



centro adscrito a:



UNIVERSITAT POLITÈCNICA
DE CATALUNYA
BARCELONATECH

GUÍA DOCENTE DE ANÁLISIS DE DATOS, INTELIGENCIA ARTIFICIAL Y APRENDIZAJE AUTOMÁTICO EN FINANZAS 2025- 2026

DATOS GENERALES

Nombre:	Análisis de datos, inteligencia artificial y aprendizaje automático en finanzas
Código:	
Curso:	2025-26
Titulación:	Master Universitario en Innovación Financiera y Fintech
N.º de créditos (ECTS):	5
Ubicación en el plan de estudios:	1er curso 2ª cuatrimestre
Departamento:	
Responsable departamento:	
Fecha de la última revisión:	Abril 2025
Profesorado:	Gerard Albà (Matemático, CIO MoraBanc), Eric Risco (Informático, AndorraTelecom), Paul Ganthail (MSc Finance, Analista financiero Creand, Superprof)

1. DESCRIPCIÓN GENERAL

La ciencia de datos está en el núcleo de cualquier negocio moderno en crecimiento. La información de negocio que se obtiene a partir del uso y análisis de los datos permite mejorar la eficacia, la calidad y la eficiencia de la actividad empresarial. Su importancia es cada vez más estratégica para cualquier modelo de negocio.

Asimismo, la industria y muchos sectores se están transformando, convirtiendo los datos en conocimiento productivo. Dos grandes fuerzas impulsan esta evolución. Por un lado, el acceso programático a fuentes variadas y masivas de datos (*Big Data*), con velocidades de procesamiento cada vez mayores. Y, por otro lado, la segunda gran fuerza, que seguirá siendo dominante en los próximos años: el desarrollo de algoritmos de aprendizaje automático (*machine learning*) y la creciente importancia de la inteligencia artificial generativa (*GenAI*).

Este nuevo proceso basado en datos nos permite construir sistemas que aprenden automáticamente con la experiencia. Y pueden aplicarse a muchos tipos de problemas específicos del sector, como veremos durante el curso, modelando relaciones complejas o tareas de clasificación, donde los modelos tradicionales no son adecuados.

Exploraremos en las sesiones, casos de uso en profundidad (también veremos su correspondiente implementación en código), incluyendo las principales categorías de herramientas que abarca la ciencia de datos: aprendizaje automático supervisado, no supervisado, aprendizaje por refuerzo, deep learning y procesamiento del lenguaje natural (NLP), modelos de lenguaje grandes (LLMs) e inteligencia artificial generativa, y computación acelerada (HPC).

2. OBJETIVOS

- Comprender los fundamentos de la ciencia de datos aplicada a las finanzas y su impacto en la toma de decisiones en banca, seguros y mercados.
- Conocer las etapas clave de un proyecto de analítica financiera, desde la comprensión del negocio y los objetivos hasta el tratamiento, análisis y visualización de datos financieros.
- Dominar la aplicación práctica de las herramientas y tecnologías de datos más utilizadas en el sector financiero, como Python, R y sus principales librerías para análisis numérico, visualización y machine learning (Pandas, NumPy, Scikit-learn, TensorFlow, etc.).
- Aplicar técnicas de aprendizaje automático supervisado y no supervisado (regresión, clasificación, clusterización, asociación) a problemas reales del entorno financiero.
- Explorar métodos avanzados como el aprendizaje por refuerzo (Reinforcement Learning), con algoritmos como Q-Learning, SARSA y Deep Q-Learning aplicados a decisiones financieras.
- Introducirse en el uso de la inteligencia artificial generativa y los modelos de lenguaje grandes (LLMs), incluyendo conceptos como arquitectura de transformadores, embeddings, agentes y RAG, con sus aplicaciones en finanzas.
- Integrar ciencia de datos en áreas clave de las finanzas:
 - Valoración de activos y derivados.
 - Gestión de carteras multiactivo.
 - Personalización de servicios financieros.
 - Evaluación de riesgo crediticio y actuarial.
 - Trading algorítmico.
 - Análisis económico con nowcasting.
 - Análisis de criptoactivos y blockchain.
- Aplicar el conocimiento a casos prácticos reales, desarrollando habilidades analíticas y técnicas en escenarios simulados o reales de la industria.

