

Análise comparativa das técnicas de previsão da movimentação do dólar no mercado financeiro brasileiro: uma abordagem utilizando Machine Learning

Víctor Souza Santos¹, Carlos Alberto Rodrigues¹

¹Universidade Estadual de Feira de Santana (UEFS)
Caixa Postal 44036-900 – Feira de Santana – BA – Brasil

victor.s.santos2@gmail.com, carod@uefs.br

Abstract. *This paper compares machine learning algorithms for predicting the dollar's exchange rate against the real, seeking the most accurate model. Using historical and time series data, supervised classification techniques were applied. The following algorithms were evaluated: Random Forest, Neural Network, SVR, SVC, Linear Regression, and KNN. Random Forest and Neural Network stood out, with accuracies of 93.68% and 89.47%. SVC, SVR, and KNN performed poorly. Linear Regression performed intermediately, serving as a benchmark. The conclusion is that models capable of capturing non-linear relationships are more effective in forecasting exchange rates in volatile scenarios.*

Resumo. *Este trabalho compara algoritmos de aprendizado de máquina para prever a variação do dólar frente ao real, buscando o modelo mais preciso. Utilizando dados históricos e séries temporais, foram aplicadas técnicas supervisionadas de classificação. Avaliaram-se os algoritmos: Random Forest, Rede Neural, SVR, SVC, Regressão Linear e KNN. Random Forest e Rede Neural se destacaram, com acurácias de 93,68% e 89,47%. Já SVC, SVR e KNN apresentaram desempenho inferior. A Regressão Linear teve desempenho intermediário, servindo como referência. Conclui-se que modelos capazes de capturar relações não lineares são mais eficazes na previsão cambial em cenários voláteis.*

1. Introdução

O mercado financeiro é caracterizado por comportamentos imprevisíveis, fortemente influenciados por decisões humanas [Tsantekidis et al. 2017]. Essa instabilidade impulsiona o desenvolvimento de modelos computacionais capazes de lidar com a complexidade, variabilidade e ruídos presentes nas séries temporais de preços. Nesse cenário, destaca-se o uso de algoritmos de aprendizado de máquina (Machine Learning – ML), que permitem a análise preditiva e a automação de decisões, transformando a forma como o mercado opera [Machado et al. 2020].

ML pode ser definido como um processo adaptativo em que um sistema ajusta sua estrutura com base nas interações com o ambiente, passando a realizar previsões ou decisões com base em dados recebidos [Ryll and Seidens 2019]. No entanto, a diversidade de métodos existentes levanta dúvidas sobre quais abordagens oferecem maior eficácia em diferentes contextos financeiros. Assim, torna-se relevante implementar e comparar

técnicas para identificar as mais adequadas ao mercado brasileiro, contribuindo para decisões mais seguras, redução de perdas e aumento da lucratividade.

Este trabalho propõe uma análise comparativa de algoritmos supervisionados de classificação e regressão para prever a variação do dólar, avaliando acurácia e desempenho financeiro simulado. Ressalta-se que nem todos os modelos são universalmente aplicáveis, pois cada ativo possui dinâmicas próprias [Lin et al. 2011]. Além disso, os parâmetros dos indicadores técnicos exigem calibração específica, considerando as características do ativo e do ambiente de negociação.

Table 1. Indicadores Técnicos Utilizados

Indicador	Descrição	Como foi utilizado no modelo
Média móvel exponencial com maior peso para preços recentes.	EMAs de 5 a 200 períodos. Variáveis binárias indicam se o preço está acima ou abaixo da média.	EMA Mede a força de movimentos de preço (0–100).
Período 14. Binárias para sobrecompra (>70) e sobrevenda (<30). Williams	Diferença entre EMAs de 12 e 26 e linha de sinal (EMA de 9).	Usada a diferença MACD – linha de sinal como variável numérica.
MACD		ROC
Variação percentual do preço em relação ao valor anterior.	Período 6. Usado como variável contínua.	
	Estocástico	

