

PREDIÇÃO DE TENDÊNCIAS EM SÉRIES FINANCEIRAS UTILIZANDO METACLASSIFICADORES

CARLOS A. S. DE ASSIS (IN MEMORIAM) *

EDUARDO G. CARRANO †

ADRIANO C. M. PEREIRA ‡

Resumo

Neste trabalho foi desenvolvido um metaclassificador baseado em métodos de inteligência computacional para prever tendências em séries temporais financeiras. O *kernel* do metaclassificador foi baseado na ferramenta (Weka). Sete classificadores foram combinados para realizar a metaclassificação. Testes foram realizados com nove ativos da Bolsa de Valores de São Paulo. Os resultados iniciais foram promissores, com boa acurácia na classificação e ganhos de até 100% do valor de capital inicialmente investido no período de um ano.

Palavras-chave: séries financeiras, inteligência computacional, metaclassificador.

Abstract

This study developed a meta-classifier based on computational intelligence methods to predict trends in financial time series. The *kernel* was based on the (Weka) tool. Seven classifiers were combined to perform the meta-classification. Tests were conducted with nine B3 assets. The initial results were encouraging, with good accuracy in the classification and gains of up to 100% above the amount of capital initially invested in a one-year period.

Keywords: financial series, computational intelligence, meta-classifier.

JEL classification: C63, C53, C38.

DOI: <http://dx.doi.org/10.11606/1980-5330/ea148159>

* Centro Federal de Educação Tecnológica de Minas Gerais, Programa de Pós-Graduação em Modelagem Matemática e Computacional, Belo Horizonte, Brasil. E-mail: carlos.assis.79@gmail.com

† Universidade Federal de Minas Gerais, Programa de Pós-Graduação em Engenharia Elétrica, Belo Horizonte, Brasil. E-mail: egcarrano@ufmg.br

‡ Universidade Federal de Minas Gerais, Programa de Pós-Graduação em Ciência da Computação, Belo Horizonte, Brasil. E-mail: adrianoc@dcc.ufmg.br

1 Introdução

Prever o futuro certamente é uma das maiores ambições do ser humano. Não existe um sistema perfeito para tal finalidade, mas é possível encontrar na literatura abordagens nos mais diversos contextos, várias delas com resultados relevantes BARRYMORE (2017).

Sendo o mercado de ações um ambiente de grandes oportunidades e incertezas, diversos estudos vêm sendo desenvolvidos para realizar previsões neste contexto TKÁČ & VERNER (2016), CAVALCANTE et al. (2016). A maior parte dos estudos foca na minimização do erro de previsão, auxiliando na tarefa de prever o *timing* do mercado, isto é, o melhor momento de compra ou venda de um ativo. Para isso, são utilizados modelos treinados em dados históricos, com a esperança de se prever comportamentos futuros. Para tanto, estas pesquisas envolvem desde modelos estatísticos e econométricos até modelos de inteligência computacional NAMETALA et al. (2016), DI PERSIO & HONCHAR (2016), PATEL et al. (2015).

Neste trabalho é apresentada uma nova ferramenta para prever séries temporais financeiras, que tem por objetivo principal auxiliar na tomada de decisão para compra e venda de ativos na bolsa de valores.

Durante a construção da ferramenta, foi desenvolvido um algoritmo de metaclassificação a partir de diversos classificadores de inteligência computacional. A ideia é selecionar dinamicamente subconjuntos de classificadores mais adequados para o sucesso da classificação, isto é, a capacidade de optar pelos classificadores com maiores chances de acerto.

A principal contribuição deste trabalho é a construção de um arcabouço que implementa a abordagem do previsor com base em metaclassificadores e estratégias de investimento. Foi realizada uma revisão sistemática da literatura e não foi encontrada uma solução que apresentasse as características desenvolvidas na presente pesquisa.

Para validar a ferramenta, foram utilizados nove conjuntos de dados reais da Bolsa de Valores de São Paulo (B3). Os resultados obtidos foram comparados com *baselines* da literatura e preditores isolados, e a abordagem proposta demonstrou resultados promissores.

O artigo está organizado da seguinte forma: a Seção 2 descreve alguns trabalhos correlatos; a Seção 3 apresenta todo o referencial teórico da pesquisa; a Seção 4 descreve a metodologia que será aplicada na Seção 5; e, finalmente, a Seção 6 apresenta a conclusão e direções futuras para o trabalho.

2 Trabalhos Relacionados

Diante do cenário de incertezas do mercado de ações, diversas pesquisas têm sido desenvolvidas para auxiliar na previsão de tendências.

Para realizar de forma metódica a busca e análise dos trabalhos relacionados, realizou-se uma revisão sistemática da literatura, seguindo a proposta apresentada em KITCHENHAM (2004). As principais vantagens desse método são:

- metodologia bem definida e menos tendenciosa, que fornece informações sobre os efeitos de algum fenômeno dada uma variedade de configurações e métodos empíricos;

- consolidação de evidências e resultados obtidos em estudos anteriores sobre o tema de interesse;
- identificação de lacunas na teoria e levantamento de trabalhos recentes para embasar as pesquisas;
- embasamento e modelos teóricos para posicionar apropriadamente novos temas e oportunidades de pesquisa, para refutar ou validar hipóteses, e criar novas hipóteses sobre um determinado tema de pesquisa.

KITCHENHAM (2004) define a revisão sistemática da literatura como um meio de identificar, avaliar e interpretar pesquisas relevantes para a pesquisa específica, área temática ou fenômeno de interesse de um trabalho. Como resultado da revisão sistemática de literatura, foram selecionadas publicações conforme a metodologia proposta. A Tabela 1 apresenta o resultado final. Nesta seção, serão apresentados os principais trabalhos relacionados ao tema encontrados após a revisão.

Tabela 1: Resultado da revisão sistemática de literatura: quantidade de trabalhos selecionados por área

Técnica	Quantidade
Inteligência computacional em séries temporais financeiras	342
Metaclassificadores	42
Metaclassificador em séries temporais financeiras	4

Para MYSKOVA et al. (2018), há um campo de grandes oportunidades na análise de texto para previsão de indicadores do mercado financeiro, como preço de ações, volume de negociação e volatilidade. Desta forma, para prever a volatilidade do retorno, os autores desenvolveram um modelo de meta-aprendizagem que utiliza indicadores financeiros e artigos de notícias. A abordagem comparou 7 metaclassificadores a 3 classificadores tradicionais com dados de 14 ativos da Bolsa de Valores de Nova Iorque. O resultado foi muito promissor, mostrando melhor performance dos metaclassificadores em grande parte dos conjuntos de dados.

Segundo DUARTE et al. (2018), saber quando comprar ou vender um ativo é uma decisão importante para a obtenção de lucros em mercados financeiros. Entretanto, antes mesmo de se tomar tal decisão, um investidor deve escolher o modelo ideal para estudo e análise de uma série de dados, devido à grande quantidade de modelos disponíveis. Assim, acreditaram que a meta-aprendizagem seria uma ótima ferramenta para auxiliar em tal decisão. Eles buscaram utilizá-la para analisar séries temporais, mais especificamente em dados do mercado euro/dólar, através de um algoritmo de ranqueamento que classifica e ordena os melhores modelos para o usuário. Como resultado, a aplicação de meta-aprendizagem mostrou-se muito promissora na sugestão de modelos para o estudo de séries temporais financeiras.

Como apresentado por BARAK et al. (2017), prever os retornos das ações e seu risco é uma das preocupações mais importantes dos tomadores de decisão de mercado. Muitos estudos têm utilizado classificadores únicos para prever retornos de ativos e métodos de risco. Os métodos de fusão, que só surgiram

recentemente, exigem um estudo mais aprofundado nesta área. Um conjunto de métodos, incluindo *Bagging* BREIMAN (1996), *Boosting* SCHAPIRE (1990) e *AdaBoost* FREUND (1999), foi aplicado para criar diversidade em combinações. Testes com dados da Bolsa de Valores de Teerã do período de 2002 a 2012 demonstraram desempenho superior dos metaclassificadores.

AGAPITOS et al. (2017) desenvolveram um metaclassificador denominado *Regularised Gradient Boosting*, que é uma extensão do *Gradient Boosting*. O objetivo da proposta é diminuir o *overfitting* do classificador, eliminando parâmetros de pouca importância. Para ser validado, o método foi aplicado ao domínio de séries temporais financeiras. Como resultado dos testes, a proposta superou o *Gradient Boosting* e outros dois métodos de aprendizado de máquinas na maioria dos conjuntos de dados utilizados.

De acordo com ARMAKI et al. (2017), praticamente todas as instituições financeiras estão expostas ao risco de crédito ao emitir empréstimos ao consumidor. Portanto, é crucial desenvolver soluções confiáveis de pontuação de crédito. Segundo os autores, diversas técnicas de aprendizado de máquina vêm demonstrando boa aplicabilidade neste cenário. Porém, em diversos estudos, através da fusão de vários algoritmos de aprendizado de máquina, modelos híbridos vêm se destacando frente aos algoritmos isolados. Diante deste cenário de oportunidades, os autores apresentaram um modelo de meta-aprendizado que utiliza três classificadores - base (Nível 0) para treinar o metaclassificador (Nível 1). O classificador utilizado como meta foi o *deep belief networks*, ou seja, uma rede neural profunda. Para validar a solução, foram utilizados quatro conjuntos de dados da *UCI Machine Learning Database Repository*. Os resultados foram muito positivos, pois em praticamente todos os cenários o metaclassificador obteve melhor performance que os classificadores isolados.

