AGTU – THE GLOBAL UNIVERSITY

APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL UTILIZANDO REDES NEURAIS RECORRENTES PARA TESTAR OS SINAIS DE TRADE E AVALIAR PERFORMANCE: UM ESTUDO DE CASO

AUTOR: MARCIO LUCENA MAGALHAES

Resumo

Este estudo de caso explora a aplicação de técnicas de Inteligência Artificial com a utilização de Redes Neurais Recorrentes (RNNs), para aprimorar a estratégia de alocação dinâmica do fundo de investimentos "Agile Capital", prevendo preços diários de Bitcoin e da Apple, em um horizonte de 14 dias. O objetivo do estudo é testar os sinais de trade embasados em forecast e avaliar a performance relativa entre duas classes de ativos. Para tal, detalha-se uma metodologia robusta, desde a coleta e pré-processamento de dados históricos de cotação até o treinamento, validação e avaliação comparativa de modelos de RNNs, frente a abordagens tradicionais. Discute-se os resultados simulados, métricas de forecast como o MSE, o cálculo do Sharpe Ratio para avaliação de retorno ajustado ao risco e os desafios inerentes à modelagem de séries temporais financeiras, como a volatilidade e o risco de overfitting. O estudo visa oferecer insights sobre a viabilidade e as limitações do uso de IA para embasar decisões de trading em mercados dinâmicos.

Palavras-chave: Inteligência Artificial; RNN; Forecast; MSE; Sharpe Ratio

1. Introdução

O mercado financeiro caracterizado pela complexidade e volume de dados, tem se tornado um campo fértil para a aplicação de inovações tecnológicas. Fundos de investimento, como o "Agile Capital", buscam constantemente otimizar suas estratégias de alocação de ativos para maximizar retornos e gerenciar riscos. A alocação dinâmica, que ajusta a composição da carteira com base em previsões de mercado, é particularmente desafiadora devido à natureza muitas vezes não linear e volátil dos preços dos ativos.

O ressurgimento das redes neurais e o avanço em pesquisa resultaram no nascimento dos modelos denominados de Modelos de Aprendizado Profundo, deep learning (Cozman, 2021), como as Redes Neurais Recorrentes (SimpleRNN, LSTM, GRU), emergem como ferramentas promissoras [1]. As RNNs são arquitetadas para identificar padrões em dados sequenciais, tornando-as adequadas para a análise de séries temporais financeiras. Este estudo de caso detalha uma abordagem sistemática para desenvolver e avaliar um sistema de previsão de preços diários de ativos como Bitcoin e Apple. A proposta é testar os sinais de trade embasados em forecast e avaliar a performance relativa entre essas classes de ativos.

2. Referencial Teórico

A previsão de séries temporais financeiras é um campo de pesquisa bem ativo, impulsionado pela promessa de ganhos financeiros e pela complexidade dos mercados. Com o advento do machine learning e posteriormente do deep learning, novas abordagens ganharam destaque. As Redes Neurais Artificiais (RNAs) oferecem a capacidade de modelar relações não lineares complexas. Dentro das RNAs, a Rede Neural Recorrente (RNN) é um tipo de rede neural que captura informações dinâmicas em dados serializados conectando periodicamente nós na camada oculta, de modo a classificar os dados serializados (Huawei, 2022) [2].

Sobre os tipos de RNNs: SimpleRNN é a forma mais básica de uma rede recorrente, pega a saída do passo anterior e a utiliza como entrada para o passo atual, criando um "loop" que permite a persistência de informação; LSTM (Long Short-Term Memory) é uma evolução da SimpleRNN projetada para resolver o problema de dependências de longo prazo. Ela possui uma estrutura mais complexa com portões que controlam o que é esquecido, o que é mantido e o que é passado para o próximo passo; GRU (Gated Recurrent Unit) é uma versão simplificada da LSTM. Ela combina os portões de esquecimento e de entrada em um único "portão de atualização".