3. RESULTADOS DE APRENDIZAJE

Al finalizar la asignatura, el estudiante será capaz de:

K1.2: Describir las principales tendencias tecnológicas que están redefiniendo el sector financiero.

K6.1: Identificar los diferentes tipos de criptoactivos, el proceso de minería, las plataformas y los riesgos y los beneficios asociados.

K6.2: Identificar el proceso de tokenización, los diferentes tipos y plataformas y casos principales de uso.

K9.1: Identificar los diferentes elementos del modelo de negocio y definir las ventajas competitivas de naturaleza tecnológica que lo hace diferencial y sostenible.

S1.1: Comunicarse eficazmente de forma oral, escrita y gráfica con otras personas sobre el aprendizaje, la elaboración del pensamiento y la toma de decisiones, y participar en debates, haciendo uso de las habilidades interpersonales, como la escucha activa y la empatía, que favorecen el trabajo en equipo.

S2.1: Desarrollar la capacidad de contribuir a la innovación en instituciones y organizaciones empresariales nuevas o existentes, mediante la participación en proyectos creativos y tener capacidad para aplicar competencias y conocimientos sobre expendeduría, organización y desarrollo empresarial de base tecnológica.

S3.1: Comprender las tecnologías digitales avanzadas, de manera que se puedan aplicar con perspectiva crítica, en contextos diversos, en situaciones académicas, profesionales, sociales o personales.

S4.1: Diferenciar los diferentes tipos de tecnología que se están aplicando al sector financiero basados en la desintermediación.

S9.1. Diferenciar los diferentes tipos de criptoactivos y activos digitales.

S9.2: Diferenciar los casos de uso de los tokens, la plataforma Ethereum y las aplicaciones descentralizadas.

C1.1: Integrar los valores de la sostenibilidad, entendiendo la complejidad de los sistemas, con el fin de emprender o promover acciones que reestablezcan y mantengan la salud de los ecosistemas y mejoren la justicia, generando diversas visiones para futuros sostenibles.

C2.1: Identificar y analizar problemas que requieren adoptar decisiones autónomas, informadas y argumentadas, para actuar con responsabilidad social, según valores y principios éticos.

C3.1: Desarrollar la capacidad de evaluar las desigualdades por razón de sexo y género y para diseñar soluciones.

C4.1: Aplicar las tecnologías de descentralización financiera en aplicaciones o modelos de negocio que posibiliten la reducción de costos y la mejora de la rentabilidad, considerando el marco ético y legal vigente.

C9.1: Aplicar las nuevas tecnologías y aplicación de digitalización bancaria a nuevos proyectos de desarrollo.

C9.2: Aplicar los casos de éxito en tecnología y desintermediación financiera para las nuevas expendedurías empresariales.

Podemos poner de relieve:

- Interpretar y aplicar conceptos clave de ciencia de datos en el contexto financiero.
- Diseñar y desarrollar proyectos de analítica de datos financieros, desde la preparación de datos hasta la visualización de resultados.
- Utilizar herramientas y lenguajes de programación (como Python o R) para análisis de datos y modelado predictivo en problemas de Finanzas.
- Aplicar técnicas de aprendizaje automático supervisado y no supervisado a problemas financieros reales.
- Implementar modelos de aprendizaje por refuerzo en escenarios financieros.
- Comprender y aplicar modelos de IA generativa y modelos de lenguaje (LLMs) para tareas como análisis textual, predicción y automatización en finanzas.
- Analizar y resolver casos reales en ámbitos como valoración de activos, gestión de carteras, análisis de riesgo, trading algorítmico, y análisis de blockchain y criptoactivos.
- Evaluar críticamente el impacto de las tecnologías de IA y big data en el sector financiero, con un enfoque ético y estratégico.

