



IA y Computación Cuántica: Soluciones Innovadoras para Solvencia II e IFRS 17

White Paper de Fermac Risk

Abril 2024






Prefacio

La industria de seguros está atravesando una profunda transformación, impulsada por la aparición de nuevos riesgos, la evolución de los marcos regulatorios y el rápido avance de la tecnología. En este panorama dinámico, las aseguradoras enfrentan el desafío de gestionar eficazmente el riesgo y al mismo tiempo cumplir con regulaciones complejas como Solvencia II y la IFRS 17. Los enfoques tradicionales de gestión de riesgos, si bien siguen siendo relevantes, ya no son suficientes para navegar las complejidades del entorno asegurador moderno. Aquí es donde entra en juego la integración de la inteligencia artificial (IA) y la computación cuántica, ofreciendo a las aseguradoras herramientas poderosas para revolucionar sus prácticas de gestión de riesgos.

Este curso, " IA y Computación Cuántica: Soluciones Innovadoras para Solvencia II e IFRS 17", explora las técnicas y metodologías de vanguardia que están transformando la gestión de riesgos en la industria de seguros. Al aprovechar el poder de la inteligencia artificial y la computación cuántica, las aseguradoras pueden obtener conocimientos sin precedentes, mejorar la toma de decisiones y desbloquear nuevas oportunidades para la evaluación de riesgos, la gestión de capital y el cumplimiento normativo.

1. IA y computación cuántica en seguros y Modelización de riesgos financieros

INSURANCE AND PROTECTION



La IA, la IA generativa (GEN AI) y la computación cuántica son tecnologías emergentes que pueden revolucionar la modelización de riesgos financieros y de seguros, particularmente en el contexto de marcos regulatorios como Solvencia II y IFRS 17. Exploremos cómo se pueden aplicar estas tecnologías en este dominio:

IA en seguros y Modelización de riesgos financieros:

Las técnicas de inteligencia artificial, como el aprendizaje automático y el aprendizaje profundo, pueden mejorar la precisión y eficiencia de los procesos de Modelización de riesgos.

Modelización predictiva:

Los algoritmos de IA pueden analizar grandes volúmenes de datos históricos para identificar patrones y predecir riesgos futuros, como la

frecuencia, la gravedad o el comportamiento de los asegurados.

Suscripción y fijación de precios:

Los modelos de IA pueden ayudar en la evaluación de riesgos y la fijación de precios premium al considerar una amplia gama de factores de riesgo y optimizar las estrategias de precios.

Gestión de reclamaciones:

La IA puede agilizar el procesamiento de reclamaciones automatizando tareas, detectando reclamaciones fraudulentas y mejorando la precisión de las estimaciones de reservas.

Gestión de Activos y Pasivos:

La IA puede optimizar la asignación de activos y ayudar a las aseguradoras a cumplir con sus obligaciones según Solvencia II y la IFRS 17 al considerar los riesgos de mercado, los riesgos de liquidez y los requisitos de capital.

IA generativa (GEN AI) en seguros y modelización de riesgos financieros:

GEN AI, como Generative Adversarial Networks (GAN) y Variational Autoencoders (VAE), puede generar datos sintéticos que imitan las características de los datos financieros y de seguros del mundo real.

Generación de datos sintéticos:

GEN AI puede crear conjuntos de datos sintéticos realistas para modelar riesgos, aumentando datos



históricos limitados y mejorando la solidez de los modelos.

Generación de escenarios:

GEN AI puede generar escenarios futuros plausibles, como condiciones económicas o eventos catastróficos, para probar los modelos de riesgo financiero y de seguros.

Aumento de datos:

GEN AI puede enriquecer los conjuntos de datos existentes generando muestras adicionales, lo que ayuda a abordar la escasez de datos y mejorar el rendimiento del modelo.

Detección de fraude:

GEN AI puede generar ejemplos sintéticos de actividades fraudulentas, lo que permite el desarrollo de modelos de detección de fraude más eficaces.

Computación cuántica en seguros y Modelización de riesgos financieros:

La computación cuántica aprovecha los principios de la mecánica cuántica para realizar cálculos complejos más rápido que las computadoras clásicas.

Problemas de optimización:

Los algoritmos cuánticos, como el recocido cuántico o los algoritmos de optimización cuántica aproximada (QAOA), pueden resolver problemas complejos de optimización en seguros y finanzas, como la optimización de carteras o la asignación de riesgos.

Simulación y análisis de escenarios:

Las computadoras cuánticas pueden realizar simulaciones y análisis de escenarios a gran escala, lo que permite a las aseguradoras evaluar el impacto de diversos factores de riesgo en sus posiciones financieras.

Mejora del aprendizaje automático:

Los algoritmos de aprendizaje automático cuántico pueden potencialmente acelerar el entrenamiento de modelos de IA y mejorar su desempeño en tareas de Modelización de riesgos.

Criptografía y seguridad de datos:

La criptografía cuántica puede mejorar la seguridad de los datos financieros y de seguros confidenciales,

garantizando el cumplimiento de los requisitos reglamentarios.

Integración con Solvencia II y IFRS 17:

Solvencia II y IFRS 17 son marcos regulatorios que requieren que las aseguradoras evalúen y gestionen sus riesgos de forma eficaz. La IA, la GEN AI y la computación cuántica pueden respaldar el cumplimiento de estos marcos al:

- Mejorar la precisión y granularidad de los cálculos de riesgo y los requisitos de capital.
- Mejorar La modelización de pasivos complejos, como contratos de seguro a largo plazo, según la IFRS 17.
- Apoyar la generación de escenarios de riesgo y pruebas de estrés requeridos por Solvencia II.
- Optimizar la asignación de activos y gestionar los riesgos de mercado en línea con los requisitos de Solvencia II.
- Automatizar los procesos de presentación de informes y divulgación, garantizando un cumplimiento oportuno y preciso.


Es importante señalar que la adopción de la IA, la GEN AI y la computación cuántica en los modelos de seguros y riesgos financieros aún se encuentra en las primeras etapas. Las aseguradoras y las instituciones financieras necesitan invertir en investigación, desarrollo de talentos e infraestructura para aprovechar todo el potencial de estas tecnologías. La colaboración con proveedores de tecnología, academia y reguladores es crucial para garantizar una implementación confiable y compatible de estas técnicas avanzadas.

A medida que las industrias financieras y de seguros sigan evolucionando, la integración de la IA, la IA GEN y la computación cuántica en La modelización de riesgos probablemente será cada vez más importante. Estas tecnologías pueden mejorar la evaluación de riesgos, mejorar la toma de decisiones y fortalecer la resiliencia de las aseguradoras y las instituciones financieras ante riesgos complejos y en evolución.

