcripciones de conferencias sobre resultados y 1.100 millones de tokens de informes de analistas.

Para el análisis de sentimientos, la capa de clasificación final de FinBERT se perfeccionó aún más utilizando 10.000 frases anotadas manualmente de informes de analistas, etiquetadas como positivas, negativas o neutras. Este entrenamiento específico permite a FinBERT detectar sentimientos matizados, como el optimismo cauteloso o la preocupación, que

suelen aparecer en las conferencias sobre resultados y en los documentos presentados a los organismos reguladores.

Dado que FinBERT se basa en la arquitectura BERT, hereda la capacidad de comprender el contexto y el significado a un nivel profundo. Al mismo tiempo, es más pequeño y eficiente que muchos otros LLM modernos, lo que lo hace práctico para su implementación en sistemas financieros del mundo real. Además, su naturaleza de código abierto permite su personalización e integración en flujos de trabajo propietarios.


Desafíos y riesgos de depender exclusivamente de LLM de terceros

Sin embargo, FinBERT también tiene algunas limitaciones conocidas. Por ejemplo, a veces clasifica erróneamente frases corteses como «Que tengas un buen día» o «Que aproveche» como sentimientos positivos, mientras que textos como

«no hay problema» como sentimientos negativos, a pesar de que son neutros en contextos financieros. Estos errores pueden mitigarse mediante un ajuste fino o utilizando técnicas de solicitud más avanzadas con LLM más nuevos como GPT 4, que interpretan mejor los matices sutiles⁷.


Mientras que los ejemplos anteriores se basaban en frases cortas, ahora pasamos a un enfoque de análisis de sentimiento **más escalable**, adecuado para documentos financieros más extensos: el **net sentiment**, que funciona con textos de cualquier longitud. Para calcular el *net sentiment*, el documento se divide primero en **bloques**. El sentimiento se evalúa después **en cada bloque de manera individual**. Posteriormente, los resultados se agregan desde el nivel de bloque hasta el nivel del documento completo, **comparando el número de bloques con sentimiento positivo frente a los negativos**, lo que da lugar a una **puntuación de sentimiento neto**⁸.

Basándonos en esta puntuación de sentimiento neto, hicimos otra observación que podría poner en duda la capacidad de FinBERT para detectar con precisión el sentimiento a nivel de empresas individuales. Si bien el modelo pudo identificar el sentimiento negativo durante la pandemia de COVID-19 (como se muestra en la zona gris del gráfico siguiente), es importante señalar que algunos sectores muestran sistemáticamente un sentimiento más positivo que otros. Por ejemplo, los servicios de comunicación (línea amarilla en el gráfico siguiente) y la tecnología de la información (línea naranja) siempre muestran



Fuente: Mistral AI, junio de 2025

Figura 1: Sentimiento neto medio de los sectores GICS



Fuente: Allianz Global Investors, equipo Systematic Equity. Datos a 30/06/2024. Back-test. Consulte la información relativa a «Back-tests y datos de rendimiento hipotéticos osimulados» en la última página de este documento. El rendimiento hipotético y las simulaciones que se muestran tienen únicamente fines ilustrativos y no representan el rendimiento real; no predicen los rendimientos futuros. Consulte la información importante relativa a back-testings y datos de rendimiento hipotéticos o simulados al final de este documento. Solo con fines ilustrativos y no representan el rendimiento real de ninguna cuenta de cliente. La información no debe considerarse un indicador deresultados futuros.

un sentimiento más positivo que los materiales (línea morada). Este sesgo sectorial puede requerir ajustes adicionales en la fase posterior del proceso de inversión, especialmente para los inversores que prefieren evitar las exposiciones específicas a determinados sectores porque no creen que asumir esos riesgos se vea compensado en el largo plazo.

Confiar únicamente en modelos estándar conlleva limitaciones adicionales, que pueden agruparse en dos cuestiones principales:

- **Cuestión 1:** En sus inicios, la mayorparte de la investigación sobre el NLP se llevaba a cabo en instituciones académicas, pero con el tiempo, las grandes empresas han tomado la delantera. Este cambio suscita preocupaciones en torno al cumplimiento normativo, la propiedad y privacidad de los datos y los derechos de autor,

aspectos fundamentales en el sector financiero, estrictamente regulado.