4. CONTENIDOS

TEMA 1: INTRODUCCIÓN A LA CIENCIA DE DATOS APLICADA A LAS FINANZAS

Resultados específicos de aprendizaje:

- Comprender los principios fundamentales de la ciencia de datos aplicada a las finanzas, incluyendo su potencial estratégico y transformador.
- Reconocer casos de uso representativos donde la ciencia de datos aporta valor en banca, seguros, inversiones y otros sectores financieros.

Contenidos:

- 1.1. Cambio de modelo: de las finanzas basadas en teoría, a finanzas basadas en datos.
- 1.2. Aplicación de la IA a las distintas áreas del sector financiero.

TEMA 2: ELEMENTOS Y ETAPAS DE UN PROYECTO DE DATA SCIENCE EN FINANZAS

Resultados específicos de aprendizaje:

- Comprender el contexto financiero del proyecto. Traducir necesidades del negocio en objetivos analíticos.
- Preparar y adaptar los datos para su uso en análisis exploratorios (EDA) y modelos de machine learning.
- Aplicar técnicas estadísticas y visuales para explorar conjuntos de datos. Identificar patrones, correlaciones, valores atípicos y relaciones entre variables. Utilizar el EDA como paso previo para la selección de algoritmos adecuados.
- Conocer diferentes estructuras de datos utilizadas en finanzas y ciencia de datos: tablas, grafos, árboles, etc.
- Evaluar el rendimiento de modelos y ajustar parámetros según el objetivo del negocio.
- Conocer y aplicar algoritmos de aprendizaje automático Supervisado.
- Conocer y aplicar algoritmos de aprendizaje automático No-supervisado.
- Conocer y aplicar algoritmos de aprendizaje Reforzado.
- Comprender el funcionamiento de los modelos **de Inteligencia Artificial Generativa (GenAI): Large Language Models (LLMs)** y su aplicación en finanzas.
- Conocer los lenguajes de programación y librerías más utilizados en ciencia de datos para finanzas: Python y R.

Contenidos:

2.1 Introducción.

2.2 Elementos y etapas de la analítica financiera. Herramientas, infraestructura tecnológica y lenguajes de programación más utilizados en la industria financiera.

2.2.1 Entender el Negocio y los objetivos del proyecto. Ejemplos en Finanzas.

2.2.2 Datos.

2.2.2.1 Los datos financieros: fuentes, limpieza, pre-procesamiento visualización. Arquitectura de datos.

2.2.2.2 Estructuras de Datos.

2.2.2.3 Tratamiento de Datos.

2.2.2.4 Análisis exploratorio de datos (*Exploratory Data Analysis: EDA*).

2.2.3 Algoritmos.

2.2.3.1 Modelos predictivos.

2.2.3.2 Aprendizaje automático (*Machine Learning*): Supervisado, No-Supervisado, Reforzado (*Reinforcement Learning*).

2.2.3.3 Aprendizaje Supervisado: Regresión y Clasificación. Regresión lineal y logística; Naïve Bayes; Máquinas de vectores soporte (SVM); Árboles de decisión; Bosques aleatorios; k-NN; Potenciación del gradiente (*Gradient boosting*); Redes neuronales.

2.2.3.4 Aprendizaje No-supervisado. Clusterización: K-Means, jerárquica, modelos gaussianos; Asociación: algoritmo Apriori para descubrir relaciones entre variables; Reducción de dimensionalidad: Análisis de Componentes Principales (PCA).

2.2.3.5 *Reinforcement Learning*.