2. La valoración de las provisiones técnicas en seguros de vida y no vida.



INSURANCE PAYMENTS



La valoración de las provisiones técnicas en seguros de vida y no vida implica la estimación de los pasivos futuros asociados a las pólizas de seguro. A continuación, se muestran algunos enfoques utilizados habitualmente para valorar las provisiones técnicas tanto en seguros de vida como en seguros distintos de los de vida:

Seguro de vida: Valoración de Prima Bruta (GPV):

- GPV es un método de valoración prospectivo que considera el valor presente de los beneficios y gastos futuros, compensado por el valor presente de las primas brutas futuras.
 - Considera las tasas de mortalidad, las tasas de rescate, los gastos y los rendimientos de las inversiones para proyectar los flujos de efectivo futuros.
 - El método GPV se utiliza comúnmente para contratos de seguro de vida a largo plazo, como pólizas de vida entera o de dotación.

Valoración de la prima neta (VAN):

- El VPN es como el GPV, pero considera sólo el valor presente de los beneficios y gastos futuros sin considerar las primas futuras.
- Asume que las primas son suficientes para cubrir los beneficios y gastos durante la vigencia de la póliza.
- El VPN se utiliza a menudo para contratos de seguro de vida a corto plazo o cuando no se espera que la prima cambie significativamente con el tiempo.

Método de flujo de caja descontado (DCF):

- El método DCF implica proyectar entradas de efectivo (primas) y salidas (beneficios y gastos) futuras asociadas con una póliza de seguro de vida.
- Estos flujos de efectivo luego se descuentan al valor presente utilizando una tasa de descuento adecuada.
- El método DCF permite modelar más detalladamente los flujos de efectivo y puede incorporar varios supuestos y escenarios.

Modelización estocástica:

- La modelización estocástica implica generar múltiples escenarios de resultados futuros basados en distribuciones de probabilidad de variables clave, como tasas de mortalidad, tasas de interés y comportamiento de los asegurados.
- Utiliza técnicas como la simulación de Monte Carlo para generar una variedad de resultados posibles y evaluar la variabilidad y la incertidumbre en la valoración de las provisiones técnicas.
- Los modelos estocásticos pueden proporcionar una visión más completa de los riesgos y resultados potenciales asociados con las obligaciones de los seguros de vida.

Seguros No Vida: Método de escalera de cadena:

- El método de la escalera de cadenas es un enfoque determinista ampliamente utilizado para estimar el costo final de las reclamaciones en seguros distintos de los de vida.
- Implica analizar patrones históricos de desarrollo de reclamaciones para proyectar pagos de reclamaciones futuras.
- El método supone que el patrón de desarrollo de las reclamaciones permanece constante a lo largo del tiempo y utiliza factores de desarrollo para estimar el costo final de las reclamaciones.

Método Bornhuetter-Ferguson:

- El método de Bornhuetter-Ferguson combina el método de la escalera de cadenas con una estimación a priori del coste final de los siniestros.
- Utiliza el índice de pérdida esperada o un punto de referencia externo para estimar el costo final de las reclamaciones y luego lo combina con los patrones de desarrollo de las reclamaciones observados en los datos históricos.
- Este método es útil cuando la experiencia de siniestros es limitada o cuando hay cambios significativos en los riesgos subyacentes.

Modelización de frecuencia-severidad:

- El modelo de frecuencia-gravedad modela por separado la frecuencia (número) y la gravedad (costo promedio) de las reclamaciones.

- Implica ajustar distribuciones de probabilidad a los datos históricos de frecuencia y gravedad de los siniestros y luego combinarlos para estimar el costo total de los siniestros.
- Este enfoque permite un análisis más granular de los factores de riesgo subyacentes y puede manejar cambios en los patrones de reclamaciones o las características de las políticas.

Reserva estocástica:


- Las técnicas de reservas estocásticas, como el bootstrapping o los métodos bayesianos, incorporan incertidumbre en la estimación de las reservas de siniestros.
- Estos métodos generan una variedad de posibles estimaciones de reservas basadas en la variabilidad de los datos históricos de reclamaciones.
- Las reservas estocásticas proporcionan una visión probabilística de la idoneidad de las provisiones técnicas y ayudan a evaluar la variabilidad potencial en los pagos de siniestros futuros.

Además de estos métodos, las aseguradoras pueden utilizar una combinación de enfoques o desarrollar modelos personalizados basados en sus productos específicos, disponibilidad de datos y perfiles de riesgo. La elección del enfoque de valoración depende de factores como la naturaleza de los contratos de seguro, la disponibilidad y calidad de los datos, los requisitos regulatorios y el nivel deseado de granularidad en el análisis.

Es importante señalar que la valoración de las provisiones técnicas es un proceso continuo que requiere actualizaciones y mejoras periódicas basadas en nueva información, cambios en los supuestos y tendencias emergentes en el mercado de seguros. Las aseguradoras también deberían considerar el impacto potencial de factores externos, como las condiciones económicas, los cambios regulatorios y los avances tecnológicos, en la valoración de sus provisiones técnicas.

3. Uso de IA generativa para la valoración de provisiones técnicas de seguros de vida

POPULAR TYPES OF INSURANCE



La IA generativa, como las redes generativas adversarias (GAN) y los codificadores automáticos variacionales (VAE), se pueden aplicar a la valoración de las provisiones de seguros de vida, ofreciendo varios beneficios potenciales. Así es como se puede utilizar la IA generativa en este contexto:

Generación de datos sintéticos:

- Los modelos de IA generativa se pueden utilizar para generar datos sintéticos de pólizas y reclamaciones que imiten las características y distribuciones de los datos de seguros de la vida real.
- Los datos sintéticos pueden aumentar los datos históricos limitados, permitiendo a las aseguradoras entrenar modelos más sólidos y precisos para valorar las provisiones de seguros de vida.
- La IA generativa puede ayudar a las aseguradoras a evaluar la sensibilidad de sus modelos de valoración a diferentes supuestos y factores de riesgo generando diversos escenarios y casos extremos.

Modelización de mortalidad y longevidad:

- La IA generativa se puede emplear para modelar patrones de mortalidad y longevidad, capturando dependencias y tendencias complejas en la demografía de la población.
- Las GAN o VAE pueden conocer las distribuciones subyacentes de las tasas de mortalidad entre diferentes grupos de edad, géneros y factores de riesgo.
- Al generar escenarios de mortalidad realistas, la IA generativa puede ayudar a proyectar flujos de efectivo futuros y estimar los pasivos a largo plazo asociados con las pólizas de seguro de vida.

Modelización de comportamiento del asegurado:

- La IA generativa se puede utilizar para modelar el comportamiento de los asegurados, como las tasas



de caducidad, las tasas de rescate y los patrones de pago de primas.