- **Cuestión 2:** Además, estos modelos siguen creciendo en tamaño y complejidad. Sin embargo, como se destaca en el documento de Chinchilla⁹, el simple hecho de aumentar el tamaño del modelo sin un aumento proporcional de los datos de entrenamiento de alta calidad conduce a una disminución de los beneficios. Para nuestras aplicaciones financieras propias es posible que no haya suficientes datos específicos del dominio para aprovechar plenamente estos modelos masivos de manera eficiente.


Por ello, los modelos preconfigurados no resultan suficientes para nuestras necesidades. Para garantizar un uso adecuado de los datos y maximizar el rendimiento en el ámbito financiero, necesitamos investigar y construir

modelos transformer propios, ajustados a nuestra estrategia.

Para abordar esta cuestión, hemos personalizado el modelo FinBERT específicamente para nuestros casos de uso, asegurándonos de que se ajustara mejor a los requisitos únicos de nuestro proceso de inversión. A continuación, realizamos una simulación exhaustiva utilizando señales de sentimiento generadas por nuestro modelo FinBERT personalizado. El resultado del backtest fue alentador: la estrategia simulada alcanzó un índice de información de aproximadamente 0,6 (antes de costes) frente al índice S&P 500 (como se muestra a continuación).

Esto demuestra que el sentimiento evaluado por máquinas, cuando se calibra e integra adecuadamente en un marco de inversión disciplinado, puede contribuir de manera significativa al rendimiento de la cartera.

Figura 2: Rendimiento relativo acumulado de nuestra señal personalizada basada en BERT



Fuente: Allianz Global Investors, equipo de Systematic Equity. Datos a 30/06/2024. Back-test. Consulte la información relativa a «Back-tests y datos de rendimiento hipotéticos o simulados» en la última página de este documento. El rendimiento hipotético y las simulaciones que se muestran tienen únicamente fines ilustrativos y no representan el rendimiento real; no predicen los rendimientos futuros. Consulte la información importante relativa a Back-testings y datos de rendimiento hipotéticos o simulados al final de este documento. Solo con fines ilustrativos y no representan el rendimiento real de ninguna cuenta de cliente. La información no debe considerarse un indicador de resultados futuros.

Aunque estos resultados son prometedores, esperamos seguir avanzando. Hasta ahora, este artículo se ha centrado únicamente en el sentimiento. Sin embargo, el potencial de los LLM va mucho más allá del análisis del sentimiento. Estos modelos son capaces de realizar tareas más sofisticadas, como comprender relaciones causales o incluso razonar. A medida que los LLM siguen evolucionando, vemos interesantes oportunidades para aprovechar sus capacidades con el fin de obtener conocimientos más profundos y análisis más sofisticados.

¿Pueden los LLM sustituir a los analistas? Probablemente no.

Basándonos en los prometedores resultados de nuestra estrategia basada en el sentimiento, dimos un paso más y nos preguntamos: ¿Podría

esta tecnología llegar a sustituir a un analista financiero?

Una función fundamental del análisis fundamental es la creación de modelos de valoración utilizando datos de balances y estados de flujo de caja. Tradicionalmente, esto requiere analistas cualificado para interpretar y contextualizar los fundamentos de las empresas. Para comprobar si los LLM podían ayudar en este ámbito, aprovechamos el modelo GPT-4 de OpenAI a través de la API de OpenAI, procesando informes de miles de empresas en paralelo.

Nuestros experimentos demostraron que los LLM pueden extraer cifras clave, calcular ratios y resumir tendencias generales con fiabilidad.

Esto concuerda con análisis como el recogido en un artículo de Chicago Booth¹⁰, que demostró que los LLM pueden asimilar estados de flujo de

caja y balances para evaluar la mejora de los beneficios futuros.

Sin embargo, estudios recientes subrayan las limitaciones de los modelos de razonamiento actuales. Shojaee et al. (2025)¹¹ examinaron sistemáticamente las capacidades de los grandes modelos de razonamiento y descubrieron que se enfrentan a un colapso en la precisión y la coherencia más allá de ciertos niveles de complejidad. Si bien los LLM destacan en el reconocimiento de patrones generales y pueden generar razonamientos y cadenas analíticas convincentes para tareas sencillas, su razonamiento computacional se deteriora ante problemas matizados y de alta complejidad, como los que se encuentran con frecuencia en el análisis exhaustivo de acciones. El estudio muestra además que estos modelos a menudo no emplean algoritmos explícitos y pueden producir explicaciones incoherentes

cuando se enfrentan a escenarios complejos.