2.2.3.5.1 Q-Learning.

2.2.3.5.2 SARSA-Learning.

2.2.3.5.3 Deep Q-Learning.

2.2.4 IA Generativa y los modelos de lenguaje: *Large Language Models* (LLMs).

2.2.4.1 Arquitectura de Transformador.

2.2.4.2 Tokens y *Embeddings*.

2.2.4.3 Agentes.

2.2.4.4 Retrieval-Augmented Generation (RAG).

2.2.4 Los lenguajes de Programación: Python y R. Utilizar librerías clave para análisis y modelado:

- Pandas: manipulación de datos.
- NumPy y SciPy: cálculos científicos y numéricos.
- Matplotlib: generación de gráficos y visualizaciones.
- Scikit-learn: modelos de machine learning tradicionales.
- TensorFlow y Keras: desarrollo de redes neuronales.
- PyTorch: modelado avanzado en *deep learning*.

TEMA 3: CÓMO SE UTILIZA LA CIENCIA DE DATOS EN FINANZAS

Resultados específicos de aprendizaje:

- Comprender el papel de la ciencia de datos en el análisis de mercados y en la toma de decisiones cuantitativas.
- Modelar series temporales financieras para identificar tendencias y estacionalidades.

- Los modelos de aprendizaje automático e IA aplicados a los Derivados financieros. Valorar opciones, futuros y swaps mediante modelos de valoración numéricos y analíticos. Evaluar y gestionar el riesgo asociado a derivados utilizando medidas.
- Diseñar y optimizar carteras diversificadas de activos financieros siguiendo criterios de media-varianza y otros enfoques modernos.
- Extraer datos de fuentes no estructuradas (noticias, redes sociales, informes).
- Aplicar técnicas de NLP para medir sentimiento y variables cualitativas que mejoren modelos predictivos.
- Aplicación de los modelos de aprendizaje automático a Riesgos financieros. Desarrollar modelos de predicción de morosidad, fraude y riesgos operativos. Implementar algoritmos de detección de anomalías para monitorizar eventos críticos. Estimar métricas de riesgo (crédito, mercado, liquidez) y validar su robustez.
- Segmentar clientes mediante algoritmos de clustering y scoring. Diseñar sistemas de recomendación y estrategias de marketing personalizado.
- Prever comportamientos y necesidades de los clientes a través de modelos predictivos.

Contenidos:

3.1 Mercados Financieros y Finanzas Cuantitativas.

3.1.1 Los precios de los activos financieros.

- Aplicar técnicas de análisis de datos para modelar y prever el comportamiento de los precios de activos.
- Utilizar series temporales, modelos estocásticos y simulaciones para estudiar movimientos del mercado.

3.1.2 Valoración y gestión de instrumentos derivados.

- Emplear herramientas cuantitativas basadas en aprendizaje automática para valorar derivados como opciones, futuros y swaps.
- Evaluar el riesgo asociado a estos productos mediante modelos matemáticos y computacionales basados en ciencia de datos.

3.1.3 Carteras multiactivo y aprendizaje automático aplicado.

- Optimizar carteras diversificadas utilizando modelos de optimización.
- Analizar la correlación entre activos y ajustar la asignación de activos basada en datos.

3.1.4 Sentimiento e información no-estructurada.

- Extraer valor a partir de datos no estructurados (noticias, redes sociales, informes).

- Aplicar procesamiento de lenguaje natural (NLP) para medir el sentimiento del mercado.
- Integrar esta información en modelos predictivos y de gestión de riesgo.

3.2 Control y Gestión de Riesgos en Banca y Seguros.

- Aplicar modelos de predicción de morosidad, fraude y riesgos operativos.
- Utilizar algoritmos de clasificación y detección de anomalías para prevenir pérdidas en suscripción y originación de riesgo.
- Estimar el riesgo crediticio, de mercado y de liquidez con herramientas avanzadas de análisis de datos.

3.3 Personalización y Analítica de Clientes.

- Utilizar técnicas de segmentación de clientes (*clustering*) para personalizar servicios financieros.
- Analizar el comportamiento del cliente para mejorar productos, márketing y retención.
- Predecir necesidades y comportamientos mediante aprendizaje automático y analítica avanzada.