Os algoritmos analisados incluem: Random Forest Classifier, Rede Neural Artificial, Support Vector Classifier (SVC), Support Vector Regression (SVR), Regressão Linear e K-Nearest Neighbors Regressor (KNN). Cada um representa um paradigma distinto de ML. O SVR busca aproximar os dados por meio de uma margem de erro [Ring and Eskofier 2016]; a Regressão Linear modela relações lineares [Mali 2024]; o KNN estima valores com base na média dos vizinhos mais próximos [Singh 2024]; a Random Forest combina várias árvores de decisão para melhorar a precisão [Breiman 2001]; a Rede Neural simula redes biológicas com múltiplas camadas [Haykin 2001]; e o SVC encontra o hiperplano ótimo para separação de classes [Cortes and Vapnik 1995].

A escolha desses modelos visa explorar abordagens variadas do aprendizado supervisionado, buscando identificar qual oferece o melhor desempenho na previsão da variação do dólar frente ao real, com base em dados reais e métricas estatísticas apropriadas.

2. Metodologia

A metodologia adotada neste trabalho visa analisar e comparar o desempenho de diferentes algoritmos de Machine Learning na previsão da variação do dólar (ativo US-DBRL=X) no mercado financeiro brasileiro. Neste contexto, prever a variação do

dólar significa antecipar a direção do movimento diário, se haverá valorização (alta) ou desvalorização (baixa) em relação ao fechamento do dia anterior. Este problema é tratado como uma tarefa de classificação binária, na qual o objetivo dos modelos é prever corretamente o sinal da variação diária do preço.

Essa abordagem visa avaliar a eficácia dos modelos sob a ótica não apenas da acurácia preditiva, mas também da sua aplicabilidade prática em operações de mercado. A proposta é proporcionar uma visão abrangente sobre quais algoritmos apresentam maior robustez, desempenho e aderência às características do mercado financeiro nacional.

2.1. Coleta de Dados

Os dados históricos do ativo USDBRL=X foram coletados por meio da API do Yahoo Finance, com frequência diária, contemplando informações como preço de abertura, fechamento, máxima, mínima e volume. O intervalo dos dados utilizados foram de 01/01/2017 a 31/12/2017, garantindo uma base consistente e temporalmente localizada para o treinamento, validação e teste dos modelos.

Além dos dados brutos, foram calculados indicadores técnicos com o objetivo de enriquecer as variáveis explicativas (features) utilizadas na modelagem. Esses indicadores são amplamente adotados na literatura de análise técnica e contribuem para capturar informações relevantes sobre tendências, força do movimento e possíveis pontos de reversão no mercado.

Os indicadores calculados foram: Médias Móveis Exponenciais (EMAs), Índice de Força Relativa (RSI), Williams %R, Moving Average Convergence Divergence (MACD), Rate of Change (ROC) e Estocástico %K. A inclusão desses indicadores visa fornecer aos modelos uma representação mais rica e informativa do comportamento do ativo, considerando não apenas os dados de preço, mas também informações derivadas de tendências, força relativa e condições de mercado, elementos fundamentais na construção de modelos preditivos robustos.

2.2. Desenvolvimento dos Modelos

Foram desenvolvidos e configurados seis modelos de aprendizado de máquina, selecionados por representarem diferentes paradigmas dentro do Machine Learning:

- **Random Forest Classifier:** algoritmo do tipo ensemble que combina várias árvores de decisão para realizar classificações robustas e reduzir o overfitting;
- **Rede Neural Artificial:** modelo de classificação composto por múltiplas camadas densas com função de ativação ReLU e camada de saída sigmoide, utilizando a API Keras/TensorFlow;
- **Support Vector Classifier (SVC):** modelo de classificação baseado em SVM, ideal para separação binária;
- **Support Vector Regression (SVR):** apesar de ser originalmente um modelo de regressão, foi adaptado para realizar classificação com base na interpretação do sinal da previsão;
- **Regressão Linear:** utilizada para classificação binária, identificando a direção do movimento (alta ou baixa) por meio da transformação dos valores previstos em classes, com base em um limiar definido;

- **K-Nearest Neighbors (KNN):** utilizado na abordagem de classificação, baseando-se nos k vizinhos mais próximos para determinar se o movimento será de alta ou baixa.

