

Tema:

Estratégias de Investimento com Base na Previsão da Direção de Mercado

Introdução

No dinâmico e desafiador mundo do mercado financeiro, a busca por estratégias de investimento lucrativas permanece um objetivo primário tanto para investidores individuais quanto institucionais. Com isso, uma das perguntas mais importantes a ser respondida é: seria possível construir uma estratégia de investimento bem-sucedida com base em previsões da direção de mudança do mercado?

Objetivo

A fim de responder a principal pergunta, o objetivo deste trabalho é fornecer uma estratégia de investimento com base na previsão da direção de retornos de mercado que possa superar um índice de referência de mercado (Ibovespa).

Direção de Mercado e Estratégia

A existência de uma conexão direta entre a previsibilidade da volatilidade do retorno de ativos e a previsibilidade dos sinais de retorno de ativos, sugere que a ampla previsibilidade da volatilidade nos retornos de capital poderia ser usada para gerar previsões de mudança de direção úteis para o timing de mercado:

$$R_{t+1}|\Omega_t \sim (\mu, \sigma_{t+1|t}^2)$$

$$Pr[R_{t+1} > 0|\Omega_t] = 1 - Pr(R_{t+1} \leq 0|\Omega_t) = 1 - F\left(\frac{-\mu}{\sigma_{t+1|t}}\right)$$

Assim, é possível calcular a probabilidade de retornos positivos em função da média condicional dos retornos esperados em $t+1$ e da volatilidade futura esperada ao mesmo tempo.

Modelos de Predição

O algoritmo **Random Forest** é um método versátil e amplamente utilizado de aprendizado de conjunto tanto para tarefas de classificação quanto de regressão. Ele pertence à família de algoritmos baseados em árvores de decisão e é conhecido por sua robustez, precisão e resistência ao overfitting.

Outro algoritmo é o **Polymodel** que é definido como uma coleção de modelos univariados, todos igualmente válidos e significativos, com um mesmo target. Podem ser entendidos como uma coleção de pontos de vista relevantes sobre a mesma realidade.


$$\begin{cases} Y = \varphi_1(X_1) \\ Y = \varphi_2(X_2) \\ \dots \\ Y = \varphi_n(X_n) \end{cases} \quad \{Y = \varphi_i(X_i) \quad \forall i\}$$

Apresentam algumas vantagens em relação a outros modelos mais conhecidos como:

- Redução de overfitting
- Robustez
- Flexibilidade
- Capacidade de funcionar com séries de diferentes tamanhos entre si.

Metodologia

Partindo de dados obtidos do terminal Refinitiv e de outras plataformas de dados financeiros, séries estacionárias foram selecionadas para serem utilizadas, compondo um conjunto de 60 variáveis que abrangem o período de 2004 a 2021, com mais de 6000 registros. Assim, uma estratégia de identificação em duas etapas foi criada: realização de uma análise abrangente e testes da estrutura dos polymodels para prever a volatilidade do mercado e estimativa da probabilidade de retornos positivos, e a aplicação das previsões para formular uma estratégia que supere os retornos do índice de referência:



Foram feitas previsões de volatilidade para o índice S&P500 e Ibovespa. Além disso, para cada índice, as previsões foram realizadas para diferentes horizontes temporais: 5, 10, 22 e 66 dias.




Figura 3: Visualização do Alvo para Volatilidade de 22 dias do Ibovespa.

Resultados

Após executar todo o processo de backtesting, temos estatísticas de desempenho de algumas simulações para cada período e índice. Foi possível encontrar estratégias que performaram melhor do que os índices de referência.




Figura 4: Retornos Cumulativos de uma Simulação Exemplar, Ibovespa 22 dias.




Figura 5: Melhores resultados no backtest e média do MCS por modelo, Ibovespa 5 dias.




Figura 6: Melhores resultados no backtest e média do MCS por modelo, Ibovespa 10 dias.




Figura 7: Melhores resultados no backtest e média do MCS por modelo, Ibovespa 22 dias.

Integrantes: Gabriel de Souza Oliva
Vinicius Akira Imaizumi

Professor Orientador: Pedro Luiz Pizzigatti Corrêa