Já NAMETALA et al. (2016) construíram uma estratégia automatizada (robô investidor) que combina previsões feitas por redes neurais artificiais e preditores econométricos em uma segunda rede neural, que age como um comitê de decisão. Estas previsões foram utilizadas para gerar sinais de compra ou venda por meio de um modelo de negociação incorporado ao algoritmo. Os experimentos foram conduzidos com séries reais referentes a três ativos de alta liquidez, uma *commodity* e um índice de mercado. Os resultados foram comparados financeiramente frente à aplicação individual de cada preditor e as técnicas clássicas de mercado. Os resultados mostraram que, para a maioria dos ativos, na média da carteira e nos retornos percentuais totais, os lucros obtidos pela combinação dos preditores foram melhores do que quando cada um dos preditores foi aplicado individualmente.

Segundo GIACOMEL et al. (2015), embora muitos estudos de previsão de séries temporais estejam focados em prever valores exatos no futuro, evidências mostram que esse tipo de problema é mais bem resolvido quando o transformamos em um problema de classificação. Portanto, os autores propuseram um agente de negociação baseado em um *ensemble* de redes neurais artificiais que prevê se uma ação vai aumentar ou cair em vez de prever seus valores futuros. Para validar a eficiência do método proposto em diferentes situações, o algoritmo foi avaliado em dois conjuntos de dados diferentes: os mercados de ações norte-americano e brasileiro. Operações reais foram simuladas nesses mercados e a solução demonstrou capacidade de lucrar em todas as séries temporais testadas.

De acordo com KAMPOURIDIS & OTERO (2015), a previsão financeira é uma área muito importante nas finanças computacionais. Os autores desen-

volveram o *Evolutionary Dynamic Data Investment Evaluator* (EDDIE), um algoritmo de programação financeira que utiliza a programação genética como base. A solução foi aplicada com sucesso em vários conjuntos de dados financeiros internacionais. Segundo os autores, o objetivo principal do trabalho foi melhorar ainda mais o desempenho preditivo do algoritmo, incorporando heurísticas na busca. Para examinar a eficácia de seu desempenho preditivo, a solução foi comparada com os algoritmos (C4.5)¹ QUINLAN (1993) e (RIPPER)² COHEN (1995). Os resultados mostraram que a introdução de heurísticas foi muito bem-sucedida, permitindo que o (EDDIE) superasse o (C4.5) e o (RIPPER). O algoritmo também foi capaz de ter ganhos financeiros na maioria dos conjuntos de dados.

CRUZ et al. (2015) desenvolveram um *ensemble* dinâmico denominado (Meta-DES), apresentando uma nova estrutura de meta-aprendizagem. Os autores propuseram cinco conjuntos distintos de metacaracterísticas, cada uma correspondente a um critério para medir o nível de qualidade de um classificador. As metacaracterísticas foram extraídas dos dados de treinamento e usadas para treinar um metaclassificador. Trinta conjuntos de dados extraídos do repositório (UCI), foram utilizados. Em sua maioria, os resultados apresentados foram promissores e obtiveram ganhos de acurácia em comparação ao *Bagging* e o *AdaBoost*.

PATEL et al. (2015) propuseram um algoritmo que combina três algoritmos em dois estágios: a regressão vetorial de suporte (SVR) DRUCKER et al. (1997) na primeira etapa e, na segunda, uma abordagem de rede neural artificial (RNA), *random forest* (RF) BREIMAN (2001) e (SVR), resultando em modelos de predição de fusão (SVR-ANN, SVR-RF e SVR-SVR). O algoritmo foi testado com dados reais da Bolsa de Valores de Bombaim (BSE), utilizando 10 anos de dados históricos. O desempenho da predição destes modelos híbridos foi comparado com os classificadores isolados (RNA, RF e SVR). Os resultados híbridos mostraram melhor performance.

Em outro trabalho, PIMENTA et al. (2014) apresentaram implementações de algoritmos mono-objetivo e multiobjetivo para a tomada decisão e negociação de ações para a bolsa de valores, denominados *GoldMiner*. Esses algoritmos combinaram a programação genética com os indicadores de análise técnica (médias móveis e índice de força relativa, entre outros), com o intuito de identificar o momento adequado para comprar e vender. Os testes foram realizados com dados históricos da Bolsa de Valores de São Paulo, com quatro ativos, (BOVA11, PETR4, VALE5 e BBAS3). Os resultados mostraram-se promissores, tanto na versão mono quanto na multiobjetivo. Os autores ressaltaram que, mesmo com o mercado em queda, foi possível obter lucro.

Já SEKER et al. (2013) aplicaram um *ensemble* em dados históricos financeiros a fim de encontrar correlação entre séries temporais financeiras e notícias da economia. Os algoritmos combinados foram (C4.5), máquinas de vetores de suporte (SVM) e (KNN). Os resultados mostraram ganhos de 3% na taxa de acerto em comparação com os algoritmos individuais.

Nos diversos trabalhos sobre o tema, muitos direcionados para algoritmos de inteligência computacional, vislumbram-se diversas oportunidades em mercado financeiro, abrindo espaço para explorar tal proposta, trazendo inovação e novas contribuições. O trabalho que mais se assemelha à aborda-

¹(C4.5) é um algoritmo utilizado para criar uma árvore de decisão.

²(RIPPER) é um algoritmo de extração de regras.

gem proposta é o metaclassificador desenvolvido por ARMAKI et al. (2017). Tal trabalho, porém, foi aplicado a conjuntos de dados de análise de crédito, o que difere da abordagem aqui proposta. Além disso, os dados utilizados, extraídos do repositório da (UCI), não pertenciam a um cenário real. Por fim, o metaclassificador utilizado por ARMAKI et al. (2017) foi um *deep belief networks*, cuja escolha não foi justificada pelos autores. Em nosso trabalho, foram analisados sete metaclassificadores, comparados entre eles e com seis classificadores isolados.

Concluimos que avançamos a literatura pois não foram encontrados trabalhos que aplicassem metaclassificadores baseados em inteligência computacional para prever séries temporais financeiras com as características apresentadas e que ainda utilizassem como validação ativos da Bolsa de Valores de São Paulo.

3 Fundamentação Teórica

Nesta seção serão detalhadas abordagens de fundamental importância para o nosso tema de pesquisa, principalmente conceitos básicos em relação a séries temporais financeiras, mercado financeiro e finanças computacionais. Também serão apresentados os algoritmos utilizados em nosso projeto de metaclassificador.

3.1 Séries Temporais


Uma série temporal é uma coleção de observações feitas sequencialmente ao longo do tempo. Esse tipo de dado tem algumas características particulares, dentre elas a dependência das observações vizinhas. As observações correlacionadas são mais difíceis de analisar e requerem técnicas específicas, sendo necessário levar em conta a ordem temporal das observações. Fatores complicadores, como presença de tendências e variação sazonal ou cíclica, podem ser difíceis de estimar ou remover; além disso, a seleção de modelos pode ser bastante complicada, e as ferramentas podem ser de difícil interpretação BOX & JENKINS (1976).

A grande maioria das já tradicionais técnicas de análise de séries temporais é aplicável em diversas áreas, como economia, astronomia, meteorologia etc. Porém, há uma característica fundamental que distingue a análise de séries temporais financeiras: de outra análise de séries temporais: a teoria financeira e suas séries temporais empíricas contêm um elemento de incerteza. A esse elemento convencionou-se chamar de "volatilidade", que pode ser definida de diversas maneiras, mas que não é claramente observada, já que a volatilidade de um ativo financeiro é o potencial de variação dos retornos e, em geral, é quantificada através do desvio-padrão ou variância da série, conforme TSAY (2005). A Figura 1 mostra um exemplo de série temporal financeira.

3.2 Mercado Financeiro

O mercado financeiro é o local onde podem ser negociados (comprados ou vendidos) bens como valores mobiliários, mercadorias e câmbio. A função do mercado é reunir diversos vendedores em um único lugar, tornando seus produtos acessíveis aos compradores interessados. Mercados são considerados como parte vital de qualquer economia, pois, quanto maior a movimentação

Figura 1: Série de preços



destes, mais oportunidades haverá para que compradores apliquem seus recursos e contribuam para o aquecimento da economia ASSAF NETO (2009).

A bolsa de valores é o ambiente de negociação onde os investidores podem comprar e vender títulos por meio da negociação direta, com auxílio ou não de correspondentes de negociação. No caso da bolsa brasileira, a negociação é feita por meio de corretoras BÚSSOLA DO INVESTIDOR (2017)³. No Brasil, a figura da bolsa de valores é representada pela BOLSA BRASIL BALCÃO (2017), dona de duas bolsas: a BM&F, com foco na negociação de produtos agropecuários e instrumentos financeiros; e a BOVESPA, com foco na negociação em ações e opções de ações.

No mercado acionário, o investidor obtém ganhos comprando ações subvalorizadas e vendendo-as em momentos de maior valorização. O lucro do investimento é determinado pela diferença entre o preço de compra e o preço de venda, somado a benefícios, como os dividendos, e descontadas as taxas referentes à transação BÚSSOLA DO INVESTIDOR (2017).

Normalmente, para prever se uma ação se valorizará ou não, os analistas utilizam dois mecanismos de diagnóstico, a análise fundamentalista ou a análise técnica ANGHEL (2013):

- **Análise fundamentalista:** o investidor tem como referência parâmetros que definem a situação financeira da empresa, como lucro líquido, grau de endividamento e distribuição de dividendos, entre outros. Em síntese, a análise fundamentalista parte do princípio de que as ações têm um valor intrínseco, que corresponderia a um preço justo. Esse preço, por sua vez, seria determinado pelo fluxo de rendimentos auferidos pela ação e efetivamente distribuídos em um dado intervalo de tempo, descontando o valor presente.
- **Análise técnica:** concentra-se em informações referentes ao valor da ação e à movimentação de compra e venda em um determinado período. Esse fato permite projetar uma trajetória ou movimentos oscilatórios prováveis do preço das ações. Dar-se-á maior foco a esta abordagem, uma vez que ela é aplicada no trabalho proposto.

³Instituições financeiras que fazem o intermédio de negociação entre os investidores e a bolsa.