Todos os modelos foram treinados para prever a direção do movimento do preço (alta ou baixa).

2.3. Treinamento e Validação dos Modelos

O conjunto de dados foi dividido de forma sequencial, respeitando a ordem temporal das observações. Os primeiros 70% dos dados do ano de 2017 foram utilizados para o treinamento dos modelos, enquanto os 30% finais foram reservados para o teste.

A escolha pela divisão dos dados para treinamento e para teste foi definida considerando o tamanho da base (dados diários do ano de 2017) e a necessidade de balancear a capacidade de aprendizado do modelo e sua validação em dados futuros. Essa proporção assegura que o modelo tenha dados suficientes para capturar padrões históricos e, simultaneamente, uma amostra representativa para avaliar sua capacidade de generalização no período mais recente. Esse tipo de divisão é frequentemente adotado em estudos que tratam de séries temporais financeiras com janelas anuais ou de curto prazo.

Essa abordagem assegura que a avaliação dos modelos ocorra em dados futuros não vistos, refletindo um cenário mais próximo da aplicação real no mercado financeiro. Foram aplicadas técnicas como:

- Validação cruzada k-fold, aumentando a robustez na avaliação dos modelos;
- Grid Search para ajuste de hiperparâmetros em alguns modelos, especialmente SVC, SVR e KNN.

2.4. Avaliação de Desempenho

Os modelos foram avaliados com base nas seguintes métricas de classificação:

- Acurácia;
- Precisão;
- Recall;
- F1-Score;
- Matriz de confusão

2.5. Análise Comparativa

Por fim, os modelos foram comparados entre si, considerando não apenas as métricas de desempenho, mas também aspectos como:

- Robustez a dados ruidosos;
- Sensibilidade a overfitting;
- Capacidade de generalização;
- Resultados financeiros nas simulações de mercado.

Essa análise permitiu identificar as vantagens e desvantagens de cada abordagem dentro do contexto do mercado financeiro brasileiro.

3. Resultados

Antes da análise dos resultados, é importante destacar o significado das métricas apresentadas nas Tabelas de classificação. As métricas *Precision*, *Recall* e *F1-score* são calculadas individualmente para cada classe, sendo que:

- **Classe 1** corresponde aos dias em que houve **valorização do dólar** frente ao real (*movimento de alta*).
- **Classe 0** representa os dias em que houve **desvalorização do dólar** (*movimento de baixa*).

Cada tabela exhibe, além das métricas por classe, dois tipos de médias:

- **Média Macro:** é a média aritmética das métricas (*Precision*, *Recall* e *F1-score*) considerando as duas classes igualmente, sem levar em conta a quantidade de exemplos de cada uma. Essa média é útil para avaliar se o modelo possui desempenho balanceado entre as classes, especialmente em cenários de desbalanceamento.
- **Média Ponderada (Weighted Average):** corresponde à média das métricas ponderada pelo *support* (número de amostras) de cada classe. Dessa forma, classes mais representadas têm maior influência no resultado final, refletindo o desempenho global do modelo de maneira proporcional à distribuição dos dados.

O campo **Support** indica o número de amostras reais pertencentes a cada classe no conjunto de teste. Esse valor é essencial para contextualizar as métricas, principalmente em casos de distribuição desbalanceada entre os dias de alta e de baixa do dólar.

A interpretação conjunta dessas métricas permite uma avaliação abrangente da capacidade dos modelos, não apenas em termos de acurácia global, mas também quanto à sua robustez, capacidade de generalização e sensibilidade a ruídos e fatores cruciais na previsão da variação do dólar.

Como mostrado na Tabela 2, o modelo Random Forest apresentou os melhores resultados entre as abordagens utilizadas. O modelo apresentou uma acurácia de 93,68%, com F1-score de 0.95 para a média ponderada. Destacando-se especialmente pelo excelente desempenho na previsão da classe 1, representando os dias de alta do dólar, com recall e precision próximos de 1. Isso indica que o modelo não apenas identifica corretamente os dias de alta, como também se mostra confiável ao fazê-lo. Tal resultado reflete a natureza robusta do Random Forest, capaz de lidar com ruídos e complexidades nos dados financeiros, característica essencial em ambientes de mercado.

