



centro adscrito a:



UNIVERSITAT POLITÈCNICA
DE CATALUNYA
BARCELONATECH

GUIA DOCENT D' ANÀLISI DE DADES, INTEL·LIGÈNCIA ARTIFICIAL I APRENTATGE AUTOMÀTIC EN FINANCES 2025- 2026

DADES GENERALS

Nom:	Anàlisi de dades, intel·ligència artificial i aprenentatge automàtic en finances
Codi:	
Curs:	2025-26
Titulació:	Màster Universitari en Innovació Financera i Fintech
Nº de crèdits (ECTS):	5
Ubicació en el pla d' estudis:	1r curs 2a quadrimestre
Departament:	
Responsable departament:	
Data de l' última revisió:	Abril 2025
Professorat:	Gerard Albà (Matemàtic, CIO MoraBanc), Eric Risco (Informàtic, AndorraTelecom), Paul Gantheil (MSc Finance, Analista financer Creand, Superprof)

1. DESCRIPCIÓ GENERAL

La ciència de dades està en el nucli de qualsevol negoci modern en creixement. La informació de negoci que s' obté a partir de l' ús i anàlisi de les dades permet millorar l' eficàcia, la qualitat i l' eficiència de l' activitat empresarial. La seva importància és cada vegada més estratègica per a qualsevol model de negoci.

Així mateix, la indústria i molts sectors s'estan transformant, convertint les dades en coneixement productiu. Dues grans forces impulsen aquesta evolució. D'una banda, l'accés programàtic a fonts variades i massives de dades (*Big Data*), amb velocitats de processament cada vegada més grans. I, d'altra banda, la segona gran força, que continuarà sent dominant en els pròxims anys: el desenvolupament d'algoritmes d'aprenentatge automàtic (*machine learning*) i la creixent importància de la intel·ligència artificial generativa (*GenAI*).

Aquest nou procés basat en dades ens permet construir sistemes que aprenen automàticament amb l' experiència. I es poden aplicar a molts tipus de problemes específics del sector, com veurem durant el curs, modelant relacions complexes o tasques de classificació, on els models tradicionals no són adequats.

Explorarem en les sessions, casos d'ús en profunditat (també veurem la seva corresponent implementació en codi), incloent-hi les principals categories d'eines que abasta la ciència de dades: aprenentatge automàtic supervisat, no supervisat, aprenentatge per reforç, deep learning i processament del llenguatge natural (NLP), models de llenguatge grans (LLMs) i intel·ligència artificial generativa, i computació accelerada (HPC).

2. OBJECTIUS

- Comprendre els fonaments de la ciència de dades aplicada a les finances i el seu impacte en la presa de decisions en banca, assegurances i mercats.
- Conèixer les etapes clau d' un projecte d' anàlisi financera, des de la comprensió del negoci i els objectius fins al tractament, anàlisi i visualització de dades financeres.
- Dominar l'aplicació pràctica de les eines i tecnologies de dades més utilitzades en el sector financer, com Python, R i les seves principals llibreries per a anàlisi numèrica, visualització i machine learning (Pandas, NumPy, Scikit-learn, TensorFlow, etc.).
- Aplicar tècniques d'aprenentatge automàtic supervisat i no supervisat (regressió, classificació, clusterització, associació) a problemes reals de l'entorn financer.
- Explorar mètodes avançats com l'aprenentatge per reforç (Reinforcement Learning), amb algoritmes com Q-Learning, SARSA i Deep Q-Learning aplicats a decisions financeres.
- Introduir-se en l'ús de la intel·ligència artificial generativa i els models de llenguatge grans (LLMs), incloent conceptes com arquitectura de transformadors, embeddings, agents i RAG, amb les seves aplicacions en finances.
- Integrar ciència de dades en àrees clau de les finances:
 - Valoració d' actius i derivats.
 - Gestió de carteres multiactiu.
 - Personalització de serveis financers.
 - Avaluació de risc creditici i actuarial.
 - Trading algorítmic.
 - Anàlisi econòmica amb nowcasting.
 - Anàlisi de cryptoactius i blockchain.
- Aplicar el coneixement a casos pràctics reals, desenvolupant habilitats analítiques i tècniques en escenaris simulats o reals de la indústria.

3. RESULTATS D' APRENENTATGE

En finalitzar l' assignatura, l' estudiant serà capaç de:

K1.2: Descriure les principals tendències tecnològiques que estan redefinint el sector financer.

K6.1: Identificar els diferents tipus de cryptoactius, el procés de mineria, les plataformes i els riscos i els beneficis associats.

K6.2: Identificar el procés de tokenització, els diferents tipus i plataformes i casos principals d'ús.