Esto sugiere que, aunque los LLM pueden extraer cifras de forma fiable, identificar tendencias, calcular ratios y proporcionar puntos de partida analíticos, aún no son capaces de replicar por completo la profundidad,

la lógica y el rigor de un analista humano experto especialmente cuando la situación financiera exige un juicio matizado o la construcción de justificaciones de inversión a medida. En la práctica, los LLM deben considerarse una herramienta de apoyo, pero sus resultados siempre requieren una revisión e interpretación

meticulosa por parte de inversores experimentados y profesionales. Por lo tanto, en nuestra opinión, la experiencia, el razonamiento crítico y la intuición del analista humano siguen siendo indispensables para traducir el análisis computacional en decisiones de inversión de la más alta calidad.

Conclusión

En resumen, este artículo ha mostrado cómo la evolución del procesamiento del lenguaje natural, desde las primeras incrustaciones de palabras con GloVe hasta modelos transformadores avanzados como FinBERT—está remodelando el panorama de las finanzas cuantitativas. Al ir más allá de los enfoques estáticos y sin contexto a modelos que entienden el lenguaje en su contexto, hemos sido capaces de extraer información útil a partir de datos financieros no estructurados.

Nuestra experiencia demuestra que los modelos estándar, aunque potentes, a menudo se quedan cortos a la hora de satisfacer las exigencias específicas del análisis financiero, especialmente en lo que respecta al sesgo sectorial, el cumplimiento normativo y la privacidad de los datos. Al desarrollar

y adaptar nuestros propios modelos, hemos mejorado significativamente nuestro análisis de opiniones, como lo demuestra la simulación que superó al S&P 500 en términos sectoriales neutros.

A medida que estas tecnologías sigan avanzando, seguiremos centrándonos en perfeccionar nuestros modelos, integrar nuevas capacidades y aplicar de forma responsable los conocimientos basados en la inteligencia artificial a nuestras estrategias de renta variable sistemáticas, como Best Styles y Powered by AI. En última instancia, la combinación de la IA específica y del sector y la experiencia humana nos sitúa en una buena posición para descifrar las narrativas financieras de forma más eficaz y descubrir nuevas fuentes de valor en unos mercados en constante evolución.

Footnotes:

- ¹ La maldición de la dimensionalidad: se refiere a los diversos retos y complicaciones que surgen al analizar y organizar datos en espacios de alta dimensionalidad (a menudo cientos o miles de dimensiones). En el ámbito del aprendizaje automático, es fundamental comprender este concepto porque, a medida que aumenta el número de características o dimensiones de un conjunto de datos, la cantidad de datos que necesitamos para generalizar con precisión crece exponencialmente. Fuente: <https://www.datacamp.com/blog/curse-of-dimensionality-machine-learning>
- ² <https://www.jmlr.org/papers/volume3/bengio03a/bengio03a.pdf>
- ³ GloVe: Vectores globales para la representación de palabras. <https://nlp.stanford.edu/projects/glove/>
- ⁴ Vaswani, A., et al. (2017). La atención es todo lo que necesitas. Avances en sistemas de procesamiento de información neuronal, 30. arXiv:1706.03762
- ⁵ <https://arxiv.org/abs/2303.17564>
- ⁶ Huang, Allen H., Hui Wang, and Yi Yang. “«FinBERT: un gran modelo lingüístico para extraer información de textos financieros». Investigación contable contemporánea (2022). <https://doi.org/10.1111/1911-3846.12832>
- ⁷ <https://arxiv.org/html/2306.02136v2>
- ⁸ El sentimiento neto se calcula como $\log \left[\frac{1 + \text{número de frases positivas}}{1 + \text{número de frases negativas}} \right]$. Esta fórmula logarítmica ayuda a suavizar los valores extremos y garantiza que la métrica se defina incluso cuando no hay fragmentos positivos o negativos.
- ⁹ <https://doi.org/10.48550/arXiv.2203.15556>
- ¹⁰ Kim, A., et al. (2024). Análisis de estados financieros con LLM. arXiv:2407.17866
- ¹¹ Shojaei et al. (2025). La ilusión del pensamiento: comprender las fortalezas y limitaciones de los modelos de razonamiento a través de la lente de la complejidad del problema <https://doi.org/10.48550/arXiv.2506.06941>