Para o desempenho de um modelo de previsão com RNNs, temos as métricas: Erro Quadrático Médio (MSE) que calcula a média dos quadrados das diferenças entre os valores previstos e os valores reais; Raiz do Erro Quadrático Médio (RMSE) que é a raiz quadrada do MSE; Erro Absoluto Médio (MAE) que calcula a média das diferenças absolutas entre os valores previstos e os valores reais;

Erro Percentual Absoluto Médio (MAPE) que calcula o erro percentual médio absoluto.

A escolha da métrica depende do objetivo e da natureza dos dados, sendo útil analisar múltiplas métricas para ter uma visão mais completa do desempenho do modelo. O Sharpe Ratio é uma métrica muito utilizada para avaliar o retorno de um investimento ajustado ao risco, interpretado como: sharpe > 1 (bom retorno ajustado ao risco); sharpe > 2 (excelente); sharpe < 1 (risco pode não compensar).

3. Metodologia

A metodologia adotada foi de pesquisa bibliográfica e experimental, sendo que o estudo de caso simula a implementação de um projeto de IA para o fundo "Agile Capital", considerando as ações metodológicas detalhadas nas etapas a seguir.

Os notebooks utilizados na implementação do projeto, assim como as figuras deste documento, podem ser acessados nos links:

- Forecast Bitcoin

https://colab.research.google.com/drive/165ZCIm_Vdqy1-dubduxravZEDhSR2Lf

- Forecast Apple

https://colab.research.google.com/drive/1U0YGXyZ1kTqVPlox0h4kXCslMC7Jw709

3.1. Coleta, tratamento e preparação dos dados

- Coleta e ingestão de dados dos datasets no formato csv (BTC e AAPL) baixados do site Investing.com da série histórica de 2014 à 2024;
- Tratamento de datas faltantes com o forward fill e excluído as linhas cuja data consta como feriado nacional;
- Análise exploratória de dados com a geração de gráficos de preços e volumes da série histórica;
- Cálculo de indicadores técnicos e geração de gráficos da média móvel simples, média móvel exponencial, índice de força relativa e MACD;
- Normalização dos preços de fechamento utilizando a função MinMaxScaler;
- Preparação dos dados para as RNNs com a utilização de janelas deslizantes.

3.2. Modelagem, treinamento com Redes Neurais Recorrentes (RNNs) e Tuning

- Foram utilizados três modelos de RNNs: SimpleRNN, LSTM e GRU, cada um com 2 camadas, 50 neurônios e camada dense para a previsão do preço;
- A plataforma utilizada para treinamento dos modelos citados foi a Google Colab; Utilização do otimizador Adam, EarlyStopping, Erro médio quadrático na função de perda da rede neural, uso de dropout para

evitar overfitting;

- Utilização de validação cruzada para Séries Temporais com TimeSeriesSplit.

3.3. Avaliação de Desempenho e Risco

- Foram realizadas diversas simulações das séries históricas da Apple e Bitcoin com vários modelos de redes neurais e calculado diversas métricas com os resultados exibidos na Tabela 1;
- O modelo de rede neural LSTM apresentou um resultado melhor comparado com as demais;

Tabela 1. Simulação

Simulação com a Apple	SimpleRNN	LSTM	GRU
MSE - Erro Médio Quadrático	$58.99	$58.67	$79.88
RMSE - Raiz do Erro Médio Quadrático	$7.68	$7.66	$8.94
MAE - Erro Médio Absoluto	$6.24	$6.22	$7.35
MAPE - Erro Percentual Médio Absoluto	3.20%	3.20%	3.76%

Simulação com Bitcoin	SimpleRNN	LSTM	GRU
MSE - Erro Médio Quadrático	$14418130.08	$9969775.98	$12761243.81
RMSE - Raiz do Erro Médio Quadrático	$3797.12	$3157.50	$3572.29
MAE - Erro Médio Absoluto	$2562.34	$2142.37	$2759.70
MAPE - Erro Percentual Médio Absoluto	5.07%	4.49%	6.14%

Fonte: autor

- Sobre o Sharp Ratio simulado, em todas as simulações de retorno hipotético, a modalidade Buy-and-Hold superou a Estratégia baseada em previsões / forecast-based signals (long-only), conforme a análise de risco

simulada obtida para a série do Bitcoin (Figura 1) e as Estatísticas de Retornos (Figura 2).

```
==== Análise de Risco ====
Sharpe Ratio (Buy and Hold): 1.6865
Sharpe Ratio (Baseado em Previsões): -0.1205
```