Os investidores que utilizam a análise técnica buscam detectar possíveis tendências, uma vez que a análise técnica assume que estas seguem um padrão cíclico NORONHA (2003). Essa detecção geralmente se dá por meio de padrões gráficos.

Com o passar do tempo, esses padrões gráficos foram traduzidos em indicadores numéricos ou lógicos, que facilitam o processamento automático das séries temporais para a identificação de oportunidades. Geralmente, dividem-se os indicadores de análise técnica em BÚSSOLA DO INVESTIDOR (2017):

- **Indicadores de momento:** normalmente indicam os momentos de entrada ou saída de mercado (exemplo: índice de força relativa, taxa de variação).
- **Indicadores de tendência:** fornecem a direção do mercado - subindo ou descendo (exemplo: médias móveis, índice de direção do movimento, convergência e divergência de médias móveis).
- **Indicadores de volatilidade:** mostram se os preços estão muito voláteis, ou seja, sem tendência definida (exemplo: bandas de *Bollinger*, canal de preço, média de amplitude de variação).
- **Indicadores de volume:** são baseados no fato de que o volume normalmente precede o movimento do preço (exemplo: saldo de volume, oscilador de volume).

Em relação a previsões no mercado financeiro, dada a sua complexidade e dinamismo, há um constante debate quanto à possibilidade de prever mudanças de preços em ações. Segundo DE MOURA (2006), os métodos tradicionais de análise (técnica e fundamentalista) não se mostram capazes de identificar as relações não lineares entre as diversas variáveis que compõem o preço de uma ação e os seus movimentos de alta e baixa, sendo necessário o uso de técnicas mais avançadas.

3.3 Ferramentas e Algoritmos

Durante o desenvolvimento deste trabalho, foi utilizada a ferramenta (Weka), agregando diversas técnicas de inteligência computacional que serão detalhadas nas próximas subseções.

(Weka)

Waikato Environment for Knowledge Analysis (Weka) WITTEN et al. (1999) é uma suíte de mineração de dados muito popular no meio acadêmico. Criada nas dependências da Universidade de Waikato, Nova Zelândia, atualmente é mantida por uma comunidade de entusiastas, por ser um software livre disponível sob licença aberta. A ferramenta tem como objetivo agregar algoritmos provenientes de diferentes abordagens/paradigmas da inteligência computacional.

O (Weka) está implementado na linguagem Java, que tem como principal característica a portabilidade. Desta forma, é possível utilizá-lo em diferentes sistemas operacionais, além de aproveitar os principais benefícios da orientação a objetos. A ferramenta também possui quatro tipos de método de aprendizado, como: agrupamento, associação, predição numérica e classificação. Nosso trabalho tem foco em classificação.

Redes Neurais Artificiais

O algoritmo de redes neurais artificiais WIDROW & HOFF (1960), MC CULLOCH & PITTS (1943), HEBB (1949), ASHBY (1960), WIDROW & HOFF (1962), ROSENBLATT (1958), WERBOS (1994) mais utilizado atualmente é o *multilayer perceptron*, que se baseia na aprendizagem por correção de erros RAMOS (2003). Este algoritmo utiliza um tipo de aprendizado supervisionado; quando o valor de saída é gerado, o erro é calculado e seus valores são retropropagados para entrada, os pesos são ajustados, e os valores são novamente calculados.

Árvore de Decisão (J48) (C4.5)

A árvore de decisão (J48) (C4.5) QUINLAN (1993) é um dos mais clássicos algoritmos de árvore de decisão. Este algoritmo utiliza o método de divisão e conquista para aumentar a capacidade de predição. Assim, sempre usa o melhor passo avaliado localmente, sem se preocupar se esse passo vai produzir a melhor solução. Um problema é dividido em vários subproblemas, sendo criadas subárvores entre a raiz e as folhas.

Máquinas de Vetores de Suporte

As máquinas de vetores de suporte são embasadas pela teoria de aprendizado estatístico, desenvolvida por VAPNIK (1995) a partir de estudos iniciados em VAPNIK & CHERVONENKIS (1971). Esse estudo estabelece uma série de princípios que devem ser seguidos na obtenção de classificadores com boa generalização, que é definida como a capacidade de prever corretamente a classe de novos dados do mesmo domínio em que o aprendizado ocorreu.

Otimização Mínima Sequencial

Proposto por PLATT (1998), o algoritmo de otimização mínima sequencial implementa as máquinas de vetores de suporte e encontra seus vetores resolvendo dois multiplicadores de Lagrange a cada passo. O diferencial da otimização mínima sequencial em relação a outros algoritmos de máquinas de vetores de suporte está em resolver o problema de programação quadrática sem usar métodos numéricos e sem precisar de grande espaço para armazenar uma matriz. O método decompõe o problema em subproblemas e busca resolver o menor problema de otimização possível.

Florestas Aleatórias

Florestas aleatórias (do inglês, *random forest*) é uma técnica de aprendizado de máquina desenvolvida por BREIMAN (2001). Uma floresta aleatória é uma combinação de árvores de decisão em que cada árvore depende dos valores de vetores aleatórios amostrados de forma independente e distribuídos igualmente para todas as árvores na floresta. Nesse método, depois que um determinado número de árvores é gerado, cada uma lança um voto para uma classe do problema, considerando um vetor de entrada. Então, a classe mais votada será escolhida na predição do classificador BREIMAN (2001). Essa técnica permite que se obtenha modelos muito eficazes sem preparação de dados ou conhecimento de modelagem GISLASON et al. (2006).

Redes Bayesianas

Redes *bayesianas* (do inglês, *Bayesian networks*) são modelos de representação do conhecimento que trabalham com o conhecimento incerto e incompleto por meio do teorema de Bayes, publicado pelo matemático em 1763 BAYES (1763) e desenvolvido no início dos anos 1980 por PEARL (1988). Uma rede *bayesianas* também chamada de "rede probabilística" ou "rede causal", pode ser vista como um modelo que utiliza a teoria dos grafos, condições de *Markov* e distribuição de probabilidades para representar uma situação, suas variáveis e estados, e então fazer inferências. A condição de *Markov* afirma que as variáveis não-descendentes não fornecem informações adicionais sobre a variável em questão NEAPOLITAN (2003).

Programação Genética

A programação genética é um método de inteligência computacional que aplica os conceitos da biologia genética, baseados na teoria da seleção natural. Seu paradigma foi desenvolvido por KOZA (1992), com base na técnica de algoritmos genéticos desenvolvida por HOLLAND (1975) e aplicada por GOLDBERG (1989) e BANZHAF et al. (1998). Segundo KOZA (1992), a diferença principal entre algoritmos genéticos e a programação genética está na representação dos indivíduos: enquanto os primeiros codificam os indivíduos em código binário ou real, a segunda codifica os indivíduos na forma de uma árvore. Essa codificação dos indivíduos gera alterações significativas nos operadores genéticos, além de possibilitar grandes benefícios, contendo não somente valores de variáveis, mas também funções.

Multiclassificadores

Sistemas multiclassificadores podem ser definidos como um conjunto de classificadores cujas decisões individuais são combinadas de modo a classificar novas instâncias KUNCHEVA (2004). Entende-se por multiclassificadores: *ensembles*, classificador múltiplo ou comitê.

Estudos como o de DIETTERICH (2000) mostram como multiclassificadores possibilitam um desempenho significativamente superior ao de classificadores individuais. A ideia da multiclassificação é que nenhum método ou sistema pode ser uniformemente superior a outro, e que a integração de diversos métodos individuais melhora o desempenho do classificador final. Em geral, a utilização de multiclassificadores tem a tendência de diminuir a taxa de erro, tornando o classificador final mais preciso DŽEROSKI & ŽENKO (2004). Por esta razão, os métodos inovadores de multiclassificação têm sido cada vez mais pesquisados TAN & GILBERT (2003).


O bom desempenho do sistema baseado em múltiplos classificadores depende dos elementos do conjunto, ou seja, dos componentes do sistema. Um dos problemas citados por HO (2001) é o desafio em recursos computacionais em termos de treinamento.

O conjunto de multiclassificadores pode ser homogêneo ou heterogêneo. No caso de sistemas baseados em múltiplos classificadores homogêneos, são utilizadas as mesmas técnicas para gerar todos os classificadores, com variação de alguns parâmetros do modelo, como o vetor de características. São exemplos: *bagging* por BREIMAN (1996) e *boosting* por SCHAPIRE (1990).

Os sistemas baseados em múltiplos classificadores heterogêneos utilizam algoritmos de aprendizado diferentes para gerar uma combinação. Alguns métodos que se destacam são listados a seguir: *stacking* WOLPERT (1992) e *stackingC* SEEWALD (2002). Iremos detalhar um pouco mais estes dois métodos, uma vez que possuem maior relação com o nosso trabalho:

- **Stacking:** também conhecido em inglês como *stacked generalization* ("generalização empilhada"), considera que um classificador é mais confiável que outro. O método *stacking* tenta aprender qual é o classificador mais confiável e qual a melhor maneira para combinar as suas saídas. *stacking* combina a saída de vários classificadores, que são formados por diferentes algoritmos de aprendizado de máquina, e estas saídas são combinadas por um metaclassificador que gera as saídas com um melhor desempenho. A Figura 2 ilustra a representação deste algoritmo.
- **StackingC:** é uma variação do algoritmo *stacking*. O método *stackingC* (*stacking with Confidences*) remove os atributos que não são relevantes e reduz a dimensão da base de dados antes de utilizá-la como entrada para o metaclassificador. No algoritmo *stackingC*, durante o treinamento e o teste, utiliza-se somente a distribuição parcial de probabilidade da classe associada a cada modelo linear. Quando a base de dados tem atributos irrelevantes, tende a ser melhor que o *stacking* em termos de precisão e de tempo de treinamento.