Las pruebas retrospectivas y los datos de rendimiento hipotéticos o simulados tienen muchas limitaciones inherentes, algunas de las cuales se describen a continuación: (i) Se diseñan con la ventaja de la retrospectiva, basándose en datos históricos, y no reflejan el impacto que ciertos factores económicos y de mercado podrían haber tenido en el proceso de toma de decisiones, si la cartera de un cliente se hubiera gestionado realmente. Ninguna prueba retrospectiva, rendimiento hipotético o simulado puede explicar completamente el impacto del riesgo financiero en el rendimiento real. (ii) No reflejan transacciones reales y no pueden explicar con precisión la capacidad de soportar pérdidas. (iii) La información se basa, en parte, en hipótesis formuladas con fines de modelización que pueden no materializarse en la gestión real de las carteras. No se ofrece ninguna garantía ni se hace ninguna declaración sobre la razonabilidad de las hipótesis formuladas ni sobre el hecho de que todas las hipótesis utilizadas para obtener los rendimientos se hayan expuesto o considerado en su totalidad. Los cambios en las hipótesis pueden tener un impacto significativo en los rendimientos del modelo presentados. Las pruebas retrospectivas del rendimiento difieren del rendimiento real de la cartera, ya que la estrategia de inversión puede ajustarse en cualquier momento y por cualquier motivo. Los inversores no deben dar por sentado que obtendrán un rendimiento similar al de las pruebas retrospectivas, hipotéticas o simuladas que se muestran. Es posible que existan diferencias significativas entre los resultados de las pruebas retrospectivas, hipotéticas o simuladas y los resultados reales obtenidos posteriormente por cualquier estrategia de inversión.

Fuente: AllianzGI, a 30/06/2024. Las declaraciones aquí contenidas pueden incluir declaraciones sobre expectativas futuras y otras declaraciones prospectivas basadas en las opiniones y suposiciones actuales de la dirección, e implican riesgos e incertidumbres conocidos y desconocidos que podrían hacer que los resultados, el rendimiento o los acontecimientos reales difieran sustancialmente de los expresados o implícitos en dichas declaraciones. No asumimos ninguna obligación de actualizar ninguna declaración prospectiva.

Invertir conlleva riesgos. El valor de una inversión y los ingresos que genera pueden tanto subir como bajar, y es posible que los inversores no recuperen la totalidad del capital invertido. Invertir en instrumentos de renta fija puede exponer a los inversores a diversos riesgos, entre los que se incluyen, entre otros, los riesgos de solvencia, tipos de interés, liquidez y flexibilidad restringida. Los cambios en el entorno económico y las condiciones del mercado pueden afectar a estos riesgos, lo que puede tener un efecto adverso en el valor de la inversión. Durante los periodos de subida de los tipos de interés nominales, se espera que el valor de los instrumentos de renta fija (incluidas las posiciones con respecto a instrumentos de renta fija a corto plazo) disminuya. Por el contrario, durante los periodos de bajada de los tipos de interés, se espera que el valor de estos instrumentos aumente. El riesgo de liquidez puede retrasar o impedir los reembolsos o retiradas de fondos. La volatilidad de los precios de las participaciones/acciones del fondo puede aumentar o incluso aumentar considerablemente. El rendimiento pasado no es indicativo del rendimiento futuro. Si la moneda en la que se muestra el rendimiento pasado difiere de la moneda del país en el que reside el inversor, este debe tener en cuenta que, debido a las fluctuaciones del tipo de cambio, el rendimiento mostrado puede ser superior o inferior si se convierte a la moneda local del inversor. Esto es solo a título informativo y no debe interpretarse como una solicitud o invitación para realizar una oferta, celebrar un contrato o comprar o vender valores. Es posible que los productos o valores descritos en el presente documento no estén disponibles para su venta en todas las jurisdicciones o para determinadas categorías de inversores. Su distribución está sujeta a la legislación aplicable y, en particular, no está disponible para residentes y/o nacionales de los Estados Unidos. Las oportunidades de inversión descritas en el presente documento no tienen en cuenta los objetivos de inversión específicos, la situación financiera, los conocimientos, la experiencia o las necesidades específicas de ninguna persona en particular y no están garantizadas. La Sociedad Gestora puede decidir rescindir los acuerdos celebrados para la comercialización de sus organismos de inversión colectiva de conformidad con la normativa aplicable en materia de retirada de notificaciones. Las opiniones y puntos de vista expresados en el presente documento, que están sujetos a cambios sin previo aviso, son los de las sociedades emisoras en el momento de su publicación. Los datos utilizados proceden de diversas fuentes y se consideran correctos y fiables en el momento de su publicación. Prevalecerán las condiciones de cualquier oferta o contrato subyacente que se haya realizado o celebrado, o que se vaya a realizar o celebrar. No se permite la duplicación, publicación o transmisión de los contenidos, independientemente de la forma, salvo en caso de autorización expresa por parte de Allianz Global Investors GmbH.