- Al aprender de los datos históricos de los asegurados, los modelos generativos pueden generar escenarios realistas de acciones de los asegurados en diversas circunstancias económicas y personales.
- Estos escenarios generados pueden ayudar a las aseguradoras a evaluar el impacto del comportamiento de los asegurados en la valoración de las provisiones de seguros de vida y hacer suposiciones más informadas en sus modelos.

Generación de escenarios económicos:

- La IA generativa se puede utilizar para generar escenarios económicos plausibles, incluidas tasas de interés, tasas de inflación y rendimientos de activos.
- Los VAE o GAN pueden aprender las distribuciones conjuntas de variables económicas y generar escenarios coherentes que capturen las dependencias y correlaciones entre ellas.
- Estos escenarios económicos generados se pueden utilizar como insumos para modelos de valoración estocástica, lo que permite a las aseguradoras evaluar el impacto de diferentes condiciones económicas en el valor de las provisiones de seguros de vida.

Proyección de flujo de caja del pasivo:

- La IA generativa se puede emplear para proyectar los flujos de caja de pasivos futuros asociados con las pólizas de seguro de vida.
- Al combinar la mortalidad generada, el comportamiento de los asegurados y los escenarios económicos, las aseguradoras pueden simular las salidas de efectivo esperadas durante la vida útil de las pólizas.
- Estas proyecciones de flujo de efectivo generadas pueden ayudar a valorar las provisiones de seguros de vida, permitiendo a las aseguradoras estimar con precisión el valor presente de los pasivos futuros.

Análisis de sensibilidad y pruebas de estrés:

- La IA generativa puede facilitar el análisis de sensibilidad y las pruebas de tensión de las valoraciones de las provisiones de seguros de vida.
- Al generar una amplia gama de escenarios con diferentes supuestos y factores de riesgo, las aseguradoras pueden evaluar la solidez de sus

modelos de valoración e identificar posibles vulnerabilidades.

- La IA generativa puede ayudar a las aseguradoras a explorar el impacto de eventos o riesgos extremos en la adecuación de sus provisiones de seguros de vida.

Validación de modelos y evaluación comparativa:

- La IA generativa se puede utilizar para validar y comparar modelos de valoración tradicionales para provisiones de seguros de vida.
- Al generar conjuntos de datos sintéticos con propiedades conocidas y comparar los resultados de los modelos tradicionales con los modelos generativos de IA, las aseguradoras pueden evaluar la precisión y confiabilidad de sus enfoques de valoración existentes.
- Este proceso de validación puede ayudar a identificar posibles sesgos, limitaciones o áreas de mejora en los modelos de valoración actuales.


Para aprovechar los beneficios de la IA generativa en la valoración de las provisiones de seguros de vida, las aseguradoras deben tener acceso a datos históricos suficientes y de alta calidad para entrenar los modelos. También deben garantizar que los escenarios generados se alineen con la dinámica del mundo real y cumplan con las regulaciones y principios actuariales pertinentes.

La colaboración entre actuarios, científicos de datos y expertos en el campo es crucial para garantizar la aplicación adecuada de las técnicas de IA generativa y la interpretación de los resultados generados. La IA generativa debería utilizarse como una herramienta complementaria para mejorar y validar los métodos de valoración tradicionales, en lugar de como un reemplazo completo.

Al igual que con cualquier aplicación de IA, el uso de IA generativa en la valoración de las provisiones de seguros de vida debe estar sujeto a procesos rigurosos de gobernanza, validación y seguimiento para garantizar la confiabilidad, equidad y explicabilidad de los modelos y sus resultados.



4. Uso de IA generativa para la valoración de provisiones técnicas de seguros no de vida



Las técnicas de IA generativa, como las redes generativas adversas (GAN) y los codificadores automáticos variacionales (VAE), se pueden aplicar a la valoración de provisiones de seguros distintos de los de vida, ofreciendo varios beneficios potenciales. Así es como se puede utilizar la IA generativa en este contexto:

Generación de datos de reclamaciones:

- Los modelos de IA generativa se pueden utilizar para generar datos de reclamaciones sintéticas que imiten las características y distribuciones de las reclamaciones del mundo real.
- Al aprender de los datos históricos de reclamaciones, las GAN o VAE pueden generar escenarios realistas de frecuencia, gravedad y patrones de desarrollo de las reclamaciones.
- Los datos sintéticos de siniestros pueden aumentar los datos históricos limitados, permitiendo a las aseguradoras entrenar modelos más sólidos y precisos para valorar las provisiones de seguros distintos de los de vida.

Estimación de reserva de pérdidas:

- La IA generativa se puede emplear para estimar las reservas para pérdidas, que representan los pagos futuros esperados por reclamaciones incurridas pero que aún no se han liquidado por completo.
- Al generar escenarios plausibles de desarrollo de siniestros futuros, los modelos generativos pueden ayudar a las aseguradoras a proyectar el costo final de los siniestros y estimar las reservas para pérdidas requeridas.
- Este enfoque puede capturar la incertidumbre y la variabilidad en los patrones de desarrollo de

siniestros y proporcionar una variedad de posibles estimaciones de reservas.

Clasificación de reclamos y detección de anomalías:

- La IA generativa puede ayudar en la clasificación de reclamaciones generando ejemplos de patrones de reclamaciones normales y anómalos.
- Al entrenar modelos generativos con datos históricos de reclamaciones, las aseguradoras pueden identificar reclamaciones inusuales o potencialmente fraudulentas que se desvían de los patrones esperados.
- Esto puede ayudar a agilizar el procesamiento de reclamaciones, mejorar la detección de fraude y optimizar la asignación de recursos en la gestión de reclamaciones.

Simulación de exposición:

- La IA generativa se puede utilizar para simular escenarios de exposición realistas, considerando factores como las características de las políticas, la demografía de los asegurados y las ubicaciones geográficas.
- Al generar diversos perfiles de exposición, las aseguradoras pueden evaluar el impacto potencial de diferentes estrategias de suscripción o segmentos de mercado en la valoración de las provisiones de seguros distintos de los de vida.
- Esto puede ayudar a las aseguradoras a tomar decisiones informadas sobre precios, selección de riesgos y acuerdos de reaseguro.

Modelización de catástrofes naturales:

- La IA generativa se puede aplicar para modelar catástrofes naturales, como huracanes, terremotos o inundaciones, que pueden tener un impacto significativo en las provisiones de seguros distintos de los de vida.
- Al aprender de los datos históricos de catástrofes y simular escenarios de eventos plausibles, los modelos generativos pueden ayudar a las aseguradoras a estimar las pérdidas potenciales y evaluar la idoneidad de sus provisiones.
- Este enfoque puede capturar las complejas dependencias y correlaciones espaciales entre eventos catastróficos y proporcionar una visión más integral de los riesgos asociados.