TEMA 4: CASOS PRÁCTICOS

Resultados específicos de aprendizaje:

- Aplicar métodos de segmentación de clientes y algoritmos de recomendación para crear soluciones de inversión personalizadas.
- Desarrollar modelos predictivos de riesgo crediticio para estimar impagos y gestionar la exposición crediticia.
- Aplicar métodos actuariales y técnicas de aprendizaje automático para gestionar el riesgo y determinar precios en productos de seguros.
- Utilizar modelos de *nowcasting* para prever indicadores económicos con datos en tiempo real.
- Diseñar y optimizar algoritmos de trading automatizado para ejecutar operaciones en mercados financieros.
- Utilizar técnicas de ciencia de datos para analizar blockchain y criptoactivos, mejorar la toma de decisiones y prever el comportamiento del mercado.

Contenidos:

- 4.1 Asesoramiento Financiero Personalizado.
- 4.2 Gestión de Riesgos Financieros: el Crédito.
- 4.3 Gestión de Riesgos Actuariales en Seguros.
- 4.4 Economía y Nowcasting.
- 4.5 Trading Algorítmico.
- 4.6 Ciencia de Datos para Blockchains y Criptoactivos.

5. METODOLOGÍA DE ENSEÑANZA Y APRENDIZAJE

La enseñanza se lleva a cabo mediante una serie de sesiones presenciales, cuyo espíritu es el de combinar equilibradamente la teoría y la práctica, complementadas con una serie de materiales didácticos (manual y presentación), ejercicios y casos para su resolución, facilitados vía online y con *feedback*, asimismo online, utilizando de soporte digital la plataforma propia del programa.

Las actividades presenciales se realizarán mediante:

- Exposición por parte del profesor de la aplicación práctica de los contenidos teóricos de los distintos temas de la asignatura. Es imprescindible la lectura previa (por parte del estudiante) del manual de referencia de cada tema que está disponible en el aula virtual.
- Debate de los contenidos.
- Aplicación de los conceptos y metodologías a ejemplos/casos prácticos

El aprendizaje se consolidará mediante la resolución de los ejercicios y/o casos que se facilitarán en el campus virtual de la asignatura.

6. EVALUACIÓN

De acuerdo con el Plan Bolonia, el modelo premia el esfuerzo constante y continuado del estudiantado. Un 60% de la nota se obtiene de la evaluación continua de las actividades dirigidas y el 40% porcentaje restante, del examen final presencial. El examen final tiene dos convocatorias.

La nota final de la asignatura (NF) se calculará a partir de la siguiente fórmula:

- **NF = Nota Examen Final x 40% + Nota Evaluación Continuada x 60%**
- Nota mínima del examen final para calcular la NF será de 40 puntos sobre 100.
- La asignatura queda aprobada con una NF igual o superior a 50 puntos sobre 100.

Tipo de actividad	Descripción	% Evaluación continua	
Cuestionarios:			60%
Cuestionario 1	Test Tema 1	20%	
Cuestionario 2	Test Tema 2	20%	
Cuestionario 3	Test Tema 3	20%	
Examen final			40%
	Examen final	100%	

7. BIBLIOGRAFÍA

7.1. BIBLIOGRAFÍA BÁSICA

Albà et al, G. (2023). *La tecnología cuantitativa de los roboadvisors*. IEF-Instituto de Estudios Financieros.

AQR. (2024). *Machine Learning: Why Finance Is Different*. Obtenido de <https://www.aqr.com/Learning-Center/Machine-Learning/Machine-Learning-Why-Finance-Is-Different>

BlackRockEngineering. (2022). *I feel the need, the need for speed*. Obtenido de <https://engineering.blackrock.com/i-feel-the-need-the-need-for-speed-92afe9e64452>

Damon, L. (2020). *Build Your Own AI Investor*.

Dixon et al, M. (2020). *Machine Learning in Finance From Theory to Practice*. Springer.

Giles, M. (2024). *Oxford Mathematical Institute*. Obtenido de <https://people.maths.ox.ac.uk/~gilesm/>

Hilpisch, Y. (2020). *Artificial Intelligence in Finance*. O'Reilly.

HSLU. (2023). *GPT for Financial Advice*. Institute of Financial Services Zug IFZ.