Figura 2: Representação do algoritmo *stacking*



Embora desenvolvido há alguns anos, o *stacking* e sua variação são menos utilizados do que *bagging* e *boosting*; em parte porque é difícil analisá-lo teoricamente e também porque não há um padrão de algoritmo para implementá-lo. A sua ideia básica pode ser aplicada em muitas variações diferentes. Resumindo, o algoritmo *stacking* tem dificuldades para definir qual metaclassificador é mais apropriado, e quais e quantos classificadores-base devem ser utilizados WITTEN & FRANK (2005). WOLPERT (1992) denomina esta característica como *black art*.

Outros trabalhos na literatura, como o de CAFFÉ et al. (2012), utilizam um número variável de algoritmos-base e, para gerar o metaclassificador, utilizam o algoritmo *naive Bayes* HAND & YU (2001). Visto que, além de simples,

naive Bayes é conhecido por ganhar de métodos de classificação altamente sofisticados, DŽEROSKI & ŽENKO (2004) também recomendam a utilização de algoritmos simples para compor o metaclassificador.

Métricas de Avaliação

Nesta seção serão apresentadas as métricas de avaliação de desempenho dos modelos de inteligência computacional e as métricas de avaliação de risco das estratégias de negociação.

Medidas de Desempenho

As medidas de desempenho têm o objetivo de avaliar a qualidade dos classificadores (preditores) com base em modelos de aprendizado de máquina, sendo constituídas de fórmulas matemáticas e estatísticas ZHANG & ZHOU (2014). Com as predições dos classificadores, é possível extrair a matriz de confusão e gerar as métricas de desempenho e risco.

A matriz de confusão é frequentemente utilizada para organizar e exibir informações que avaliam o desempenho de um algoritmo. Cada coluna da matriz representa as instâncias de uma classe prevista, enquanto cada linha representa os casos em uma classe real. Verdadeiros positivos são exemplos rotulados corretamente como positivos, falsos positivos referem-se a exemplos negativos incorretamente rotulados como positivos; verdadeiros negativos correspondem a negativos rotulados corretamente como negativos e falsos negativos referem-se a exemplos positivos incorretamente rotulados como negativos DAVIS & GOADRIC (2006). A Figura 3 ilustra a matriz de confusão para duas classes.

Figura 3: Matriz de confusão

		Valor Previsto		Total
		p	n	
Valor Real	p'	Verdadeiro Positivo	Falso Negativo	p'
	n'	Falso Positivo	Verdadeiro Negativo	N'
Total		P	N	

As métricas mais utilizadas são a acurácia, a revocação, a precisão, o *F1-score* e a especificidade, detalhadas a seguir:

- **Acurácia:** é a quantidade de amostras positivas e negativas classificadas corretamente dividida pelo total de amostras da série avaliada em percentual, representada pela Equação (1).

$$acuracia = \frac{VP + VN}{VP + FP + VN + FN} \quad (1)$$

- **Precisão:** é a quantidade de amostras positivas classificadas corretamente sobre o total de amostras classificadas como falsas positivas, acrescida das amostras positivas em percentual, representada pela Equação (2).

$$precisao = \frac{VP}{VP + FP} \quad (2)$$

- **Revocação:** é a quantidade de amostras positivas (VP) classificadas corretamente sobre o total de amostras classificadas como falsas negativas mais (VP) em percentual, representada pela Equação (3).

$$revocacao = \frac{VP}{VP + FN} \quad (3)$$

- **F1-score:** é a média harmônica entre a precisão e a revocação, representada pela Equação (4).

$$F1 - score = \frac{2 * precisao * revocacao}{precisao + revocacao} \quad (4)$$

Além das métricas de performance já apresentadas, foram utilizadas também algumas métricas financeiras para a análise dos resultados, visto que em problemas de investimento é importante validar modelos do ponto de vista financeiro, pois estes nem sempre se correlacionam com a qualidade preditiva do modelo. Assim, entende-se que, por vezes, modelos com precisão baixa são capazes de apresentar lucros superiores, desde que sejam capazes de detectar mudanças mais agudas nos preços.

Medidas Financeiras

As métricas financeiras utilizadas serão: o retorno financeiro, o ganho médio, a perda média, e a quantidade de gatilhos de ganho e gatilhos de perda. Também serão apresentadas algumas medidas de risco, que têm a finalidade de avaliar o risco versus o retorno das estratégias de negociação A ERNST (2014) e VARGA (2001) utilizando os indicadores: volatilidade e índice *Sharpe*.

- **Retorno financeiro:** é o percentual de ganho financeiro de um ativo durante um período.
- **Ganho médio:** é o percentual médio de ganho por gatilho.
- **Perda média:** é o percentual médio de perda por gatilho.
- **Volatilidade:** é a medida da taxa de variação de um ativo em um determinado período de tempo, ou seja, é quanto este ativo variou em porcentagem nesse período de tempo. Em resumo, é o desvio-padrão dos retornos dos ativos, conforme a Equação (5).

$$DP = \sqrt{\frac{\sum |x - \bar{x}|^2}{n}} \quad (5)$$

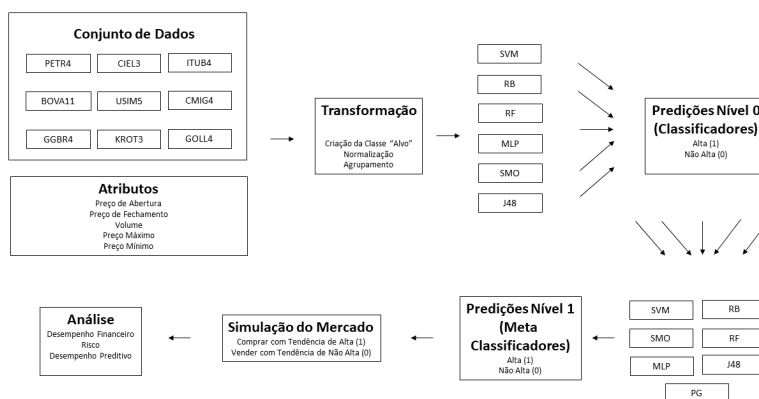
- **Índice Sharpe:** é uma medida de eficiência da relação do risco versus retorno, ou seja, quanto maior é o valor do índice *Sharpe*, mais eficiente é o retorno financeiro (RF) encontrado na estratégia de operação. Para o cálculo deste índice, é subtraído do (RF) o valor da taxa do Certificado de Depósitos Interbancários (CDI)⁴ do período avaliado, e o resultado é dividido pela volatilidade, conforme a Equação (6).

$$\text{Sharpe} = \frac{RF - \text{CDI}}{\text{Volatilidade}} \quad (6)$$

4 Metodologia

Esta seção descreve o método proposto para prever tendências em séries temporais financeiras. Resumidamente, as etapas da metodologia são: a) coleta dos conjuntos de dados históricos de ativos de bolsa de valores da Bolsa de Valores de São Paulo; b) tratamento dos dados; c) treinamento dos classificadores e metaclassificadores; e d) simulação do mercado e análise dos resultados. A Figura 4 ilustra a metodologia proposta.

Figura 4: Metodologia proposta



4.1 Coleta de Dados

Para a coleta das séries temporais financeiras foi utilizado o software *MetaTrader*. METATRADER (2017), que realiza negociações *on-line*, faz análise técnica e utiliza sistemas de *trading* automatizados nos mercados financeiros. O *MetaTrader 5* possui um conjunto de indicadores técnicos que cobrem a maioria das necessidades do *trader* moderno e tem acesso a todo o histórico de cotizações do instrumento financeiro (moedas e ações). O ambiente de desenvolvimento possui como linguagem o *MetaQuotes Language* (MQL), possui diversas funcionalidades e, além disso, é amigável para os desenvolvedores METATRADER (2017). As suas vantagens incluem: uma arquitetura orientada a objetos,

⁴Certificado de Depósitos Interbancários é um valor médio dos juros praticados entre os bancos e serve como uma referência para a economia.

maior velocidade de cálculo, e uma sintaxe semelhante à da linguagem de programação C++ STROUSTRUP (2000).


Assim, foi desenvolvido um código, ou *script* (MQL), capaz de capturar os *candles* dos ativos a serem avaliados. Um *script* (MQL) é um programa destinado a uma execução única de qualquer ação. Estes programas também têm acesso a todas as funções analíticas e de negociação. Este *script* possibilita a extração de *candles* de granularidade diária. Os dados extraídos contêm os preços de abertura, fechamento, máximo, mínimo e o volume negociado.

4.2 Pré-Processamento

Séries temporais de preços de ações são sujeitas a uma quantidade considerável de ruído e variação aleatória, o que dificulta a tarefa de previsão. A Figura 1 mostra uma série de preços com nível alto de ruídos.

Segundo TSAY (2005), a maioria dos estudos financeiros, ao invés de utilizar os preços dos ativos, opta por utilizar os retornos financeiros gerados, justificando de dois modos essa utilização: primeiro, as informações de retorno atendem aos interesses de investidores; segundo, as séries de retorno são mais fáceis de manusear do que a série de preços porque possuem propriedades estatísticas mais atraentes. A Figura 5 ilustra uma série de retornos financeiros.

Figura 5: Série de retornos financeiros



THORSTENSEN (1976) atribui a preferência por trabalhar com retornos calculados à diferença dos logaritmos dos ativos, pois a variação no logaritmo do preço pode ser considerada como rendimento produzido pelo ativo em uma capitalização contínua, ao se manter o ativo por um dia; o uso do logaritmo anula o efeito dos níveis de preço, além de produzir uma distribuição estacionária e, para variações menores do que 15%, a variação dos logaritmos dos preços está muito próxima da variação percentual.