K9.1: Identificar els diferents elements del model de negoci i definir els avantatges competitiu de naturalesa tecnològica que el fa diferencial i sostenible.

S1.1: Comunicar-se eficaçment de forma oral, escrita i gràfica amb altres persones sobre l'aprenentatge, l'elaboració del pensament i la presa de decisions, i participar en debats, fent ús de les habilitats interpersonals, com l'escolta activa i l'empatia, que afavoreixen el treball en equip.

S2.1: Desenvolupar la capacitat de contribuir a la innovació en institucions i organitzacions empresarials noves o existents, mitjançant la participació en projectes creatius i tenir capacitat per aplicar competències i coneixements sobre expedientia, organització i desenvolupament empresarial de base tecnològica.

S3.1: Comprendre les tecnologies digitals avançades, de manera que es puguin aplicar amb perspectiva crítica, en contextos diversos, en situacions acadèmiques, professionals, socials o personals.

S4.1: Diferenciar els diferents tipus de tecnologia que s'estan aplicant al sector financer basats en la desintermediació.

S9.1. Diferenciar els diferents tipus de cryptoactius i actius digitals.

S9.2: Diferenciar els casos d'ús dels tokens, la plataforma Ethereum i les aplicacions descentralitzades.

C1.1: Integrar els valors de la sostenibilitat, entenent la complexitat dels sistemes, per tal d'emprendre o promoure accions que restablissin i mantinguin la salut dels ecosistemes i millorin la justícia, generant diverses visions per a futurs sostenibles.

C2.1: Identificar i analitzar problemes que requereixen adoptar decisions autònomes, informades i argumentades, per actuar amb responsabilitat social, segons valors i principis ètics.

C3.1: Desenvolupar la capacitat d'avaluar les desigualtats per raó de sexe i gènere i per dissenyar solucions.

C4.1: Aplicar les tecnologies de descentralització financera en aplicacions o models de negoci que possibilitin la reducció de costos i la millora de la rendibilitat, considerant marc ètic i legal vigent.

C9.1: Aplicar les noves tecnologies i aplicació de digitalització bancària a nous projectes de desenvolupament.

C9.2: Aplicar els casos d'èxit en tecnologia i desintermediació financera per a les noves expedienties empresarials.

Podem posar en relleu:

- Interpretar i aplicar conceptes clau de ciència de dades en el context financer.
- Dissenyar i desenvolupar projectes d'analítica de dades financeres, des de la preparació de dades fins a la visualització de resultats.
- Utilitzar eines i llenguatges de programació (com Python o R) per a anàlisi de dades i modelatge predictiu en problemes de Finances.
- Aplicar tècniques d'aprenentatge automàtic supervisat i no supervisat a problemes financers reals.
- Implementar models d'aprenentatge per reforç en escenaris financers.
- Comprendre i aplicar models d'IA generativa i models de llenguatge (LLMs) per a tasques com anàlisi textual, predicció i automatització en finances.
- Analitzar i resoldre casos reals en àmbits com valoració d'actius, gestió de carteres, anàlisi de risc, trading algorítmic, i anàlisi de blockchain i criptoactius.
- Avaluar críticament l'impacte de les tecnologies d'IA i big data en el sector financer, amb un enfocament ètic i estratègic.

4. CONTINGUTS

TEMA 1: INTRODUCCIÓ A LA CIÈNCIA DE DADES APLICADA A LES FINANCES

Resultats específics d'aprenentatge:

- Comprendre els principis fonamentals de la ciència de dades aplicada a les finances, incloent-hi el seu potencial estratègic i transformador.
- Reconèixer casos d'ús representatius on la ciència de dades aporta valor en banca, assegurances, inversions i altres sectors financers.

Continguts:

- 1.1. Canvi de model: de les finances basades en teoria, a finances basades en dades.
- 1.2. Aplicació de la IA a les diferents àrees del sector financer.

TEMA 2: ELEMENTS I ETAPES D'UN PROJECTE DE DATA SCIENCE EN FINANCES

Resultats específics d'aprenentatge:

- Comprendre el context financer del projecte. Traduir necessitats del negoci en objectius analítics.
- Preparar i adaptar les dades per al seu ús en anàlisis exploratòries (EDA) i models de machine learning.

- Aplicar tècniques estadístiques i visuals per explorar conjunts de dades. Identificar patrons, correlacions, valors atípics i relacions entre variables. Utilitzar l' EDA com a pas previ per a la selecció d' algorismes adequats.
- Conèixer diferents estructures de dades utilitzades en finances i ciència de dades: taules, grafs, arbres, etc.
- Avaluar el rendiment de models i ajustar paràmetres segons l' objectiu del negoci.
- Conèixer i aplicar algoritmes d' aprenentatge automàtic Supervisat.
- Conèixer i aplicar algoritmes d' aprenentatge automàtic No-supervisat.
- Conèixer i aplicar algoritmes d' aprenentatge Reforçat.
- Comprendre el funcionament dels models **d'Intel·ligència Artificial Generativa (GenAI): Large Language Models (LLMs)** i la seva aplicació en finances.
- Conèixer els llenguatges de programació i llibreries més utilitzats en ciència de dades per a finances: Python i R.