- Hull, I. (2021). *Machine Learning for Economics and Finance in TensorFlow 2 Deep Learning Models for Research and Industry*. Apress.
- Isaiah, H. (2021). Decision Trees. En H. Isaiah, *Machine Learning for Economics and Finance in TensorFlow 2*. Apress.
- Jansen, S. (2020). *Machine Learning for Algorithmic Trading*. Packt.
- JPMorgan. (2017). (*JPMorgan, Cross Asset Portfolios of Tradable Risk Premia Indices Hierarchical Risk Parity: Enhancing Returns at Target Volatility, 2017*). Global Quantitative & Derivatives Strategy.
- Kaabar, S. (2024). *Deep Learning for Finance*. O'Reilly.
- Karasan, A. (2022). *Machine Learning for Financial Risk Management with Python*. O'Reilly.
- Mazars. (2019). *Deep hedging Application of deep learning to hedge financial derivatives*.
- NVIDIA. (2007). *Computational Finance in GPUs*. Obtenido de https://developer.download.nvidia.com/compute/cuda/1.1-Beta/x86_website/Computational_Finance.html
- Tatsat et al, H. (2020). Blueprint for Building a Trading Strategy Based on Sentiment Analysis. En H. Tatsat et al, *Machine Learning and Data Science Blueprints for Finance*.
- Tatsat et al, H. (2020). Blueprint for Creating a Machine Learning Model for Predicting Loan Default Probability. En H. Tatsat et al, *Machine Learning and Data Science Blueprints for Finance*. O'Reilly.
- Tatsat et al, H. (2020). Blueprint for Using Classification Models to Determine Whether a Transaction Is Fraudulent. En H. Tatsat et al, *Machine Learning and Data Science Blueprints for Finance*. O'Reilly.
- Tatsat et al, H. (2020). Blueprint for Using Clustering to Implement Hierarchical Risk Parity. En *Machine Learning and Data Science Blueprints for Finance*. O'Reilly.
- Tatsat et al, H. (2020). Case Study 2: Chatbot Digital Assistant. En H. Tatsat et al, *Machine Learning and Data Science Blueprints for Finance*.
- Tatsat et al, H. (2020). *Machine Learning and Data Science Blueprints for Finance*. O'Reilly.
- Tatsat et al, H. (s.f.). Blueprint for Using Clustering for Grouping Investors. En H. Tatsat et al, *Machine Learning and Data Science Blueprints for Finance*. O'Reilly.

7.2 BIBLIOGRAFÍA COMPLEMENTARIA

- Alexander, C. (2008). *Market Risk Analysis, Quantitative Methods in Finance*. Wiley.
- Alonso, A. (. (2021). *Understanding the performance of machine learning models to predict credit default: a novel approach for supervisory evaluation*. Banco de España.
- Atlanta, F. R. (s.f.). *GDPNow*. Obtenido de <https://www.atlantafed.org/cqer/research/gdpnow>
- Brownlee, J. (2018). *Deep Learning for Time Series Forecasting Predict the Future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery.
- Castillo, G. (2023). *Data Science for Web3: A comprehensive guide to decoding blockchain data with data analysis basics and machine learning cases*. Packt.
- Cesa et al, M. (2022). JP Morgan testing deep hedging of exotics. *Risk magazine*.
- ChenDataBytes. (2024). *Fraud Detection and Anomaly Detection Start from supervised learning to unsupervised learning*. Obtenido de <https://medium.com/@chenycy/fraud-detection-and-anomaly-detection-e65dd11a3146>
- Citi. (2023). *Unleashing AI*. Citi GPS: Global Perspectives & Solutions.
- DeepMind, G. (2015). *From Pixels to Actions: Human-level control thorough Deep Reinforcement Learning*. Obtenido de <https://research.google/blog/from-pixels-to-actions-human-level-control-through-deep-reinforcement-learning/>
- Denuit et al, M. (2007). *Actuarial Modelling of Claim Counts: Risk Classification, Credibility and Bonus-Malus Systems*. Wiley.
- Domashova et al, J. (2021). Usage of machine learning methods for early detection of money laundering schemes. *Procedia Computer Science*, 184-192.
- Fama et al, E. (1992). The Cross-Section of Expected Stock Returns. *The Journal of Finance*.
- Giannone et al, D. (2008). Nowcasting: The real-time informational content of macroeconomic data. *Journal of Monetary Economics*, 665-676.
- HUANG, A. (2021). *Stock recommendation via machine learning algorithms*. Obtenido de <https://github.com/WideSu/Stock-recommandation-via-machine-learning-algorithm>.