A Matriz de Confusão apresentada na Tabela 3 reforça esses resultados. É possível observar que, dos 62 dias de alta (classe 1), 56 foram classificados corretamente, e houve apenas 6 falsos negativos. Para os 33 dias de baixa (classe 0), todos foram corretamente classificados, sem ocorrência de falsos positivos.

Table 2. Relatório de Classificação Random Forest

Classe	Precision	Recall	F1-score	Support
0	0.85	1.00	0.92	33
1	1.00	0.90	0.95	62
Acurácia			0.9368	95
Média Ponderada	0.92	0.95	0.93	95
Média Macro	0.95	0.94	0.94	95

Table 3. Matriz de Confusão - Random Forest

	Prev. Baixa (0)	Prev. Alta (1)
Real Baixa (0)	33	0
Real Alta (1)	6	56

Em segundo lugar, a Rede Neural Tabela 4 apresentou também resultados expressivos, com acurácia de 89% e F1-score médio de 0.89. Apesar de levemente inferior ao Random Forest, o modelo manteve desempenho equilibrado entre as classes e boa capacidade de generalização. Isso sugere que, mesmo sendo mais sensível a sobreajustes (overfitting), a rede foi bem configurada e treinada, obtendo resultados consistentes.

Analisando a Matriz de Confusão da Tabela 5, verifica-se que, assim como no Random Forest, todos os 33 dias de baixa foram corretamente identificados. Para os dias de alta (classe 1), o modelo acertou 52, porém cometeu 10 erros, classificando incorretamente esses dias como baixa. O que representa uma quantidade maior de falsos negativos em relação ao Random Forest.

Table 4. Relatório de Classificação Rede Neural

Classe	Precision	Recall	F1-score	Support
0	0.77	1.00	0.87	33
1	1.00	0.84	0.91	62
Acurácia			0.8947	95
Média Ponderada	0.88	0.92	0.89	95
Média Macro	0.92	0.89	0.90	95

Table 5. Matriz de Confusão - Rede Neural

	Prev. Baixa (0)	Prev. Alta (1)
Real Baixa (0)	33	0
Real Alta (1)	10	52

Por outro lado, modelos mais simples ou menos adaptados ao problema específico apresentaram desempenho significativamente inferior. O Support Vector Classifier (SVC), mostrado na Tabela 6, teve acurácia de apenas 43%, com F1-score de 0.51. A baixa capacidade de identificar corretamente os dias de alta (classe 1), cujo recall ficou em

36%, indica fragilidade do modelo diante de dados financeiros ruidosos e possivelmente mal balanceados.

Essa limitação é ainda mais evidente na Matriz de Confusão apresentada na Tabela 7. O modelo acertou apenas 16 dias de alta e cometeu 16 erros para essa mesma classe, enquanto na classe de baixa, houve 23 acertos e 21 falsos positivos, o que compromete seriamente sua confiabilidade.

Table 6. Relatório de Classificação Support Vector Classifier

Classe	Precision	Recall	F1-score	Support
0	0.59	0.52	0.55	44
1	0.43	0.50	0.46	32
Acurácia			0.5131	76
Média Macro	0.51	0.51	0.51	76
Média Ponderada	0.52	0.51	0.52	76

Table 7. Matriz de Confusão - Support Vector Classifier (SVC)

	Prev. Baixa (0)	Prev. Alta (1)
Real Baixa (0)	23	21
Real Alta (1)	16	16

A Regressão Linear Tabela 8 teve desempenho mediano, com acurácia de 54% e F1-score médio de 0.54. Embora inferior às abordagens mais complexas, apresenta uma alternativa mais simples e interpretável. Pode ser útil como ponto de partida (base-line) para análises, mas apresenta limitações claras quanto à modelagem de relações não lineares, que são comuns em séries temporais financeiras.

A Matriz de Confusão da Tabela 9 evidencia esse desempenho intermediário: dos 44 dias de baixa, 30 foram corretamente classificados e 14 foram classificados incorretamente como alta. Para os 32 dias de alta, o modelo acertou 13, mas cometeu 19 erros, o que representa uma elevada taxa de falsos negativos.