Continguts:

2.1 Introducció.

2.2 Elements i etapes de l' analítica financera. Eines, infraestructura tecnològica i llenguatges de programació més utilitzats en la indústria financera.

2.2.1 Entendre el Negoci i els objectius del projecte. Exemples en Finances.

2.2.2 Dades.

2.2.2.1 Les dades financeres: fonts, neteja, pre-processament visulització. Arquitectura de dades.

2.2.2.2 Estructures de Dades.

2.2.2.3 Tractament de Dades.

2.2.2.4 Anàlisi exploratòria de dades (*Exploratory Data Analysis: EDA*).

2.2.3 Algorismes.

2.2.3.1 Models predictius.

2.2.3.2 Aprenentatge automàtic (*Machine Learning*): Supervisat, No-Supervisat, Reforçat (*Reinforcement Learning*).

2.2.3.3 Aprenentatge Supervisat: Regressió i Classificació. Regressió lineal i logística; Naïve Bayes; Màquines de vectors suport (SVM); Arbres de decisió; Boscos aleatoris; k-NN; Potenciació del gradient (*Gradient boosting*); Xarxes neuronals.

2.2.3.4 Aprenentatge No-supervisat. Clusterització: K-Means, jeràrquica, models gaussians; Associació: algoritme Apriori per descobrir relacions entre variables; Reducció de dimensionalitat: Anàlisi de Components Principals (PCA).

2.2.3.5 *Aprenentatge per reforç.*

2.2.3.5.1 Q-Aprenentatge.

2.2.3.5.2 SARSA-Aprenentatge.

2.2.3.5.3 Aprenentatge Q profund.

2.2.4 IA Generativa i els models de llenguatge: *Large Language Models* (LLMs).

2.2.4.1 Arquitectura de Transformador.

2.2.4.2 Fitxes i *Incrustacions*.

2.2.4.3 Agents.

2.2.4.4 Generació augmentada per recuperació (RAG).

2.2.4 Els llenguatges de Programació: Python i R. Utilitzar llibreries clau per a anàlisi i modelatge:

- Pandes: manipulació de dades.
- NumPy i SciPy: càlculs científics i numèrics.
- Matplotlib: generació de gràfics i visualitzacions.
- Scikit-learn: models de machine learning tradicionals.
- TensorFlow i Keras: desenvolupament de xarxes neuronals.
- PyTorch: modelat avançat en *deep learning*.

TEMA 3: COM S' UTILITZA LA CIÈNCIA DE DADES EN FINANCES

Resultats específics d' aprenentatge:

- Comprendre el paper de la ciència de dades en l' anàlisi de mercats i en la presa de decisions quantitatives.
- Modelar sèries temporals financeres per identificar tendències i estacionalitats.
- Els models d' aprenentatge automàtic i IA aplicats als Derivats financers. Valorar opcions, futurs i supèrs mitjançant models de valoració numèrics i analítics. Avaluar i gestionar el risc associat a derivats utilitzant mesures.
- Dissenyar i optimitzar carteres diversificades d' actius financers seguint criteris de mediavariància i altres enfocaments moderns.
- Extreure dades de fonts no estructurades (notícies, xarxes socials, informes).

- Aplicar tècniques de NLP per mesurar sentiment i variables qualitatives que millorin models predictius.
- Aplicació dels models d'aprenentatge automàtic a Riscos financers. Desenvolupar models de predicció de morositat, frau i riscos operatius. Implementar algoritmes de detecció d'anomalies per monitoritzar esdeveniments crítics. Estimar mètriques de risc (crèdit, mercat, liquiditat) i validar la seva robustesa.
- Segmentar clients mitjançant algoritmes de clustering i scoring. Dissenyar sistemes de recomanació i estratègies de màrqueting personalitzat.
- Preveure comportaments i necessitats dels clients a través de models predictius.

Continguts:

3.1 Mercats Financers i Finances Quantitatives.

3.1.1 Els preus dels actius financers.

- Aplicar tècniques d'anàlisi de dades per modelar i preveure el comportament dels preus d'actius.
- Utilitzar sèries temporals, models estocàstics i simulacions per estudiar moviments del mercat.