Figura 1. Análise de Risco. Fonte: autor. Elaborado no Colab

```
==== Estatisticas de Retornos ====
Retorno Médio Diário (Buy and Hold): 0.2697%
Retorno Médio Diário (Estratégia): -0.0194%
Volatilidade Diária (Buy and Hold): 2.5403%
Volatilidade Diária (Estratégia): 2.5545%
Retorno Cumulativo (Buy and Hold): 455.84%
Retorno Cumulativo (Estratégia): -31.36%
```

Figura 2. Estatísticas de Retornos. Fonte: autor. Elaborado no Colab

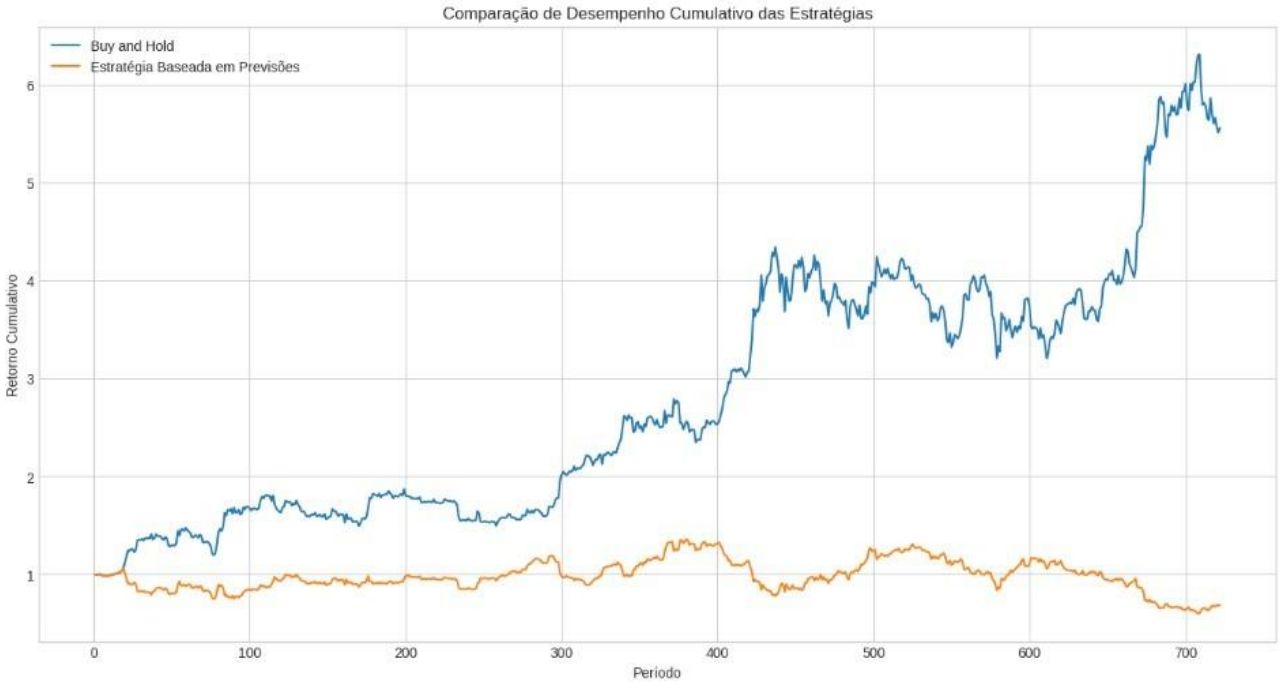


Figura 3. Comparação de Desempenho. Fonte: autor. Elaborado no Colab

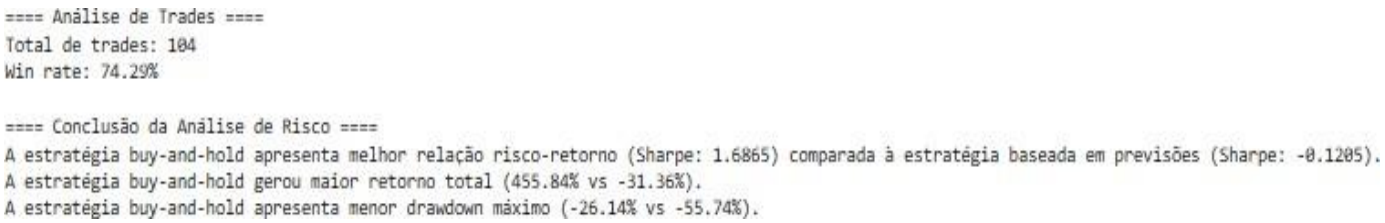


Figura 4. Análise e Conclusão. Fonte: autor. Elaborado no Colab

3.4. Resultados em Dashboard

Exemplo de dashboard para a simulação do Bitcoin utilizando o modelo de rede neural LSTM.



Figura 5. Dashboard de Resultados. Fonte: autor. Elaborado no Colab

4. Questões analisadas

Em termos de volatilidade versus dependência temporal: as RNNs conseguem capturar picos e/ou crashes em criptomoedas? As RNNs, em especial as LSTMs e GRUs, têm potencial para capturar alguns sinais precursores de picos e crashes se esses eventos forem precedidos por padrões aprendidos nos dados históricos como: mudanças anormais no volume e certos padrões nos indicadores técnicos. No entanto, prever eventos impulsionados por notícias repentinas e não

refletidas nos dados de preço/volume passados, continuam sendo um desafio extremo. Livieris et al. (2020) propôs modelos híbridos que combinam RNNs com outras técnicas para melhorar a capacidade de capturar volatilidade extrema, sugerindo que as RNNs sozinhas podem não ser suficientes [3].

Em relação a variáveis exógenas x endógenas: até que ponto os indicadores técnicos ajudam no forecast? Os indicadores técnicos tradicionais continuam sendo amplamente utilizados em análises financeiras, mas pesquisas recentes têm reavaliado sua eficácia no contexto de mercados modernos. Como destacam Sezer et al. (2020), esses indicadores representam transformações matemáticas das próprias séries temporais de preços e volumes, funcionando essencialmente como variáveis endógenas derivadas [4]. A simulação poderia mostrar que a inclusão de indicadores técnicos (SMA, EMA, RSI, MACD) e volume como variáveis exógenas melhora modestamente o desempenho dos modelos em relação a usar apenas o histórico de preços (variável endógena).