- JPMorgan. (2017). *(JPMorgan, Cross Asset Portfolios of Tradable Risk Premia Indices Hierarchical Risk Parity: Enhancing Returns at Target Volatility, 2017)*. Global Quantitative & Derivatives Strategy.
- Kaggle. (2019). *Anomaly Detection with Unsupervised Learning*. Obtenido de Anomaly Detection with Unsupervised Learning:
<https://www.kaggle.com/code/jiedong00/anomaly-detection-with-unsupervised-learning>
- Kaggle. (2021). *Credit Card Fraud Detection*. Obtenido de
<https://www.kaggle.com/datasets/mlg-ulb/creditcardfraud>
- Kaggle. (s.f.). *Kaggle*. Obtenido de Kaggle.com
- Karasan, A. (2022). *Machine Learning for Financial Risk Management with Python*. O'Reilly.
- Krikorian, M. (2021). *Fraud Detection applying Unsupervised Learning techniques*. Obtenido de <https://medium.com/southworks/fraud-detection-applying-unsupervised-learning-techniques-4ae6f71b266f>
- Le Borgne et al, Y. (2022). *Reproducible machine learning for credit fraud detection - practical handbook*. Obtenido de <https://fraud-detection-handbook.github.io/fraud-detection-handbook/Foreword.html#authors>
- Mass, C. (2011). Nowcasting: The Next Revolution in Weather Prediction. *Bulletin of the American Meteorological Society*.
- Mazars. (2019). *Deep hedging Application of deep learning to hedge financial derivatives*.
- Mazars. (s.f.). *Deep hedging Application of deep learning to hedge financial derivatives*.
- Microsoft. (2024). *wiss Re Launches Swiss Re Life Guide Scout, a Generative AI-Powered Underwriting Assistant*. Obtenido de <https://news.microsoft.com/de-ch/2024/04/22/swiss-re-launches-swiss-re-life-guide-scout-a-generative-ai-powered-underwriting-assistant/>
- OpenBB. (2023). *Creating an AI powered financial analyst*. Obtenido de OpenBB:
<https://openbb.co/blog/creating-an-ai-powered-financial-analyst>
- Oxford, U. o. (2018). *Deep learning approach to hedging*. University of Oxford .
- Rachev et al, S. (2006). *Financial Econometrics: From Basics to Advanced Modeling Techniques*. Wiley.

- Reacfin. (2017). *Machine learning applications to non-life pricing*.
- Reese et al, R. (2017). Fraud detection of insurance claims. En R. Reese et al, *Machine Learning: End-to-End guide for Java developers*. Packt.
- Santander, B. (2016). *Santander Product Recommendation Can you pair products with people?* Obtenido de <https://www.kaggle.com/competitions/santander-product-recommendation/overview/description>
- Tegmark, M. (2017). *Life 3.0*. Penguin Books.
- Tibshirani, R. (2002). Estimating the Number of Clusters in a Data Set Via the Gap Statistic. *Statistical Methodology* , 411-423.
- York, F. R. (2017). Macroeconomic Nowcasting and Forecasting with Big Data.
- Zeng et al, Q. (2023). *Sentiment Analysis in Finance*. Obtenido de <https://github.com/Apricot0/Sentiment-Analysis-in-Finance>
- Zuckerman, G. (2019). *The Man Who Solved the Market*. Penguin.