3.1.2 Valoració i gestió d'instruments derivats.

- Emprar eines quantitatives basades en aprenentatge automàtic per valorar derivats com a opcions, futurs i swap.
- Avaluar el risc associat a aquests productes mitjançant models matemàtics i computacionals basats en ciència de dades.

3.1.3 Carteres multiactiu i aprenentatge automàtic aplicat.

- Optimitzar carteres diversificades utilitzant models d'optimització.
- Analitzar la correlació entre actius i ajustar l'assignació d'actius basada en dades.

3.1.4 Sentiment i informació no-estructurada.

- Extreure valor a partir de dades no estructurades (notícies, xarxes socials, informes).
- Aplicar processament de llenguatge natural (NLP) per mesurar el sentiment del mercat.
- Integrar aquesta informació en models predictius i de gestió de risc.

3.2 Control i Gestió de Riscos en Banca i Assegurances.

- Aplicar models de predicció de morositat, frau i riscos operatius.

- Utilitzar algorismes de classificació i detecció d'anomalies per prevenir pèrdues en subscripció i originació de risc.
- Estimar el risc creditici, de mercat i de liquiditat amb eines avançades d'anàlisi de dades.

3.3 Personalització i Analítica de Clients.

- Utilitzar tècniques de segmentació de clients (*clustering*) per personalitzar serveis financers.
- Analitzar el comportament del client per millorar productes, màrqueting i retenció.
- Predir necessitats i comportaments mitjançant aprenentatge automàtic i analítica avançada.

TEMA 4: CASOS PRÀCTICS

Resultats específics d'aprenentatge:

- Aplicar mètodes de segmentació de clients i algorismes de recomanació per crear solucions d'inversió personalitzades.
- Desenvolupar models predictius de risc creditici per estimar impagaments i gestionar l'exposició creditícia.
- Aplicar mètodes actuarials i tècniques d'aprenentatge automàtic per gestionar el risc i determinar preus en productes d'assegurances.
- Utilitzar models de *nowcasting* per preveure indicadors econòmics amb dades en temps real.
- Dissenyar i optimitzar algorismes de trading automatitzat per executar operacions en mercats financers.
- Utilitzar tècniques de ciència de dades per analitzar blockchain i cryptoactius, millorar la presa de decisions i preveure el comportament del mercat.

Continguts:

4.1 Assessorament Financer Personalitzat.

4.2 Gestió de Riscos Financers: el Crèdit.

4.3 Gestió de Riscos Actuarials en Assegurances.

4.4 Economia i Nowcasting.

4.5 Trading Algorítmic.

4.6 Ciència de Dades per a Blockchains i Criptoactius.

5. METODOLOGIA D' ENSENYAMENT I APRENENTATGE

L'ensenyament es duu a terme mitjançant una sèrie de sessions presencials, l'esperit de les quals és el de combinar equilibradament la teoria i la pràctica, complementades amb una sèrie de materials didàctics (manual i presentació), exercicis i casos per a la seva resolució, facilitats via online i amb *feedback*, així mateix online, utilitzant de suport digital la plataforma pròpia del programa.

Les activitats presencials es realitzaran mitjançant:

- Exposició per part del professor de l' aplicació pràctica dels continguts teòrics dels diferents temes de l' assignatura. És imprescindible la lectura prèvia (per part de l'estudiant) del manual de referència de cada tema que està disponible a l'aula virtual.
- Debat dels continguts.
- Aplicació dels conceptes i metodologies a exemples/casos pràctics

L'aprenentatge es consolidarà mitjançant la resolució dels exercicis i/o casos que es facilitaran al campus virtual de l'assignatura.

6. AVALUACIÓ

D' acord amb el Pla Bolonya, el model premia l' esforç constant i continuat de l' estudiantat. Un 60% de la nota s' obté de l' avaluació contínua de les activitats dirigides i el 40% percentatge restant, de l' examen final presencial. L' examen final té dues convocatòries.

La nota final de l'assignatura (NF) es calcularà a partir de la següent fórmula:

- **NF = Nota Examen Final x 40% + Nota Avaluació Continuada x 60%**
- Nota mínima de l' examen final per calcular la NF serà de 40 punts sobre 100.
- L' assignatura queda aprovada amb una NF igual o superior a 50 punts sobre 100.

Tipus d' activitat	Descripció	% Avaluació contínua	
Qüestionaris:			60%
Qüestionari 1	Test Tema 1	20%	
Qüestionari 2	Test Tema 2	20%	
Qüestionari 3	Test Tema 3	20%	
Examen final			40%
	Examen final	100%	

7. BIBLIOGRAFIA

7.1. BIBLIOGRAFIA BÀSICA

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 BIBLIOGRAFIA COMPLEMENTÀRIA

- 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-recommendation-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.