

Anexo I. Registro del Título del Trabajo Fin de Grado (TFG)

NOMBRE DEL ALUMNO: Raúl Bermejo Mediavilla

Programa: E2 + BA

Grupo: 5ºA

Fecha: 23/10/2024

Director Asignado: Aza Hidalgo, Marcos

Título provisional del TFG: **Modelo de Trading Algorítmico Basado en Detección de Patrones en Commodities a través de Machine Learning**

1. Objetivo del TFG:

El objetivo principal de este trabajo es diseñar un modelo de trading algorítmico que permita detectar patrones en los precios de diversos commodities mediante técnicas de *Machine Learning* (ML). Estos commodities incluyen Petróleo crudo, Gas natural, Oro, Plata, Cobre, Aluminio, Níquel, Platino, Paladio, Trigo, Maíz, Soja, Café, Azúcar, Algodón, Cacao, Mineral de hierro, Gasolina, Energía eléctrica, Madera (*Lumber*) y Zinc. Se aplicarán técnicas de aprendizaje supervisado y no supervisado para identificar patrones históricos que permitan mejorar la toma de decisiones en estrategias de trading automatizadas.

2. Metodología:

Para llevar a cabo esta investigación, se seguirá el siguiente enfoque metodológico:

- Revisión bibliográfica:** Se realizará una revisión de la literatura relacionada con el uso de técnicas de *Machine Learning* para la detección de patrones en series temporales, especialmente en el ámbito del trading algorítmico aplicado a los mercados de commodities.
- Selección de datos:** Se recopilarán datos históricos de precios de los commodities seleccionados, así como variables macroeconómicas relacionadas, como tasas de interés, inflación y datos de oferta y demanda. La fuente de los datos será confiable y abarcativa para asegurar la calidad del modelo.
- Análisis de las variables:** Se analizarán las variables más influyentes en la predicción de precios y patrones de los commodities. Esto incluirá el análisis de la volatilidad, tendencias de precios y correlaciones entre los distintos commodities.
- Diseño del algoritmo de clasificación:** Se evaluarán diferentes técnicas de ML como redes neuronales, árboles de decisión, modelos de *Random Forest*, y algoritmos no supervisados como K-means y clustering jerárquico. El modelo se ajustará para maximizar la precisión en la detección de patrones que puedan ser aplicables a estrategias de trading.
- Validación del algoritmo:** Se utilizarán técnicas de validación cruzada y métricas de rendimiento (precisión, *recall*, F1) para evaluar la efectividad del modelo. También se realizarán pruebas retrospectivas (*backtesting*) para comprobar el rendimiento del modelo en datos históricos y su potencial en la práctica.
- Análisis y conclusiones:** Los resultados obtenidos serán analizados para extraer conclusiones sobre la capacidad del modelo para identificar patrones consistentes y rentables en los mercados de commodities. Se discutirán las implicaciones para traders y gestores, y se explorarán mejoras posibles.

Índice Provisional

1. Introducción

- Contexto y motivación del estudio
- Planteamiento del problema
- Objetivos y estructura del trabajo

2. Fundamentos teóricos

- Introducción al mercado de commodities
- Trading algorítmico y técnicas de detección de patrones
- Importancia de *Machine Learning* en la predicción de precios de commodities

3. Metodología

- Descripción de los datos utilizados (precios de commodities, variables macroeconómicas)
- Selección de las variables relevantes para la clasificación
- Procesamiento de los datos
- Modelos de *Machine Learning* seleccionados para la detección de patrones

4. Desarrollo del algoritmo

- Construcción del modelo de detección de patrones
- Implementación técnica del algoritmo
- Optimización y ajuste del modelo
- Validación del modelo con datos históricos

5. Resultados y análisis

- Resultados del modelo aplicado a los distintos commodities
- Interpretación de los patrones detectados
- Comparativa con otros enfoques tradicionales de trading
- Evaluación del rendimiento del modelo en términos de precisión y rentabilidad


6. Conclusiones

- Resumen de los hallazgos principales
- Aportes del estudio al ámbito del trading algorítmico
- Limitaciones del modelo y estudio
- Propuestas para investigaciones futuras

4. Bibliografía

- Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLOS ONE*, 12(7), e0180944. <https://doi.org/10.1371/journal.pone.0180944>
- Mara Nakano, M., Takahashi, A., & Takahashi, S. (2018). Bitcoin technical trading with artificial neural network. *Physica A: Statistical Mechanics and its Applications*, 510, 587-599. <https://doi.org/10.1016/j.physa.2018.07.032>
- Kumar, A., & Thenmozhi, M. (2012). Forecasting Commodity Market Price Trends with Decision Trees and Support Vector Machines. *Procedia Economics and Finance*, 1, 330-339. [https://doi.org/10.1016/S2212-5671\(12\)00038-5](https://doi.org/10.1016/S2212-5671(12)00038-5)
- Tang, Y., Almeida, C., & Fishwick, P. (2019). Time series forecasting using machine learning techniques: A survey. *Energy Systems*, 10(3), 1-26. <https://doi.org/10.1007/s12667-019-00318-4>

Firma del estudiante:

A handwritten signature in black ink, consisting of several overlapping loops and strokes, positioned to the right of the text 'Firma del estudiante:'.

Fecha: 23/10/2024