Análisis de escenarios y pruebas de estrés:

- La IA generativa puede facilitar el análisis de escenarios y las pruebas de tensión de las provisiones de seguros distintos de los de vida.
- Al generar una amplia gama de escenarios plausibles, incluidos eventos extremos o crisis económicas, las aseguradoras pueden evaluar la resiliencia de sus provisiones bajo diferentes condiciones de estrés.
- Esto puede ayudar a identificar vulnerabilidades potenciales, optimizar la asignación de capital e informar las estrategias de gestión de riesgos.

Optimización de Reaseguros:

- La IA generativa se puede utilizar para optimizar las estrategias de reaseguro para carteras de seguros distintos de los de vida.
- Al simular diferentes estructuras de reaseguro y puntos de vinculación, las aseguradoras pueden evaluar el impacto en la valoración de sus provisiones e identificar los acuerdos de transferencia de riesgos más eficientes.
- Los modelos generativos pueden ayudar a las aseguradoras a evaluar las compensaciones entre la retención de riesgos y los costos de reaseguro, permitiendo la toma de decisiones basada en datos en la optimización del reaseguro.

Para aprovechar eficazmente la IA generativa en la valoración de las provisiones de seguros no de vida, las aseguradoras deben tener acceso a datos históricos de reclamaciones suficientes y de alta calidad para entrenar los modelos. También deben garantizar que los escenarios generados se alineen con la dinámica del mundo real y cumplan con las regulaciones y estándares actuariales pertinentes.

La colaboración entre actuarios, científicos de datos y expertos en el dominio es esencial para garantizar la aplicación adecuada de las técnicas de IA generativa y la interpretación de los resultados generados. La IA generativa debería utilizarse como una herramienta complementaria para mejorar y validar los métodos de valoración tradicionales, en lugar de como un reemplazo completo.

Al igual que con cualquier aplicación de IA, el uso de IA generativa en la valoración de provisiones de seguros distintos de los de vida debe estar sujeto a

procesos rigurosos de gobernanza, validación y seguimiento para garantizar la confiabilidad, equidad y explicabilidad de los modelos y sus resultados. Las aseguradoras también deberían considerar las posibles limitaciones y sesgos de los modelos generativos y actualizarlos y perfeccionarlos periódicamente a medida que haya nuevos datos disponibles.

5. Nuestra Experiencia en IFRS 17

HOW TO GET A LIFE INSURANCE POLICY?



La IFRS 17 es una norma contable integral para contratos de seguro que introduce cambios significativos en la forma en que las aseguradoras miden, presentan y revelan sus pasivos de seguro. La norma exige que las aseguradoras utilicen un enfoque de medición actual, que refleje el valor temporal del dinero, el riesgo asociado con los contratos de seguro y el impacto financiero de las opciones y garantías incluidas en los contratos.

El enfoque para implementar la IFRS 17 implica varios componentes y consideraciones clave:

Modelos de Medición:

- Modelo General de Medición (GMM): El modelo predeterminado según la IFRS 17, que se aplica a la mayoría de los contratos de seguro. Requiere que las aseguradoras midan los pasivos de seguros utilizando un valor de cumplimiento actual, que comprende el valor presente de los flujos de efectivo futuros, un ajuste de riesgo para el riesgo no financiero y un margen de servicio contractual (CSM) que representa la ganancia no devengada.
- Enfoque de asignación de primas (PAA): un enfoque simplificado que permite contratos de corta duración o contratos que cumplen ciertos criterios de elegibilidad. Según la PAA, las aseguradoras miden el pasivo por la cobertura restante utilizando la prima no devengada y el pasivo por reclamaciones incurridas utilizando el valor presente de los flujos de efectivo futuros y un ajuste de riesgo.
- Enfoque de tarifa variable (VFA): Aplicable a contratos de seguro con características de participación directa, donde los asegurados



participan en los rendimientos de los elementos subyacentes. El VFA ajusta el CSM en función de los cambios en la tarifa variable ganada por la aseguradora.

Agrupación de Contratos:

- La IFRS 17 exige que las aseguradoras agrupen los contratos de seguro en función de su nivel de rentabilidad y características de riesgo.
- Los contratos se agrupan en carteras, que a su vez se dividen en cohortes anuales y grupos de rentabilidad (onerosos, sin riesgo significativo de volverse onerosos, y otros).
- La agrupación de contratos afecta la medición y reconocimiento del CSM y el momento del reconocimiento de ganancias.

Transición:

- La IFRS 17 proporciona tres enfoques de transición: el enfoque retrospectivo completo, el enfoque retrospectivo modificado y el enfoque del valor razonable.
- Las aseguradoras deben evaluar la disponibilidad de datos históricos y la viabilidad de aplicar cada enfoque para determinar el método de transición más apropiado para sus circunstancias.
- La elección del enfoque de transición puede afectar significativamente al balance inicial y al reconocimiento futuro de beneficios.

Datos y Sistemas:

- La implementación de la IFRS 17 requiere cambios significativos en la gestión de datos y los sistemas de TI de las aseguradoras.
- Las aseguradoras deben asegurarse de tener la granularidad, precisión e integridad de los datos necesarios para respaldar los modelos de medición y los requisitos de divulgación.
- Es posible que sean necesarias actualizaciones o reemplazos de los sistemas existentes para manejar la mayor complejidad y los requisitos computacionales de la IFRS 17.

Modelos actuariales y supuestos:

- La IFRS 17 requiere que las aseguradoras utilicen supuestos actuales y explícitos al medir los pasivos de seguros.

- Es necesario adaptar o desarrollar modelos actuariales para incorporar los requisitos de la IFRS 17, incluida la proyección de flujos de efectivo futuros, la determinación de tasas de descuento y la estimación de ajustes por riesgo.
- Los supuestos deben revisarse y actualizarse periódicamente para reflejar los cambios en el entorno económico, el comportamiento de los asegurados y otros factores relevantes.

Impacto financiero y comunicación con las partes interesadas:

- La IFRS 17 puede afectar significativamente los estados financieros, los indicadores clave de desempeño y las posiciones de capital regulatorio de las aseguradoras.
- Las aseguradoras deben evaluar las implicaciones financieras de la IFRS 17 y desarrollar estrategias para gestionar la volatilidad potencial en los resultados informados.
- La comunicación clara y transparente con las partes interesadas, incluidos inversores, analistas y reguladores, es crucial para explicar los cambios provocados por la IFRS 17 y su impacto en el desempeño financiero de la aseguradora.