Table 8. Relatório de Classificação Regressão Linear

Classe	Precision	Recall	F1-score	Support
0	0.61	0.68	0.65	44
1	0.48	0.41	0.44	32
Acurácia			0.5657	76
Média Macro	0.55	0.54	0.54	76
Média Ponderada	0.56	0.57	0.56	76

Table 9. Matriz de Confusão - Regressão Linear

	Prev. Baixa (0)	Prev. Alta (1)
Real Baixa (0)	30	14
Real Alta (1)	19	13

O desempenho do K-Nearest Neighbors Regressor (KNN), mostrado na Tabela 10, foi particularmente preocupante. Apesar de uma acurácia de 58%, o modelo falhou completamente em prever a classe 1, com recall de 0.00. Isso revela que a acurácia é uma métrica enganosa neste caso, já que o modelo não consegue capturar os momentos de alta do dólar uma informação crítica no contexto de negociação cambial.

A Matriz de Confusão (Tabela 11) mostra claramente esse problema: todos os 32 dias de alta foram classificados como baixa (classe 0), enquanto os 44 dias de baixa foram corretamente classificados. Isso caracteriza um modelo enviesado, que aprendeu a priorizar a classe majoritária no treinamento, ignorando completamente a classe minoritária.

Table 10. Relatório de Classificação K-Nearest Neighbors Regressor

Classe	Precision	Recall	F1-score	Support
0	0.58	1.00	0.73	44
1	0.00	0.00	0.00	32
Acurácia			0.5789	76
Média Macro	0.29	0.50	0.37	76
Média Ponderada	0.34	0.58	0.42	76

Table 11. Matriz de Confusão - K-Nearest Neighbors (KNN)

	Prev. Baixa (0)	Prev. Alta (1)
Real Baixa (0)	44	0
Real Alta (1)	32	0

De forma semelhante, o modelo de Support Vector Regression (SVR), apresentado na Tabela 12, também apresentou desempenho insatisfatório. Embora tenha alcançado uma acurácia de 56%, o recall para a classe 1 novamente foi nulo. O F1-score médio ficou em 0.37, confirmando que o modelo não conseguiu capturar adequadamente as variações positivas do dólar. Isso reforça a limitação do SVR quando adaptado para classificação binária por meio de um limiar fixo, sendo mais apropriado para regressão contínua do que para predição categórica nesse cenário.

A análise da Matriz de Confusão (Tabela 13) confirma esse comportamento: assim como no KNN, todos os 32 dias reais de alta foram erroneamente classificados como baixa, enquanto os 44 dias de baixa foram corretamente previstos. Isso evidencia que o SVR, quando aplicado de forma ingênua para classificação, não é uma abordagem viável neste contexto.

Table 12. Relatório de Classificação Support Vector Regression

Classe	Precision	Recall	F1-score	Support
0	0.58	1.00	0.73	44
1	0.00	0.00	0.00	32
Acurácia			0.5789	76
Média Macro	0.29	0.50	0.37	76
Média Ponderada	0.34	0.58	0.42	76

Table 13. Matriz de Confusão - Support Vector Regression (SVR)

	Prev. Baixa (0)	Prev. Alta (1)
Real Baixa (0)	44	0
Real Alta (1)	32	0

A Tabela 14 apresenta uma visão consolidada do desempenho dos modelos, considerando acurácia, precisão, recall e F1-score por classe. Os algoritmos Random Forest e Rede Neural obtiveram os melhores resultados gerais, com acurácias de 93,68% e 89,47%, respectivamente, além de elevados valores de F1-score ponderado (0.93 e 0.89). Ambos apresentaram ótimo desempenho na identificação da classe 1 (valorização do dólar), com destaque para o recall, o que demonstra boa sensibilidade na detecção de dias de alta.