Para inversores en Europa (excepto Suiza y el Reino Unido): Para obtener una copia gratuita del folleto de venta, los documentos de constitución, los precios diarios de los fondos, el documento de datos fundamentales, los últimos informes financieros anuales y semestrales, póngase en contacto con el emisor en la dirección indicada a continuación o en www.allianzgi-regulatory.eu. Los inversores austriacos también pueden ponerse en contacto con el agente de información austriaco Erste Bank der österreichischen Sparkassen AG, Am Belvedere 1, AT-1100 Viena. Lea atentamente estos documentos, que son los únicos vinculantes, antes de invertir. Esta es una comunicación comercial emitida por Allianz Global Investors GmbH, www.allianzgi.com, una sociedad de inversión de responsabilidad limitada, constituida en Alemania, con domicilio social en Bockenheimer Landstrasse 42-44, 60323 Fráncfort del Meno, inscrita en el registro mercantil de Fráncfort del Meno con el número HRB 9340, autorizada por la Bundesanstalt für Finanzdienstleistungsaufsicht (www.bafin.de). Allianz Global Investors GmbH tiene sucursales en Francia, Italia, España, Luxemburgo, Suecia, Bélgica y los Países Bajos. Los datos de contacto y la información sobre la normativa local están disponibles aquí (www.allianzgi.com/Info). El resumen de los derechos de los inversores está disponible en inglés, francés, alemán, italiano y español en <https://regulatory.allianzgi.com/en/investors-rights>.

Para inversores en Suiza: Para obtener una copia gratuita del folleto de venta, los documentos de constitución, los precios diarios de los fondos, la información clave para los inversores y los últimos informes financieros anuales y semestrales, póngase en contacto con [el representante y agente pagador de los fondos suizos BNP Paribas Securities Services, París, sucursal de Zúrich, Selnaustrasse 16, CH-8002 Zúrich, solo para inversores minoristas suizos] o con el emisor, ya sea por vía electrónica o por correo postal a la dirección indicada. Lea atentamente estos documentos, que son los únicos vinculantes, antes de invertir. Esta es una comunicación comercial emitida por Allianz Global Investors (Schweiz) AG, una filial al 100 % de Allianz Global Investors GmbH. El resumen de los derechos de los inversores está disponible en inglés, francés, alemán, italiano y español en <https://regulatory.allianzgi.com/en/investors-rights>.

Para inversores del Reino Unido: Para obtener una copia gratuita del folleto de venta, los documentos de constitución, los precios diarios del fondo, el documento de datos fundamentales para el inversor y los últimos informes financieros anuales y semestrales, póngase en contacto con el emisor en la dirección que se indica a continuación o en regulatory.allianzgi.com. Lea atentamente estos documentos, que son los únicos vinculantes, antes de invertir. Esta es una comunicación comercial emitida por Allianz Global Investors UK Limited, 199 Bishopsgate, Londres, EC2M 3TY, www.allianzglobalinvestors.co.uk. Allianz Global Investors UK Limited, con número de registro mercantil 11516839, está autorizada y regulada por la Autoridad de Conducta Financiera. Los detalles sobre el alcance de nuestra regulación están disponibles previa solicitud y en el sitio web de la Autoridad de Conducta Financiera (www.fca.org.uk). No se permite la duplicación, publicación o transmisión de los contenidos, independientemente de la forma, salvo en caso de autorización expresa por parte de Allianz Global Investors UK Limited.