Gobernanza y controles:

- La implementación de la IFRS 17 requiere una gobernanza y controles internos sólidos para garantizar la confiabilidad y precisión de los informes financieros.
- Las aseguradoras deben establecer políticas, procedimientos y controles apropiados para la gestión de datos, la validación de modelos, el establecimiento de supuestos y los procesos de presentación de informes financieros.
- El monitoreo, las pruebas y la revisión periódica de los procesos y resultados de la IFRS 17 son necesarios para mantener el cumplimiento e identificar áreas de mejora.

La implementación de la IFRS 17 es una tarea compleja y multifacética que requiere importantes recursos, experiencia y colaboración multifuncional dentro de las organizaciones de seguros. Las aseguradoras deben desarrollar un plan de implementación integral, involucrarse con las partes interesadas y asignar suficiente tiempo y recursos para realizar una transición exitosa al nuevo estándar.



A continuación se muestran algunos ejercicios del curso sobre el enfoque de la IFRS 17.

Ejercicio de Modelos de Medición:

Una aseguradora tiene una cartera de contratos de seguro de vida a término con un período de cobertura de 10 años. Según la IFRS 17, la aseguradora aplica el Modelo General de Medición (GMM) para medir los pasivos por seguros. Proyectan las futuras entradas de efectivo (primas) y salidas (reclamaciones, gastos) asociadas con los contratos, las descuentan al valor presente utilizando las tasas de descuento actuales y agregan un ajuste de riesgo para el riesgo no financiero. La diferencia entre el valor presente de las entradas y salidas de efectivo, menos el ajuste por riesgo forma el margen de servicio contractual (CSM), que representa la ganancia no devengada que se reconocerá durante el período de cobertura.

Ejercicio de Agrupación de Contratos:

Una aseguradora ofrece productos de seguro de vida temporal y de vida total. Agrupan los contratos en carteras separadas en función de sus distintas características de riesgo. Dentro de cada cartera, los contratos se dividen en cohortes anuales según el año de emisión. Luego, la aseguradora evalúa la rentabilidad de cada cohorte en el reconocimiento inicial y los agrupa en contratos onerosos, sin riesgo significativo de volverse onerosos y otros. Esta agrupación afecta la medición y el reconocimiento del CSM y ayuda a brindar transparencia en la rentabilidad de las diferentes líneas de productos.

6. Experiencia en Fermac Risk modelizando el riesgo de mercado en compañías de seguros

HOW TO GET A LIFE INSURANCE POLICY?



La modelización del riesgo de mercado es un componente crucial del marco de Solvencia II, ya que ayuda a las compañías de seguros a evaluar y gestionar las pérdidas financieras potenciales que

surgen de movimientos adversos en los precios de mercado. El riesgo de mercado abarca varios factores de riesgo, como tasas de interés, precios de acciones, tipos de cambio y diferenciales de crédito. A continuación, se muestran algunos enfoques para modelar el riesgo de mercado en Solvencia II, junto con ejercicios y estudios de casos en nuestro curso:

Ejercicio de fórmula estándar:

Supongamos que una aseguradora utiliza la fórmula estándar prescrita por Solvencia II para calcular su capital de solvencia obligatorio (SCR) para riesgo de mercado. La Fórmula Estándar proporciona un enfoque estandarizado que aplica escenarios de estrés predefinidos a cada submódulo de riesgo de mercado, como riesgo de tasa de interés, riesgo de acciones y riesgo de divisas. La aseguradora ingresa sus exposiciones de activos en la Fórmula Estándar y obtiene el SCR para Riesgo de Mercado basado en el impacto agregado de los escenarios de estrés.

Ejercicio de Modelos Internos:

Una gran compañía de seguros desarrolla su propio modelo interno para evaluar el Riesgo de Mercado. El modelo interno se adapta a la cartera de activos, el perfil de riesgo y las estrategias de inversión específicos de la aseguradora. El modelo incorpora técnicas estadísticas avanzadas, como las simulaciones de Monte Carlo, para generar una gran cantidad de escenarios para factores de riesgo de mercado. La aseguradora utiliza el modelo interno para calcular su SCR por Riesgo de Mercado, teniendo en cuenta las dependencias y efectos de diversificación entre diferentes factores de riesgo.

Ejercicio de Valor en Riesgo (VaR) y Déficit Esperado (ES):

Una aseguradora utiliza medidas de valor en riesgo (VaR) y déficit esperado (ES) para cuantificar su exposición al riesgo de mercado. El VaR estima la pérdida potencial máxima en un horizonte temporal determinado con un nivel de confianza específico, mientras que ES mide la pérdida promedio más allá del umbral del VaR. Estas medidas de riesgo ayudan a la aseguradora a evaluar sus pérdidas potenciales en condiciones de mercado normales y estresadas.

Ejercicio de Pruebas de Estrés y Análisis de Escenarios:



Una aseguradora realiza pruebas de estrés y análisis de escenarios para evaluar el impacto de eventos extremos del mercado en su posición financiera. La aseguradora define una serie de escenarios de tensión, como un aumento significativo de los tipos de interés, una fuerte caída de los mercados de valores o una ampliación de los diferenciales de crédito. Luego, la aseguradora evalúa el impacto de estos escenarios en sus activos, pasivos y requisitos de capital. Las pruebas de estrés ayudan a la aseguradora a identificar vulnerabilidades potenciales y desarrollar estrategias de mitigación de riesgos.

Ejercicio de Generadores de Escenarios Económicos (ESG):

Una aseguradora utiliza generadores de escenarios económicos (ESG) para simular muchos escenarios económicos futuros plausibles. Los ESG son modelos sofisticados que generan trayectorias consistentes y realistas para los factores de riesgo de mercado, como las tasas de interés, los rendimientos de las acciones y la inflación. La aseguradora utiliza estos escenarios generados como insumos para sus modelos de gestión de activos y pasivos (ALM) y marcos de valoración. Al analizar los resultados en una amplia gama de escenarios, la aseguradora puede evaluar la solidez de sus estrategias de inversión y tomar decisiones informadas de gestión de riesgos.

Gestión de Activos y Pasivos (ALM):

Una aseguradora integra la modelización de riesgo de mercado en su marco de gestión de activos y pasivos (ALM). ALM implica gestionar los activos y pasivos de la aseguradora de manera coordinada para garantizar que la aseguradora pueda cumplir con sus obligaciones con los asegurados. La aseguradora utiliza modelos ALM para proyectar sus flujos de efectivo de activos y pasivos bajo diferentes escenarios de mercado, considerando las interacciones entre los factores de riesgo de mercado y los riesgos de seguro. ALM ayuda a la aseguradora a optimizar sus estrategias de inversión, igualar las duraciones de los activos y pasivos y gestionar el riesgo de liquidez.