Após a coleta dos dados, houve duas etapas de tratamento dos dados. Na primeira, transformamos a série de preços em série de retorno *log*; a Equação (7) mostra este cálculo. A segunda visa retirar os ruídos (*outliers*). Normalizamos a série subtraindo de cada observação a sua média e dividindo pelo seu desvio-padrão, produzindo o *z-score* (Equação (8)), e colocando todos os dados em uma mesma escala.

$$\text{retorno}_{\log} = \log(p_i) - \log(p_{i-1}) \quad (7)$$

$$z = \frac{x - \mu}{\sigma} \quad (8)$$

Conforme apresentado, as séries temporais financeiras passam por constantes mudanças, e seu comportamento é muito influenciado por fatores externos de toda espécie (por exemplo, políticos, locais, ou macroeconômicos); por isso, dificilmente modelos serão capazes de generalizar tal comportamento. Prima-se, portanto, pelo uso de dados recentes na modelagem. Assim, utilizamos o conceito de janela deslizante, segundo o qual a massa de dados de treinamento e teste se move conforme o tempo.

4.3 Classificação e Técnicas de Aprendizado

O metaclassificador proposto (Algoritmo 6) possui em seu conjunto de classificadores seis técnicas de aprendizado de máquina como entrada do algoritmo, a saber: florestas aleatórias (RF), máquinas de vetor de suporte (SVM), redes neurais (MLP), árvore de decisão (J48), otimização mínima sequencial (SMO), e redes *bayesianas* (BN).

A primeira etapa do algoritmo consistiu em trabalhar os dados. Através de testes preliminares mostrou-se que o *candle* puro (somente com dados de preço), ou seja, sem tratamento, não possui informação que possa contribuir para que os classificadores tenham boa performance. Assim, foi proposta uma fase de qualificação dos dados denominada "etapa de pré-processamento".

No próximo passo, cada classificador isolado é treinado utilizando o conjunto de dados *A*.

Uma vez que todos os modelos tenham sido treinados, aplicam-se os conjuntos *B* e *C* nos modelos, gerando assim dois novos conjuntos *B'* e *C'*. Esses conjuntos serão compostos de previsões de cada técnica, gerando cada matriz de 1 (alta) e 0 (não alta).

O próximo passo é treinar novamente todas as técnicas já citadas, mais a programação genética, utilizando o conjunto *B'* e testando no conjunto *C'*, formando assim nosso conjunto de metaclassificações.

4.4 Simulação do Mercado

Foi desenvolvido um módulo capaz de avaliar a qualidade das estratégias de negociação do tipo *swing trade*⁵. Outra característica do sistema de negociação desenvolvido é a granularidade, uma vez que foram utilizados *candles* diários. A proposta é simples, comprar com previsão de alta e vender com previsão de não alta.

Para maior clareza do funcionamento básico da abordagem, segue o pseudocódigo da estratégia no Algoritmo 6.

4.5 Análise dos Resultados

A etapa da análise de resultados apresenta três análises distintas, consolidadas para cada código de ativo avaliado: análise de estatísticas, de desempenho, e de operação/risco.

⁵É um método de investimento em que as suas aplicações se iniciam e se encerram em poucos dias ou semanas. O objetivo é aproveitar as variações de preços dos ativos negociados no curto prazo.

Figura 6: Algoritmo 1 - Metaclassificador

Entrada: Lista de *candles*, Vetor de *classificadores*, *A*, *B*, *C*
Saída: *ListaMetaPredicoes*
início

```

para i < classificadores.size() faça
    para j < candles.size() faça
        candles ← preprocessamento(candles);
        A ← candles.get(j, A.size());
        B ← candles.get(j + A.size(), B.size());
        C ← candles.get(j + A.size() + B.size(), C.size());
        modelo ← treinar(classificadores[i], A);
        B' ← classificar(modelo, B);
        C' ← classificar(modelo, C);
        metaModelo ← treinar(classificadores[i], B');
        metaPredicoes ← classificar(metaModelo, C');
        ListaMetaPredicoes.add(metaPredicoes);
        j ← j + A.size() + B.size() + C.size();
    fim
fim
retorna ListaMetaPredicoes

```

Figura 7: Algoritmo 2 - Pseudocódigo da estratégia “sem stops”

Entrada: *ListaMetaPredicoes*, Lista de *candles*, Vetor de *classificadores*
Saída: Arquivo *LogOperacao* de todos os meta-classificadores.
posicao ← *vendido*;
início

```

para i < classificadores.size() faça
    sinaisPredicao ← obterPredicoes(classificadores.get(i));
    para j < sinaisPredicao faça
        se posicao = vendido então
            se sinaisPredicao[j] = 1 então
                comprar (candles.getPrecoFechamento(D + 1));
                posicao ← comprado;
            fim
        fim
        senão
            se sinaisPredicao[j] = 0 então
                vender (candles.getPrecoFechamento(D + 1));
                posicao ← vendido;
            fim
        fim
        calcular(LogOperacao[i, j]);
    fim
    gravar (LogOperacao[i, j]);
fim
retorna LogOperacao

```

A análise estatística apresenta a caracterização da amostra de cada código de ativo e é composta pela distribuição dos dados em relação aos períodos de treino e teste da série temporal avaliada, contemplando os seguintes indicadores:

- quantidades de dias avaliados da série;
- preço inicial do código de ativo;
- preço final do código de ativo; e
- percentual de dias em que ocorreram altas e não altas.

A análise de desempenho avalia os modelos de aprendizado de máquina através das métricas com a finalidade de medir as taxas de desempenho dos modelos de previsão (classificadores) durante a simulação realizada:

- **Acurácia** (Equação (1));
- **Precisão** (Equação (2));
- **Revocação** (Equação (3));
- **F1-score** (Equação (4)); e

Para análise financeira foram utilizadas as seguintes métricas:

- **Percentuais de:** dias positivos, dias negativos, perda, ganho e retorno total;
- **Índice Sharpe:** avalia a rentabilidade e o risco de um investimento, sendo fundamental para mensurar o quanto de retorno excedente em relação a um ativo livre de risco é compensado através de seu nível de risco.
- **Drawdown:** é o percentual de queda a partir do ponto máximo de retorno financeiro cumulativo, *drawdown* máximo é o percentual máximo de queda em uma determinada série de dados.

Todas as métricas, sejam elas de performance ou financeiras, são comparadas entre os classificadores isolados, os metaclassificadores, alguns *baselines* e *benchmarks* do período.

Dentre os *baselines* estão:

- **Buy-and-hold:** assumir posição de compra no período t_1 e fechar a posição em t_n .
- **Random:** modelo que sorteia a operação de compra ou venda aleatoriamente.
- **Estratégia inversa:** operar realizando a ação contrária ao que o modelo previsor indica.

Já os *benchmarks* são:

- **Certificados de Depósitos Interbancários (CDI):** é uma média dos juros praticados entre os bancos e serve como uma referência para o preço do dinheiro na economia, pois é utilizada como *benchmark* em muitos investimentos ELEVEN FINANCIAL (2017);
- **Índice Geral de Preços do Mercado (IGP-M):** é o indicador de movimento dos preços calculado mensalmente pela Fundação Getúlio Vargas e divulgado no final de cada mês de referência, sendo utilizado para o reajuste dos aumentos da energia elétrica e dos contratos de aluguel ADVFN (2010);
- **Dólar:** é a moeda oficial dos Estados Unidos e utilizada no mundo inteiro, tanto em reservas internacionais, como em livre circulação em alguns países.

Combinando algoritmos de aprendizado de máquina, o propósito desta etapa é avaliar a viabilidade e o grau de risco de investimento das estratégias de operação, bem como a possibilidade de aplicar estas estratégias em um cenário real no mercado financeiro.

5 Experimentos e Resultados

Como visto anteriormente, neste trabalho investiga-se o uso de metaclassificadores para a previsão de séries temporais financeiras. Nesta seção serão apresentados os conjuntos de dados, as parametrizações utilizadas na instânciação dos testes e, por fim, os resultados. Para a aplicação e validação da metodologia, foram utilizados nove conjuntos de dados históricos da Bolsa de Valores de São Paulo.

Os códigos de ativos analisados nos experimentos são de empresas que compõem o Índice Bovespa (Ibovespa). Esses ativos foram escolhidos por possuírem uma maior representatividade em relação ao volume negociado, representando diferentes setores da economia, como petróleo e gás, mineração, bancos, siderurgia, aviação e educação:

- **Petrobrás (PETR4):** ações da Petróleo Brasileiro S.A. A empresa de capital aberto cujo acionista majoritário é o Governo Federal, sendo, portanto, uma empresa estatal de economia mista⁶.
- **Cielo (CIEL3):** ações da Cielo (antiga Visanet Brasil), empresa brasileira que atua como adquirente multibandeira. É uma das responsáveis pela captura, transmissão e liquidação financeira de transações com cartões de crédito e débito⁷.
- **Itaú Unibanco (ITUB4):** ações da empresa Itaú Unibanco, banco brasileiro fundado em 4 de novembro de 2008 mediante a fusão de duas das maiores instituições financeiras do país, o *holding* Itaú Bancos e Unibanco⁸.

⁶<http://www.petrobras.com.br/>

⁷<http://www.cielo.com.br/>

⁸<http://www.itau.com.br/>

- **Índice Bovespa (BOVA11)**: o objetivo do fundo é obter uma performance próxima à do próprio Índice Bovespa. Vários investidores unidos investem nesse fundo, que utiliza todo o recurso para comprar ações exatamente nas mesmas proporções do índice.
- **Usiminas (USIM5)**: empresa do setor siderúrgico, líder na produção e comercialização de aços planos laminados a frio e a quente, bobinas, placas e revestidos, destinados principalmente aos setores de bens de capital e bens de consumo da linha branca, além da indústria automotiva⁹.
- **Companhia Energética de Minas Gerais (CMIG4)**: uma das principais concessionárias de energia elétrica do Brasil. Tem sede na cidade de Belo Horizonte, capital do estado de Minas Gerais¹⁰.
- **Gerdau (GGBR4)**: também referida como Grupo Gerdau, é uma empresa siderúrgica brasileira regida sob a forma jurídica de sociedade anônima. Possui operações industriais em 11 países nas Américas, na Europa e na Ásia, as quais somam uma capacidade instalada superior a 25 milhões de toneladas de aço bruto por ano¹¹.
- **Kroton Educacional (KROT3)**: a maior empresa privada do mundo no ramo da educação. É a maior empresa brasileira no segmento de ensino superior para o número de alunos e de receita¹².
- **Gol Linhas Aéreas Inteligentes (GOLL4)**: maior companhia aérea do Brasil em número de passageiros, tendo 36% de participação do mercado doméstico¹³.