Ao comparar modelos tradicionais versus deep learning, questiona-se: onde os modelos clássicos ainda ganham? Apesar do avanço contínuo do deep learning, os modelos estatísticos tradicionais mantêm vantagens significativas em diversos cenários: Interpretabilidade e transparência pela facilidade da compreensão na decisão; Eficiência computacional com uso de poucos recursos em relação as redes neurais; Quando o conhecimento de domínio pode ser diretamente incorporado aos modelos, como sazonalidades conhecidas e relações causais; Desempenho em dados estruturados bem definidos; Como observado por Makridakis et al. (2022) em seu estudo comparativo abrangente de métodos de previsão, a escolha entre modelos tradicionais e deep learning deve ser guiada pelas características específicas do problema, com uma abordagem pragmática que reconheça os pontos fortes de cada

paradigma [5].

Um ponto importante é o gerenciamento de risco. Usar forecast para trade real é algo viável? A utilização do forecast para trade real é viável, desde que seja utilizado como um sinal probabilístico dentro de um sistema e da robustez do gerenciamento de risco. A viabilidade não está em prever o preço exato, mas em extrair sinais mais sutis do mercado a partir de dados híbridos da combinação de dados. Livieris et al. (2020) mostram que modelos híbridos, como a combinação de Redes Neurais Convolucionais para extrair padrões de janelas de tempo com LSTMs para interpretar a sequência temporal desses padrões, podem superar modelos únicos ao extrair diferentes tipos de características dos dados de preços. Outro questionamento que pode surgir é sobre qual fração alocar? A fração a ser alocada deve ser conservadora, começando com uma fração fixa de risco (1-2% do capital por operação). Métodos mais complexos como o Fractional Kelly ou alocação baseada em incerteza só devem ser considerados após o modelo provar sua robustez em um ambiente simulado que inclua custos realistas e de forma muito cautelosa.