Estos enfoques para modelar el riesgo de mercado en Solvencia II ayudan a las aseguradoras a evaluar su

exposición a las fluctuaciones del mercado, calcular sus requisitos de capital y tomar decisiones informadas de gestión de riesgos. La elección del enfoque depende de factores como el tamaño, la complejidad, el perfil de riesgo y los recursos disponibles de la aseguradora.

Es importante señalar que modelar el riesgo de mercado es un proceso continuo que requiere actualizaciones y validación periódicas. Las aseguradoras necesitan monitorear sus exposiciones al riesgo de mercado, adaptar sus modelos a las condiciones y regulaciones cambiantes del mercado y mejorar continuamente sus prácticas de gestión de riesgos para garantizar el cumplimiento de Solvencia II y mantener la estabilidad financiera.

7. Riesgo de suscripción de No Vida



El riesgo de suscripción de No Vida es un componente crítico del marco Solvencia II, cuyo objetivo es garantizar la estabilidad financiera y la solvencia de las compañías de seguros en la Unión Europea. Según Solvencia II, las aseguradoras deben evaluar y cuantificar su riesgo de suscripción de no vida para determinar el nivel adecuado de capital que deben mantener. A continuación, se muestran algunos enfoques comunes utilizados para la evaluación del riesgo de suscripción de seguros distintos de los de vida en Solvencia II:

Fórmula estándar:

- La fórmula estándar es un enfoque prescrito proporcionado por la normativa de Solvencia II para calcular el capital de solvencia obligatorio (SCR) para el riesgo de suscripción de no vida.
- Consta de fórmulas y parámetros predefinidos basados en las líneas de negocio, los volúmenes de primas y el historial de reclamaciones de la aseguradora.
- La fórmula estándar es relativamente sencilla de implementar y proporciona un enfoque



estandarizado para evaluar el riesgo de suscripción de no vida.

Modelos internos:

- Los modelos internos son modelos personalizados desarrollados por las aseguradoras para evaluar su perfil de riesgo de suscripción específico de no vida.
- Estos modelos se adaptan a las operaciones comerciales, las características de riesgo y la disponibilidad de datos de la aseguradora.
- Los modelos internos permiten una evaluación más granular y sofisticada del riesgo de suscripción de no vida en comparación con la fórmula estándar.
- Sin embargo, el desarrollo y aprobación de modelos internos requiere importantes recursos y está sujeto a estrictos requisitos regulatorios y procesos de validación.

Análisis de escenario:

- El análisis de escenarios implica evaluar el impacto de escenarios adversos específicos sobre el riesgo de suscripción de no vida de la aseguradora.
- Las aseguradoras definen una variedad de escenarios de estrés plausibles, como eventos climáticos extremos, recesiones económicas o cambios en la frecuencia o gravedad de las reclamaciones.
- Se evalúa el impacto de estos escenarios en el desempeño técnico, las reservas para siniestros y los requisitos de capital de la aseguradora.
- El análisis de escenarios ayuda a identificar vulnerabilidades potenciales e informa las estrategias de gestión de riesgos.

Modelización estocástica:

- La modelización estocástica implica generar una gran cantidad de escenarios simulados para evaluar la distribución de resultados potenciales para el riesgo de suscripción de no vida.
- Utiliza técnicas estadísticas, como las simulaciones de Monte Carlo, para generar escenarios aleatorios basados en datos históricos y juicios de expertos.
- La modelización estocástica captura la incertidumbre y variabilidad inherentes en la experiencia de siniestros y proporciona una evaluación probabilística de los requisitos de capital de la aseguradora.

Modelización de Reaseguro:

- El reaseguro es una técnica de mitigación de riesgos en la que las aseguradoras transfieren una parte de su riesgo de suscripción de no vida a compañías de reaseguros.
- La modelización de reaseguros implica evaluar el impacto de los acuerdos de reaseguro en el perfil de riesgo de suscripción y los requisitos de capital de la aseguradora.
- Considera factores como los términos de los contratos de reaseguro, los niveles de retención y la solvencia de las contrapartes de reaseguro.
- La modelización de reaseguro ayuda a optimizar la estrategia de reaseguro de la aseguradora y garantiza una transferencia de riesgo y un alivio de capital adecuados.

Análisis de sensibilidad:

- El análisis de sensibilidad implica evaluar el impacto de los cambios en supuestos clave o factores de riesgo sobre el riesgo de suscripción de no vida de la aseguradora.
- Examina cómo las variaciones en supuestos, como la frecuencia de los siniestros, la gravedad o los índices de gastos, afectan los requisitos de capital y la posición de solvencia de la aseguradora.
- El análisis de sensibilidad ayuda a identificar los factores de riesgo más influyentes e informa las decisiones de gestión de riesgos.

Pruebas de estrés inverso:

- Las pruebas de estrés inversas comienzan con un resultado adverso predefinido, como un incumplimiento del SCR o una pérdida significativa, y avanzan hacia atrás para identificar los escenarios que podrían conducir a tal resultado.
- Ayuda a las aseguradoras a comprender los eventos extremos o las combinaciones de factores de riesgo que podrían amenazar su solvencia.
- Las pruebas de estrés inversas informan sobre el establecimiento del apetito por el riesgo, las estrategias de mitigación de riesgos y la planificación de contingencias.

Estos enfoques no son mutuamente excluyentes y las aseguradoras suelen utilizar una combinación de métodos para evaluar su riesgo de suscripción de no vida bajo Solvencia II. La elección del enfoque depende de factores como el tamaño, la complejidad,



el perfil de riesgo y los recursos disponibles de la aseguradora.

8. Computación cuántica para modelar el riesgo de suscripción de no vida



La computación cuántica tiene el potencial de revolucionar la modelización del riesgo de suscripción de seguros distintos de los de vida aprovechando las propiedades únicas de los sistemas cuánticos. Así es como se puede aplicar la computación cuántica para modelar el riesgo de suscripción de seguros distintos de los de vida:

Aprendizaje automático cuántico:

- Se pueden utilizar algoritmos de aprendizaje automático cuántico para desarrollar modelos predictivos del riesgo de suscripción de seguros distintos de los de vida.
- Los algoritmos mejorados cuánticamente, como las máquinas de vectores de soporte cuánticos (QSVM) y las redes neuronales cuánticas (QNN), pueden proporcionar potencialmente una evaluación de riesgos más rápida y precisa en comparación con las técnicas clásicas de aprendizaje automático.
- Los modelos de aprendizaje automático cuántico pueden manejar datos de alta dimensión y capturar patrones y dependencias complejos en los datos de suscripción.