Além dos experimentos mencionados nesta seção, foram realizados diversos outros, utilizando configurações e parametrizações diferentes nos algoritmos, com o intuito de testar diferentes variantes até chegar ao modelo atual, que é resultado da melhor configuração encontrada.

5.1 Caracterização e Análise dos Dados

Foram coletados dados de *candles* diários de agosto de 2015 a agosto de 2016. A Tabela 2 detalha informações de preço dos ativos utilizados. A Figura 8 mostra a evolução dos preços durante este período. Em geral, as séries de preços apresentam uma alta volatilidade. É interessante observar que em quase todos os ativos, entre o 100º dia e o 150º dia da série, houve pontos de menor preço. Segundo Almeida (2016), este fato aconteceu devido ao caos político e econômico, que fez o país perder a confiança dos investidores nacionais e internacionais.

Avaliando a proporção das classes (Figura 9), é possível verificar que a distribuição é bastante balanceada para os ativos selecionados. Na maioria dos casos, o número de instâncias de classe de alta é ligeiramente superior ao de não alta.

⁹<http://www.usiminas.com.br/>

¹⁰<http://www.cemig.com.br/>

¹¹<http://www.gerdau.com.br/>

¹²<http://www.kroton.com.br/>

¹³<http://www.voegol.com.br/>

Figura 8: Série de preços de fechamento original

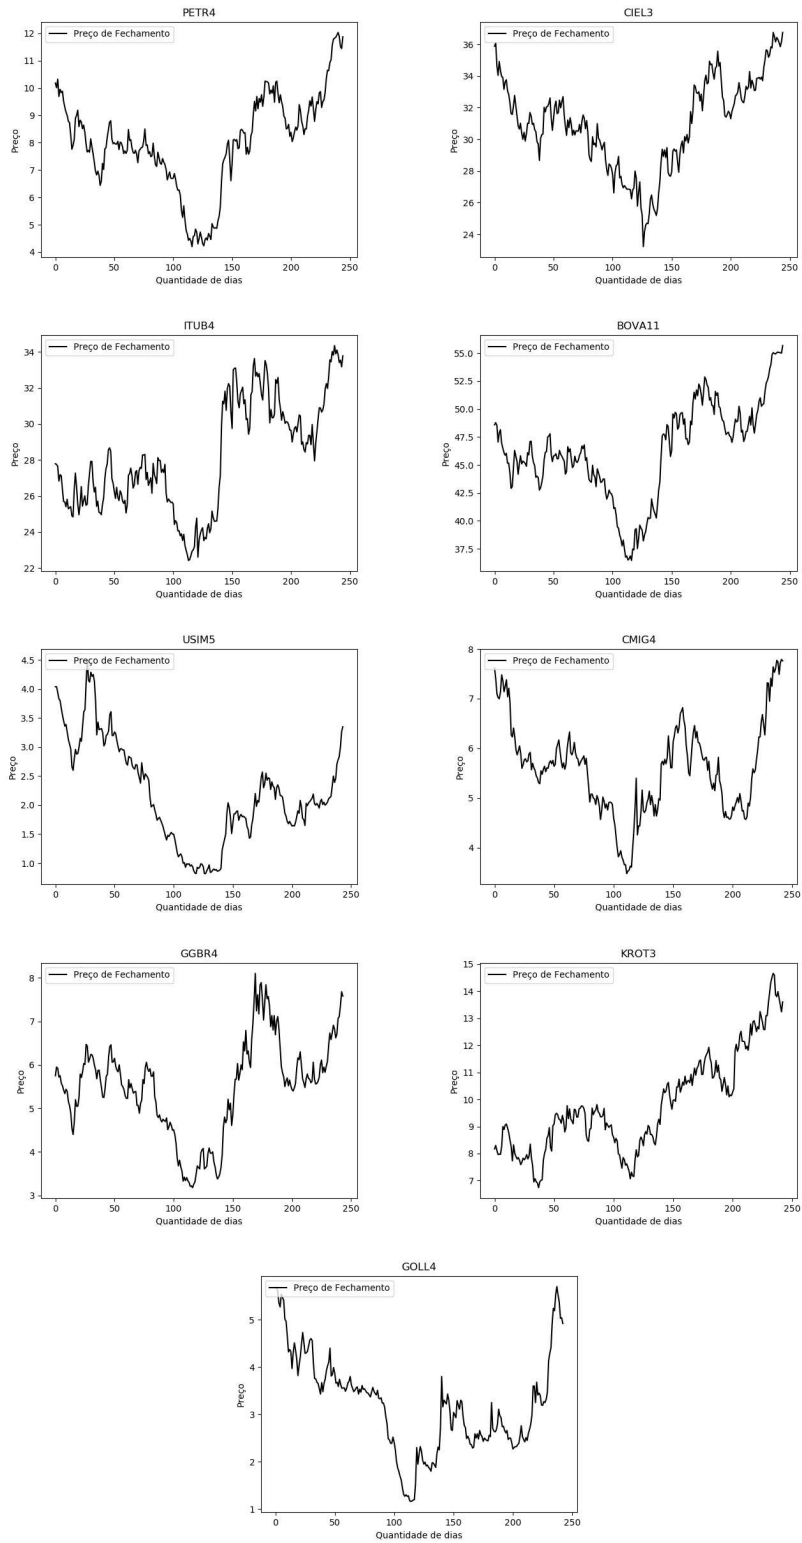



Tabela 2: Valor de mercado de ativos entre agosto de 2015 e agosto de 2016

Ativo	Quantidade de Dias	Preço Inicial	Preço Final	% Não Alta	% Alta
PETR4	244	R\$ 10,18	R\$ 11,87	47%	53%
CIEL3	244	R\$ 35,88	R\$ 36,75	50%	50%
ITUB4	244	R\$ 27,79	R\$ 33,78	48%	52%
BOVA11	244	R\$ 48,59	R\$ 55,68	49%	51%
USIM5	244	R\$ 4,04	R\$ 3,35	53%	47%
CMIG4	244	R\$ 7,62	R\$ 7,76	50%	50%
GGBR4	244	R\$ 5,75	R\$ 7,58	49%	51%
KROT3	244	R\$ 8,17	R\$ 13,61	49%	51%
GOLL4	244	R\$ 5,67	R\$ 4,92	58%	42%

Figura 9: Distribuição das classes por ativo

Com o intuito de comparar os resultados financeiros, também foram coletados alguns indicadores de mercado (*benchmarks*). A Tabela 3 apresenta os *benchmarks* do período avaliado, contendo: CDI, IGP-M, dólar e ouro.

Tabela 3: *Benchmarks*

CDI	IGP-M	Dólar	Ouro
19,27%	11,60%	29,70%	17,83%

5.2 Instanciação dos Algoritmos

Para executar a solução proposta, foi necessário instanciar todos os classificadores e o metaclassificador. Os algoritmos (SVM), (RF), (MLP), (J48), (SMO) e (BN) foram utilizados com a parametrização-padrão do (Weka).

Para a programação genética, foram aplicados os seguintes parâmetros: tamanho da população de 500 indivíduos, seleção por torneio. Os operadores genéticos de cruzamento e mutação apresentaram taxas de 85% e 15%, respectivamente. Os nós não terminais foram formados pelo operador *AND* e na função de *fitness* utilizamos a acurácia.

Após várias simulações com alternância de diversos parâmetros com o objetivo de melhorar a performance do arcabouço, os dados foram calibrados de acordo com a Tabela 4, onde a coluna “Resultado” apresenta a configuração final utilizada nos experimentos. Foram realizadas 30 execuções por ativo.

Em resumo, o metaclassificador foi inicializado com os sete algoritmos já citados. Os conjuntos de treinamento e testes foram divididos em três subconjuntos em uma janela deslizante: o conjunto *A* tem tamanho de 20 *candles*; o conjunto *B*, de 10; e o conjunto *C*, também 10.

Para as estratégias de negociação, aquelas que possuem *stops*, utilizamos os percentuais de 2% e 3% para *gain* e *loss*, respectivamente.

Tabela 4: Intervalo de parâmetros de calibração do metaclassificador

Parâmetros	Variação	Resultado
Quantidade de conjuntos	[2; 3]	3
Conjunto A	[5; 50]	20
Conjunto B	[5; 50]	10
Conjunto C	[1; 30]	10
<i>Stop Loss</i>	[1; 5]	2%
<i>Stop Gain</i>	[1; 5]	3%
Estratégia	[1; 7]	1

5.3 Avaliação dos Modelos e Estratégias

Diante do grande volume de informações, é muito importante selecionar os resultados de quais modelos e de quais estratégias apresentar. Desta forma,

após a calibração dos parâmetros do metaclassificador e sua execução, os resultados gerados como saída do arcabouço são a combinação dos seguintes dados:

- Ativos: nove ativos da Bolsa de Valores de São Paulo;
- Modelos: treze modelos preditivos (seis classificadores isolados + sete metaclassificadores);
- Estratégias: sete estratégias de simulação do mercado;
- Medidas: onze medidas de desempenho.