Modelos como KNN e SVR, embora tenham apresentado acurácia próxima de 58%, obtiveram recall e F1-score nulos para a classe 1, indicando total falha na previsão de valorização da moeda, mesmo acertando razoavelmente a classe 0. Esses resultados revelam forte viés de classificação para a classe majoritária, típico de modelos sensíveis a desbalanceamentos. A Regressão Linear teve desempenho mediano, com F1-score ponderado de 0.56, apresentando certo equilíbrio entre as classes, mas com limitações claras em capturar relações não lineares. O Support Vector Classifier (SVC), por sua vez, foi o modelo com pior desempenho geral, com métricas fracas em ambas as classes.

De forma geral, os resultados indicam que modelos mais robustos na detecção de padrões complexos e não lineares — como Random Forest e Redes Neurais — são mais adequados para tarefas de previsão em mercados financeiros, especialmente em cenários de alta volatilidade e distribuição desbalanceada entre classes.

Table 14. Comparativo Consolidado de Desempenho dos Modelos por Classe

Algoritmo	Acurácia	Prec. (0)	Rec. (0)	F1 (0)	Prec. (1)	Rec. (1)	F1 (Pond.)
Random Forest	93,68%	0.85	1.00	0.92	1.00	0.90	0.93
Rede Neural	89,47%	0.77	1.00	0.87	1.00	0.84	0.89
KNN Regressor	57,89%	0.58	1.00	0.73	0.00	0.00	0.42
SVR	57,89%	0.58	1.00	0.73	0.00	0.00	0.42
Reg. Linear	56,57%	0.61	0.68	0.65	0.48	0.41	0.56
SVC	51,31%	0.59	0.52	0.55	0.43	0.50	0.52

4. Conclusão

Este trabalho teve como objetivo avaliar o desempenho de diferentes algoritmos de aprendizado de máquina na previsão da variação do dólar frente ao real, utilizando dados históricos e indicadores técnicos. A partir de uma abordagem comparativa, foram analisados modelos de classificação e regressão, com ênfase na acurácia preditiva e na capacidade de generalização.

Os resultados evidenciam que modelos capazes de capturar relações não lineares, como Random Forest e Redes Neurais, apresentam desempenho significativamente superior, com acurácia de 93,68% e 89,47%, respectivamente. Ambos demonstraram robustez

frente à variabilidade dos dados e elevada capacidade na identificação de movimentos de valorização do dólar.

Por outro lado, algoritmos como Support Vector Classifier, K-Nearest Neighbors e Support Vector Regression mostraram desempenho insatisfatório, indicando limitações na modelagem de padrões complexos, especialmente em cenários de dados desbalanceados.

Conclui-se, portanto, que modelos baseados em técnicas de ensemble, como Random Forest, e arquiteturas de redes neurais são mais adequados para tarefas de previsão no mercado cambial. Ademais, o estudo reforça a relevância do ajuste criterioso de hiperparâmetros, da validação cruzada e do uso de métricas complementares à acurácia, como F1-score e matriz de confusão, para uma avaliação mais robusta.

Referências

- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3):273–297.
- Haykin, S. (2001). *Redes neurais: princípios e prática*. Bookman, 2 edition.
- Lin, X., Yang, Z., and Song, Y. (2011). Intelligent stock trading system based on improved technical analysis and echo state network. *Expert Systems with Applications*, 38(9):11347–11354.
- Machado, E. J., de Assis, C. A. S., and Pereira, A. C. M. (2020). Modelagem, implementação e avaliação de estratégias de negociação baseadas em algoritmos de aprendizado de máquina para o mercado financeiro. *Revista Brasileira de Computação Aplicada*, 12(1):16–31.
- Mali, K. (2024). Everything you need to know about linear regression. Blog post.
- Ring, M. and Eskofier, B. M. (2016). An approximation of the gaussian rbf kernel for efficient classification with svms. *Pattern Recognition Letters*, 84:107–113.
- Ryll, L. and Seidens, S. (2019). Evaluating the performance of machine learning algorithms in financial market forecasting: a comprehensive survey. arXiv preprint.
- Singh, A. (2024). Knn algorithm: introduction to k-nearest neighbors algorithm for regression. Blog post.
- Tsantekidis, A., Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., and Iosifidis, A. (2017). Forecasting stock prices from the limit order book using convolutional neural networks. In *Proceedings of the 2017 IEEE 19th Conference on Business Informatics (CBI)*, pages 7–12.