Optimización cuántica para la segmentación de riesgos:

- Los algoritmos de optimización cuántica, como el recocido cuántico o el algoritmo de optimización cuántica aproximada (QAOA), se pueden utilizar para resolver problemas de optimización complejos en la segmentación de riesgos.
- Estos algoritmos pueden explorar de manera eficiente un vasto espacio de posibles segmentos de riesgo e identificar las estrategias de segmentación óptimas en función de las características de las políticas y los perfiles de riesgo.

- La optimización cuántica puede ayudar a las aseguradoras a encontrar la forma más eficaz de agrupar pólizas en segmentos de riesgo homogéneos, permitiendo estrategias de suscripción y fijación de precios específicas.

Simulación cuántica para análisis de escenarios:

- La simulación cuántica se puede utilizar para generar escenarios realistas y evaluar el impacto de diversos factores de riesgo en la cartera de suscripción.
- Las computadoras cuánticas pueden simular eficientemente sistemas complejos y modelar las interacciones entre diferentes variables de riesgo, como las condiciones económicas, el comportamiento de los asegurados y los eventos catastróficos.
- Al ejecutar simulaciones cuánticas, las aseguradoras pueden evaluar los resultados potenciales de diferentes estrategias de suscripción y evaluar la resiliencia de sus carteras ante diversos escenarios de estrés.

Estimación de amplitud cuántica para Modelización de pérdidas:

- La estimación de amplitud cuántica (QAE) se puede utilizar para estimar la probabilidad de diferentes escenarios de pérdidas en la suscripción de no vida.
- QAE permite la estimación eficiente de las probabilidades asociadas con eventos raros o riesgos de cola, que son cruciales para modelar escenarios de pérdidas extremas.
- Al aprovechar QAE, las aseguradoras pueden obtener estimaciones más precisas de pérdidas potenciales y tomar decisiones informadas sobre la retención de riesgos y las estrategias de reaseguro.

Es importante señalar que la aplicación de la computación cuántica al Modelización de riesgos de suscripción de seguros distintos de los de vida aún se encuentra en las primeras etapas de investigación y desarrollo. Si bien la computación cuántica ofrece un potencial prometedor, existen desafíos relacionados con la escalabilidad y confiabilidad del hardware cuántico y el desarrollo de algoritmos cuánticos específicos para casos de uso de seguros.

Las aseguradoras interesadas en explorar la computación cuántica para la modelización de riesgos de suscripción de seguros distintos de los de vida deben colaborar con expertos en computación




cuántica, instituciones de investigación y proveedores de tecnología para mantenerse actualizados sobre los últimos avances y evaluar la viabilidad y los beneficios de las soluciones cuánticas.

A medida que las tecnologías de computación cuántica maduran y se vuelven más accesibles, las aseguradoras que investigan y experimentan de manera proactiva con aplicaciones cuánticas pueden obtener una ventaja competitiva en términos de precisión de la evaluación de riesgos, eficiencia computacional y desempeño general de suscripción.

9. Modelización del riesgo de suscripción de vida en Solvencia II

POPULAR TYPES OF INSURANCE



En el marco de Solvencia II, la modelización del Riesgo de Suscripción de Vida es crucial para evaluar los requisitos de capital y garantizar la solvencia de las compañías de seguros de vida. El riesgo de suscripción de vida surge de las incertidumbres asociadas con los riesgos de mortalidad, longevidad, discapacidad, morbilidad, caducidad y gastos. Estos son los enfoques clave para modelar el riesgo de suscripción de vida en Solvencia II:

Fórmula estándar:

- La fórmula estándar es un enfoque prescrito proporcionado por la normativa de Solvencia II para calcular el Capital de Solvencia Obligatorio (SCR) para el Riesgo de Suscripción de Vida.
- Consta de escenarios de estrés y factores de riesgo predefinidos para cada submódulo de Riesgo de suscripción de vida, como riesgos de mortalidad, longevidad, invalidez, caducidad y gastos.
- La fórmula estándar aplica shocks estandarizados a los supuestos de mejor estimación y calcula el impacto en los pasivos y fondos propios de la aseguradora.

- Si bien la fórmula estándar proporciona un enfoque simplista, es posible que no capture completamente el perfil de riesgo específico de las aseguradoras individuales.

Modelos internos:

- Los modelos internos son modelos personalizados desarrollados por las aseguradoras para evaluar su perfil específico de riesgo de suscripción de vida.
- Estos modelos se adaptan a la oferta de productos de la aseguradora, las características de los asegurados y la disponibilidad de datos.
- Los modelos internos permiten una evaluación más granular y sofisticada del riesgo de suscripción de vida que la fórmula estándar.
- Pueden incorporar supuestos específicos de la empresa, dependencias de riesgos y acciones de gestión.
- El desarrollo y aprobación de modelos internos requiere importantes recursos y está sujeto a estrictos requisitos regulatorios y procesos de validación.

Modelización estocástica:

- La modelización estocástica implica generar una gran cantidad de escenarios simulados para evaluar la distribución de resultados potenciales para el riesgo de suscripción de vida.
- Utiliza técnicas estadísticas, como las simulaciones de Monte Carlo, para generar escenarios aleatorios basados en distribuciones de probabilidad de factores de riesgo clave, como tasas de mortalidad, tasas de caída y tasas de interés.
- La modelización estocástica captura la incertidumbre y variabilidad inherentes a los riesgos de los seguros de vida y proporciona una evaluación probabilística de los requisitos de capital de la aseguradora.
- Permite evaluar riesgos de cola y cuantificar el impacto de eventos extremos en la posición de solvencia de la aseguradora.

Pruebas de estrés y análisis de escenarios:

- Las pruebas de estrés y el análisis de escenarios implican evaluar el impacto de escenarios adversos específicos en el riesgo de suscripción de vida de la aseguradora.



- Las aseguradoras definen una variedad de escenarios de estrés plausibles, como cambios significativos en las tasas de mortalidad, tasas de caída o tasas de interés.
- Se evalúa el impacto de estos escenarios sobre los pasivos, los fondos propios y los requisitos de capital de la aseguradora.
- Las pruebas de estrés y el análisis de escenarios ayudan a identificar vulnerabilidades potenciales e informar las estrategias de gestión de riesgos.

Modelización de riesgos de longevidad:

- El riesgo de longevidad es un componente importante del riesgo de suscripción de vida, particularmente para productos de anualidades y pensiones.
- La modelización del riesgo de longevidad implica evaluar el impacto de los cambios en las mejoras de la mortalidad en los pasivos y requisitos de capital de la aseguradora.
- Requiere el uso de modelos de mortalidad sofisticados, como modelos de mortalidad estocásticos o tablas de mortalidad prospectivas, para proyectar las tasas de mortalidad futuras.
- Los modelos de riesgo de longevidad ayudan a las aseguradoras a cuantificar el impacto financiero de los asegurados que viven más de lo esperado e informan las estrategias de mitigación de riesgos, como los swaps de longevidad o los reaseguros.