Como detectar o overfitting e evitá-lo em dados financeiros ruidosos? O overfitting, também conhecido como sobretreinamento, ocorre quando um modelo se ajusta de forma excelente aos dados de treino, mas falha em generalizar para dados novos (fora da amostra). Os dados financeiros apresentam desafios únicos para machine learning devido à alta dimensionalidade, ruído significativo, não-estacionariedade e correlações espúrias. O overfitting em finanças manifesta-se principalmente através de backtest overfitting, seleção enviesada de características e parametrização excessiva (Arian et al., 2024) [6]. Alguns métodos de detecção são: validação cruzada temporal (walk-forward), análise de curvas de aprendizado, métricas de estabilidade e teste de permutação. Já para a prevenção, a solução está

em uma abordagem integrada: regularização forte como Dropout que desativa aleatoriamente neurônios durante o treinamento, forçando a rede a aprender representações mais robustas e menos dependentes de neurônios individuais; O Meta-Labeling é uma técnica que estrutura o problema de uma maneira que reduz significativamente o impacto do ruído, tornando as previsões mais confiáveis e com maior sentido financeiro; A engenharia de features também pode ser utilizada pois cria features que capturem conceitos financeiros conhecidos (momentum, valor, volatilidade).

5. Conclusões

Este estudo de caso oferece uma análise aprofundada da aplicação de Redes Neurais Recorrentes para a previsão de preços de Bitcoin e Apple, com o objetivo de gerar sinais de trade para a alocação dinâmica do fundo de investimentos “Agile Capital”. Demonstrou-se que as RNNs, especialmente as LSTMs, são ferramentas poderosas para capturar padrões complexos em séries temporais financeiras, superando os modelos tradicionais em termos de acurácia de previsão quando as variáveis exógenas são devidamente incorporadas, porém muito importante reconhecer os limites inerentes à previsão de mercados voláteis.

A volatilidade dos preços apresenta um desafio persistente, e mesmo os modelos de deep learning mais avançados podem não ser capazes de prever com precisão eventos extremos. O gerenciamento de risco se torna o pilar de qualquer estratégia baseada em forecast, com a alocação de capital sendo cuidadosamente ponderada pelo sharpe ratio simulado.

O sucesso desta abordagem não reside apenas na acurácia das previsões, mas na robustez e na capacidade de adaptação do modelo as novas condições de mercado. A detecção e mitigação do overfitting, através de técnicas de validação e regularização, são vitais para garantir a generalização do modelo. A recomendação final é o desenvolvimento de um sistema híbrido, que combine a capacidade preditiva das RNNs com uma sólida estrutura de gerenciamento de risco e monitoramento contínuo, permitindo uma tomada de decisão mais informada e resiliente no dinâmico cenário dos mercados financeiros.

6. Referências

[1] COZMAN, F. G.; PLONSKI, G. A.; NERI, H. **Inteligência Artificial: avanços e tendências.** Universidade de São Paulo. Instituto de Estudos Avançados, 2021.

[2] HUAWEI TECHNOLOGIES CO., LTD. **Artificial Intelligence Technology.** Springer, 2022.

[3] LIVIERIS, I. E.; GUDELEK, M. U.; OZBAYOGLU, A. M. **A CNN-LSTM model for gold price time-series forecasting.** Neural Computing and Applications, 2020.

[4] SEZER, O. B.; GUDELEK, M. U.; OZBAYOGLU, A. M. (2020). **Financial time series forecasting with deep learning:** A systematic literature review: 2005–2019. Applied Soft Computing.

[5] MAKRIDAKIS, S.; SPILIOTIS, E.; ASSIMAKOPOULOS, V**. M5 accuracy competition:** Results, findings, and conclusions. International Journal of Forecasting, 2022.

[6] ARIAN, H. R.; NOROUZI, D.; SECO, L. A. **Backtest Overfitting in the Machine Learning Era:** A Comparison of Out-of-Sample Testing Methods. Journal of Financial Data Science, Elsevier, 2024.