Assim, através da Equação (9), é possível apresentar a quantidade total de indicadores gerados para avaliar os resultados. Neste caso, são gerados 9009 indicadores, o que torna a análise impraticável caso não sejam definidos critérios e filtros de avaliação.

$$\text{indicadores} = \text{ativos} \times \text{modelos} \times \text{estrategias} \times \text{medidas} \quad (9)$$

Para filtrar e diminuir as possibilidades de combinações com os modelos de previsão de tendências propostos na apresentação dos resultados, foram definidos quatro filtros macro:

- **Estratégia:** o objetivo deste filtro é utilizar a melhor estratégia de simulação do mercado do arcabouço.
- **Percentual médio de retorno financeiro:** entre todas as informações de um investimento, uma das mais relevantes para qualquer investidor é o retorno financeiro. Este filtro tem como objetivo selecionar os modelos que possuem percentual positivo médio de retorno para todos os ativos e com retornos financeiros superiores ao CDI, IGP-M, dólar e ouro, conforme a Tabela 3
- **Acurácia média:** este filtro permite selecionar os modelos que apresentem resultados de acurácia acima dos 50%. Esta métrica foi utilizada como filtro, pois as estratégias de simulação apresentadas utilizam os sinais de compra e venda dos modelos, ou seja, é necessário utilizar a predição tanto de “alta” quanto de “não alta”. Além disso, os conjuntos de dados utilizados são balanceados, o que permite utilizar esta medida como desempenho geral do modelo.
- **Percentual médio de retorno financeiro entre o melhor classificador isolado e o melhor metaclassificador:** o intuito deste critério é demonstrar e selecionar o melhor classificador isolado e o melhor metaclassificador com o objetivo de explorar e aprofundar com mais detalhes apenas os resultados deste filtro.

A Tabela 5 apresenta os resultados simulados de retorno financeiro de todos os modelos para todos os ativos. Os resultados foram agrupados por classificador com o intuito de facilitar a visualização. Cada classificador possui também um metaclassificador, com exceção da programação genética, cujos resultados podem ser visualizados na Tabela 7.

Com o objetivo de facilitar também a identificação do melhor modelo para cada ativo entre os grupos, as colunas com melhor resultado por ativo foram destacadas em negrito; e para identificar o melhor modelo entre todos os ativos, a coluna com o melhor modelo foi sublinhada. A Tabela 6 apresenta os resultados de acurácia com as mesmas características de visualização, porém, neste caso, os resultados sublinhados são aqueles superiores a 50% de acordo com o filtro definido na etapa de seleção dos classificadores.

Ao verificar individualmente os resultados de cada ativo, é visivelmente clara certa superioridade em retornos financeiros dos metaclassificadores em grande parte dos ativos. Outro resultado interessante é que os metaclassificadores são superiores em todos os retornos financeiros médios. Também é possível visualizar o mesmo comportamento na acurácia.

Após a apresentação destes resultados, foi realizada cada etapa dos filtros elaborados. O primeiro filtro foi definido durante a etapa de calibragem do arcabouço; assim, identificou-se que, apesar de sua simplicidade, a Estratégia 1 demonstrou melhores retornos financeiros em todos os ativos quando comparada às demais estratégias. O segundo filtro mostrou-se arrojado e proporcionou uma seleção rigorosa; foram selecionados somente os modelos com percentuais de retorno financeiro positivos e com retornos acima dos índices de mercado CDI, IGP-M, ouro, dólar. Foram selecionados todos os metaclassificadores e apenas um classificador isolado, no caso, a (MLP) com retorno financeiro médio de 30,87% no período. Ao aplicar o quarto filtro, temos como resultado os melhores modelos de cada grupo. Representando os classificadores isolados, selecionou-se a (MLP); e representando os metaclassificadores, o (Meta-RF) obteve melhor performance. A Tabela 8 compara os resultados desse último filtro.

Com a execução dos filtros, o objetivo de trabalhar com um conjunto de resultados reduzido foi cumprido, sem perder informação e qualidade para uma análise mais criteriosa dos resultados. Nas próximas seções serão apresentados de forma mais substancial e com mais profundidade os resultados desses dois modelos selecionados.

5.4 Avaliação da Viabilidade dos Custos Operacionais

Na simulação de estratégias de negociação, um ponto muito importante são os custos operacionais, visto que um modelo de previsão pode até ter retornos financeiros positivos. Porém, caso o custo operacional seja maior do que o ganho bruto, toda uma estratégia de operação pode ser inviabilizada.

Assim, para todas as simulações realizadas neste trabalho foram contabilizados os custos das operações, contemplando o Imposto de Renda recolhido na fonte pela Bovespa, o Imposto de Renda recolhido pelo investidor sobre o lucro, a taxa de corretagem sobre as ordens de compra e venda, o Imposto Sobre Serviços sobre o valor da taxa de corretagem e os emolumentos sobre o valor investido. Devido ao fato de muitas corretoras isentarem seus clientes da taxa de custódia, esta não foi acrescentada nos custos das transações.

A Tabela 9 apresenta os custos operacionais de forma detalhada, acrescidos de três exemplos de lucro bruto (R\$100,00, R\$1.000,00 e R\$10.000,00), o que torna evidente o fato de que, quanto maior for o valor investido, menor será o custo operacional relativo, com exceção da tributação do Imposto de Renda, que é um valor fixo de 20,00% sobre o ganho de capital para transações de

Tabela 5: Comparação de retorno financeiro entre pares de classificadores e metaclassificadores

Algoritmo	BOVA11	CIEL3	ITUB4	PETR4	USIM5	CMIG4	GGBR4	KROT3	GOLL4	Média
SVM	-6,42%	7,69%	27,31%	-9,82%	14,53%	12,19%	29,00%	47,52%	-3,03%	13,22%
Meta-SVM	58,89%	35,41%	45,74%	28,47%	74,23%	49,63%	61,41%	37,97%	67,28%	51,00%
RF	-5,14%	-1,60%	15,17%	13,24%	71,17%	33,82%	32,19%	84,54%	-12,15%	25,70%
Meta-RF	29,24%	41,23%	56,42%	55,49%	139,84%	86,38%	50,22%	60,93%	57,24%	64,11%
MLP	3,78%	-12,02%	7,29%	21,58%	79,01%	0,84%	17,55%	64,78%	71,13%	28,21%
Meta-MLP	18,67%	30,77%	37,28%	48,37%	90,77%	31,38%	-3,90%	23,07%	37,22%	34,85%
J48	-2,78%	-26,92%	27,15%	42,79%	74,09%	53,46%	9,30%	10,78%	17,00%	22,77%
Meta-J48	19,85%	25,98%	47,74%	17,43%	138,73%	9,04%	34,23%	26,10%	128,42%	49,73%
SMO	5,57%	9,36%	34,81%	16,51%	19,98%	15,17%	26,07%	25,98%	-5,85%	16,40%
Meta-SMO	22,24%	34,28%	32,00%	21,13%	165,00%	55,62%	13,89%	95,32%	79,99%	57,72%
BN	-11,18%	-6,22%	42,16%	-5,57%	35,80%	-6,79%	37,78%	47,20%	15,65%	16,54%
Meta-BN	17,58%	55,06%	19,65%	11,52%	48,74%	17,38%	33,97%	28,60%	70,06%	33,62%

Tabela 6: Comparação da acurácia dos modelos preditivos

Algoritmo	Acurácia									Média
	BOVA11	CIEL3	ITUB4	PETR4	USIM5	CMIG4	GGBR4	KROT3	GOLL4	
SVM	47,50%	45,00%	45,50%	48,50%	52,00%	49,00%	51,50%	53,00%	56,50%	49,83%
RF	44,00%	43,00%	50,50%	55,50%	57,50%	47,50%	53,00%	54,00%	53,50%	50,94%
MLP	45,00%	44,50%	51,00%	54,50%	55,00%	49,00%	50,00%	56,50%	52,00%	50,83%
J48	44,50%	42,50%	51,50%	49,50%	51,00%	46,00%	47,00%	47,50%	55,00%	48,28%
SMO	49,50%	48,50%	50,00%	54,50%	52,50%	50,00%	51,00%	49,50%	52,00%	50,83%
BN	45,00%	44,50%	50,50%	50,50%	51,50%	51,00%	52,50%	51,50%	57,00%	50,44%
Meta-GP	56,60%	51,22%	46,92%	48,30%	50,98%	49,74%	49,79%	53,71%	57,84%	51,68%
Meta-SVM	56,00%	54,00%	51,50%	50,50%	56,50%	53,50%	54,00%	56,00%	57,00%	54,33%
Meta-RF	56,50%	53,00%	53,50%	48,00%	56,50%	54,00%	53,50%	56,00%	53,50%	53,83%
Meta-MLP	50,50%	51,00%	51,50%	51,00%	54,50%	53,50%	50,00%	52,00%	52,00%	51,78%
Meta-J48	49,50%	50,50%	53,50%	47,50%	55,00%	50,00%	52,00%	54,50%	58,00%	52,28%
Meta-SMO	49,00%	52,00%	50,00%	56,50%	58,00%	54,00%	50,00%	56,50%	54,50%	53,39%
Meta-BN	47,00%	55,00%	49,00%	55,50%	56,00%	47,00%	49,50%	53,50%	57,00%	52,17%

Tabela 7: Comparação de retorno financeiro entre melhor classificador com Meta-GP

Algoritmo	BOVA11	CIEL3	ITUB4	PETR4	USIM5	CMIG4	GGBR4	KROT3	GOLL4	Média
MLP	3,78%	-12,02%	7,29%	21,58%	79,01%	0,84%	17,55%	64,78%	71,13%	28,21%
Meta-GP	36,18%	23,04%	32,61%	42,77%	51,20%	-0,07%	37,03%	52,76%	141,84%	46,37%

Tabela 8: Comparação de retorno financeiro entre melhor classificador com metaclassificador

Algoritmo	BOVA11	CIEL3	ITUB4	PETR4	USIM5	CMIG4	GGBR4	KROT3	GOLL4	Média
MLP	3,78%	-12,02%	7,29%	21,58%	79,01%	0,84%	17,55%	64,78%	71,13%	28,21%
Meta-RF	29,24%	41,23%	56,42%	55,49%	139,84%	86,38%	50,22%	60,93%	57,24%	64,11%

compra e venda no mesmo dia, e 15% sobre os lucros de operações de mais de um dia.