Modelización de comportamiento del asegurado:

- El comportamiento de los asegurados, como las tasas de caducidad y las tasas de rescate, pueden afectar significativamente el riesgo de suscripción de vida.
- La modelización del comportamiento de los asegurados implica evaluar el impacto de los cambios en el comportamiento de los asegurados sobre los pasivos y requisitos de capital de la aseguradora.
- Requiere analizar datos históricos de los asegurados, identificar los principales factores de riesgo y desarrollar modelos predictivos.
- La modelización del comportamiento de los asegurados ayuda a las aseguradoras a comprender la sensibilidad de sus responsabilidades a las acciones de los asegurados e informa el diseño de productos y las decisiones de fijación de precios.

Modelización de Reaseguro:

- El reaseguro es una técnica de mitigación de riesgos utilizada por las aseguradoras de vida para transferir una parte de su riesgo de suscripción de vida a las compañías de reaseguros.
- La modelización de reaseguros implica evaluar el impacto de los acuerdos de reaseguro en el perfil de riesgo y los requisitos de capital de la aseguradora.
- Considera factores como los términos de los contratos de reaseguro, los niveles de retención y la solvencia de las contrapartes de reaseguro.
- La modelización de reaseguro ayuda a optimizar la estrategia de reaseguro de la aseguradora y garantiza una transferencia de riesgo y un alivio de capital adecuados.

Estos enfoques no son mutuamente excluyentes y las aseguradoras de vida suelen utilizar una combinación de métodos para evaluar su riesgo de suscripción de vida en Solvencia II. La elección del enfoque depende de factores como el tamaño, la complejidad, la combinación de productos y los recursos disponibles de la aseguradora.

10. Experiencia en Fermac Risk en Machine Learning aplicado en la modelización del riesgo de vida en Solvencia II

HOW TO GET A LIFE INSURANCE POLICY?



Exploremos estudios de casos y ejercicios durante el curso sobre aprendizaje automático para modelar el riesgo de suscripción de vida en Solvencia II.

Ejercicio de Modelización Predictivo:

Supongamos que una aseguradora quiere predecir el riesgo de mortalidad de sus asegurados. Recopila datos históricos sobre las características de los asegurados (por ejemplo, edad, sexo, estado de salud) y resultados de mortalidad. Utilizando un algoritmo de máquina de aumento de gradiente (GBM), entrena un modelo predictivo que aprende la relación entre estas variables y el riesgo de



mortalidad. Luego, el modelo entrenado se puede utilizar para estimar el riesgo de mortalidad de los nuevos asegurados en función de sus características individuales.

Ejercicio de modelización de la mortalidad:

Una aseguradora pretende mejorar sus proyecciones de mortalidad para productos de anualidades. Reúne un gran conjunto de datos sobre tasas de mortalidad históricas y factores demográficos y socioeconómicos. Utilizando un modelo de aprendizaje profundo, como una red neuronal recurrente (RNN), captura los patrones complejos y las dependencias en los datos de mortalidad. El modelo aprende a predecir tasas de mortalidad futuras basándose en datos históricos y puede utilizarse para evaluar el riesgo de longevidad y establecer reservas adecuadas.

Ejercicio de Modelización de lapsos y rendición:

Una aseguradora quiere comprender los factores que impulsan el comportamiento de abandono y abandono de los asegurados. Recopilan datos sobre las características del asegurado, las características de la póliza y los eventos de caducidad/rescisión. Utilizando un algoritmo de bosque aleatorio, construyen un modelo que identifica las variables más importantes que influyen en las tasas de caducidad y entrega. El modelo puede predecir la probabilidad de caducidad o rescate de pólizas individuales, ayudando a la aseguradora a optimizar los precios y gestionar el riesgo de liquidez.

Ejercicio de Detección de Anomalías:

Una aseguradora quiere detectar posibles fraudes en reclamaciones de seguros de vida. Aplican una técnica de aprendizaje no supervisada, como el bosque de aislamiento, para identificar patrones de reclamaciones anómalos. El algoritmo aprende el comportamiento normal de los reclamos y señala cualquier reclamo que se desvíe significativamente de la norma. Las reclamaciones marcadas pueden luego investigarse más a fondo en busca de actividades potencialmente fraudulentas.

Caso de Estudio de procesamiento del lenguaje natural (PNL):

Una compañía de seguros recibe un gran volumen de informes médicos y notas de suscripción en formato textual. Utilizan técnicas de PNL como el reconocimiento de entidades nombradas (NER) y el análisis de sentimientos para extraer información relevante de manera eficiente. NER puede identificar y extraer términos médicos, diagnósticos y tratamientos clave de los informes, mientras que el análisis de opiniones puede evaluar el tono general y la opinión de las notas. Esta extracción automatizada de información ayuda a los suscriptores a tomar decisiones más informadas y acelera el proceso de suscripción.

Ejercicio de Modelización y Simulación Estocástica:

Una aseguradora quiere evaluar el impacto de diferentes escenarios económicos en su cartera de seguros de vida. Para ello, utiliza una red generativa adversaria (GAN) para generar escenarios económicos realistas, como trayectorias de tipos de interés y rentabilidades del mercado de valores. Estos escenarios generados luego se utilizan como entradas para un modelo de simulación estocástica que proyecta los activos, pasivos y requisitos de capital de la aseguradora bajo cada escenario. Esto permite a la aseguradora evaluar la resiliencia de su cartera y tomar decisiones informadas de gestión de riesgos.

Ejercicio de Validación e Interpretación de Modelos:

Una aseguradora ha desarrollado un modelo de aprendizaje automático para predecir el riesgo de caducidad de sus pólizas. Utilizan técnicas de validación cruzada y backtesting para validar el rendimiento del modelo. Comparan las predicciones del modelo con eventos de lapso reales para evaluar su precisión y confiabilidad. Además, aplican métodos de interpretación de modelos, como SHAP (explicaciones aditivas de Shapley), para comprender las características clave que impulsan las predicciones del modelo. Esto ayuda a garantizar la transparencia y la explicabilidad en el proceso de toma de decisiones del modelo.

Estos ejercicios y estudios de casos ilustran cómo se pueden aplicar los enfoques de aprendizaje automático a diversos aspectos de la modelización del riesgo de suscripción de vida en Solvencia II. Los algoritmos de aprendizaje automático pueden



descubrir patrones, hacer predicciones y respaldar la toma de decisiones basada en datos aprovechando los datos históricos. Sin embargo, es crucial enfatizar que los modelos de aprendizaje automático deben usarse con experiencia actuarial y someterse a una validación e interpretación rigurosas para garantizar su confiabilidad y cumplimiento de los requisitos regulatorios.