Segundo o site da Bolsa de Valores de São Paulo, no Brasil há 87 corretoras ativas. Contudo, cada uma utiliza uma taxa de corretagem diferente, e há corretoras que não cobram essas taxas¹⁴. Desta forma, como os custos operacionais não são padronizados, optou-se por utilizar o custo operacional de 20,59% apresentado na Tabela 9, visto que o capital inicial das simulações foi de R\$10.000,00. Entende-se desta forma que o arcabouço demonstra certa compatibilidade com o mercado real sobre os custos para este cenário, com uma margem de erro prevista.

Tabela 9: Exemplos de custos operacionais

	Lucro Bruto		
	R\$ 100,00	R\$ 1.000,00	R\$ 10.000,00
IR na fonte (0,50%)	R\$ 0,50	R\$ 5,00	R\$ 50,00
IR recolhido pelo investidor (20,00%)	R\$ 20,00	R\$ 200,00	R\$ 2.000,00
Corretagem por ordem (2,50)	R\$ 5,00	R\$ 5,00	R\$ 5,00
ISS sobre a corretagem (12,00%)	R\$ 0,60	R\$ 1,20	R\$ 1,20
Emolumentos (0,025%)	R\$ 0,03	R\$ 0,25	R\$ 2,50
Custo da operação (R\$)	R\$ 26,13	R\$ 211,45	R\$ 2.058,70
Custo da operação (%)	26,13%	21,15%	20,59%
Custo da operação sem IR (%)	6,13%	1,15%	0,59%
Lucro líquido sem IR (%)	93,88%	98,86%	99,41%
Lucro líquido (%)	73,88%	78,86%	79,41%
Lucro líquido (R\$)	R\$ 73,88	R\$ 788,55	R\$ 7.941,30

5.5 Resultados Experimentais

Nesta seção serão apresentados os resultados experimentais detalhados das duas técnicas selecionadas para avaliação e comparação: (MLP) e (Meta-RF). Os resultados dizem respeito a simulações realizadas levando-se em conta 244 dias de pregão dentro do período de agosto de 2015 a agosto de 2016, em nove conjuntos de dados de nove ativos distintos da Bolsa de Valores de São Paulo. Em todos os experimentos foram utilizados investimentos iniciais de R\$ 10.000,00, com todos os custos operacionais já considerados nos retornos financeiros.

A Tabela 11 apresenta os resultados simulados do melhor metaclassificador (Meta-RF); já a Tabela 12 apresenta os resultados simulados do melhor classificador isolado (MLP). Entende-se que com essas duas tabelas é possível compará-los e demonstrar características relevantes dos dois modelos de previsão.

Ao avaliar os nove ativos selecionados e comparar os retornos financeiros acumulados, o metaclassificador teve melhor performance em sete oportuni-

¹⁴<https://www.clear.com.br/>

dades, perdendo somente nos ativos KROT3 e GOLL4. Com grande destaque para os ativos BOVA11, CIEL, ITUB4, USIM5, CMIG4. Os resultados são interessantes, visto que, dentre os destaques, o metaclassificador supera o classificador isolado em mais de 100% de média. Nota-se que para o ativo ITUB4 o metaclassificador foi superior em 611%.

Para cada um dos ativos, os resultados são apresentados também nas Figuras 11, 12, 13, 14, 15, 16, 17, 18, 19; nos Apêndices, onde são comparados os retornos financeiros acumulados, os *drawdowns* e o *boxplot* dos retornos.

Nesta mesma métrica de retorno financeiro, o metaclassificador e o classificador isolado foram comparados com três *baselines*: *buy-and-hold*, aleatório e estratégia inversa, conforme a Tabela 13. Ao avaliar a estratégia *buy-and-hold* dos nove ativos, apenas para KROT3 o metaclassificador não foi superior. Neste caso, a série de preços possui uma característica de forte tendência de alta, conforme a Figura 8. Logo, é mais frequente encontrar este comportamento em cenários de tendência de grandes altas, quando a estratégia *buy-and-hold* demonstra-se superior aos modelos de previsão. Já para os demais *baselines*, o metaclassificador foi melhor em todos os ativos.

O classificador isolado não obteve resultados satisfatórios nesta comparação; por diversas vezes foi pior que os *baselines*, como no caso dos ativos BOVA11, CIEL3, ITUB4 e PETR4.

Nas demais métricas financeiras também é possível verificar certa superioridade do metaclassificador, como é no caso do ganho médio, da perda média e *drawdown*. Nota-se que quando o metaclassificador ganha, ganha-se mais, e quando perde, perde-se menos do que no classificador isolado. É muito importante considerar também o *drawdown*; a Tabela 10 demonstra bem o quanto é difícil recuperar perdas. Neste aspecto o metaclassificador apresentou melhor performance também com um *drawdown* médio dos ativos de -18,98%, enquanto o classificador isolado obteve -22,13%.

A predominância do metaclassificador também é caracterizada nas medidas de desempenho dos modelos (acurácia, revocação, especificidade, *F1-score* e precisão).


Tabela 10: Referência de *drawdown*

% Capital Perdido	% Capital Requerido para Recuperar
10%	11.11%
20%	25.00%
30%	42.85%
40%	66.66%
50%	100%
60%	150%
70%	233%
80%	400%
90%	900%
100%	Falência

Por fim, dentro da análise das métricas financeiras, foi feita uma comparação da dispersão de todos os retornos financeiros acumulados, conforme a Figura 10, que mostra o melhor desempenho do metaclassificador. Também foi aplicado o teste *t* de STUDENT (1908) e através do p-valor de 0,04015,

o metaclassificador mostrou diferença estatística significativa, possibilitando concluir que o metaclassificador é melhor que o classificador isolado.

Figura 10: Comparação de dispersão geral dos retornos financeiros



6 Conclusão

Este artigo apresentou uma pesquisa que teve por objetivo principal desenvolver um método para prever séries temporais financeiras utilizando um metaclassificador que apresentasse boa performance financeira a partir de suas previsões. O objetivo proposto foi alcançado, uma vez que, de forma geral, o metaclassificador apresentou melhores resultados que os *baselines* e os métodos concorrentes.

Todo o arcabouço projetado foi implementado na plataforma (Weka). Durante o desenvolvimento, diversas versões foram criadas e algumas das informações produzidas acabaram por não figurar no texto final, visto que várias destas não faziam parte diretamente do escopo final do projeto. No entanto, todas estas etapas influenciaram positivamente em diversos momentos quanto às decisões de implementação.

Inicialmente, foram investigados diversos trabalhos relacionados ao tema da previsão de séries temporais financeiras. Através de uma Revisão Sistemática da Literatura, percebeu-se que o tema em questão é de grande interesse não só para a área acadêmica, mas também para o mercado financeiro. Não foram encontrados trabalhos que utilizassem metaclassificadores com as características implementadas para este cenário proposto, o que motivou ainda mais o desenvolvimento desta pesquisa.

Desta forma, foi desenvolvido um metaclassificador baseado em sete técnicas de inteligência computacional para descobrir tendências em séries financeiras: programação genética, máquinas de vetor de suporte, florestas aleatórias, redes neurais, árvore de decisão, otimização mínima sequencial e redes bayesianas, o que percebemos como um grande diferencial deste trabalho.

Tabela 11: Resultados metaclassificador - Meta-RF

Técnica	Meta-RF								
Ativo	BOVA11	CIEL3	ITUB4	PETR4	USIM5	CMIG4	GGBR4	KROT3	GOLL4
% Retorno Financeiro	27,20%	36,13%	52,62%	52,98%	116,37%	68,62%	48,51%	50,57%	57,12%
Max Drawdown	-11,54%	-10,26%	-14,82%	-22,40%	-29,59%	-18,62%	-28,80%	-9,69%	-25,06%
Volatilidade	2,52%	2,94%	7,85%	6,26%	14,18%	5,29%	6,72%	3,26%	6,59%
Índice Sharpe	6,83	8,87	5,42	6,86	7,5	11,07	5,73	12,43	7,14
% Perda Média	-1,52%	-2,08%	-2,17%	-4,14%	-5,15%	-3,21%	-4,08%	-2,33%	-3,67%
% Ganho Médio	3,41%	2,44%	4,26%	6,28%	11,90%	5,31%	6,22%	3,61%	7,97%
% Dias Positivo	8,00%	12,50%	10,00%	9,50%	9,00%	11,00%	8,50%	12,50%	7,50%
% Dias Negativo	9,00%	6,00%	7,50%	8,00%	9,50%	7,50%	7,00%	8,50%	8,50%
% Gatilhos Positivos	23,53%	33,78%	28,57%	26,39%	23,68%	29,73%	27,42%	29,76%	22,73%
% Gatilhos Negativos	26,47%	16,22%	21,43%	22,22%	25,00%	20,27%	22,58%	20,24%	25,76%
Acurácia	56,50%	53,00%	53,50%	48,00%	56,50%	54,00%	53,50%	56,00%	53,50%
Precisão	56,36%	52,88%	54,39%	51,06%	53,68%	54,26%	55,42%	56,57%	41,51%
Revocação	61,39%	55,00%	60,19%	45,28%	54,26%	51,00%	45,10%	55,45%	26,19%
Especificidade	51,52%	51,00%	46,39%	51,06%	58,49%	57,00%	62,24%	56,57%	73,28%
F1	58,77%	53,92%	57,14%	48,00%	53,97%	52,58%	49,73%	56,00%	32,12%

Tabela 12: Resultados classificador - MLP

Técnica	MLP								
	BOVA11	CIEL3	ITUB4	PETR4	USIM5	CMIG4	GGBR4	KROT3	GOLL4
% Retorno Financeiro	4,90%	-10,44%	8,60%	28,47%	63,37%	5,33%	23,67%	56,10%	71,13%
Max Drawdown	-10,95%	-20,70%	-12,39%	-30,03%	-14,61%	-25,77%	-29,78%	-18,50%	-36,40%
Volatilidade	2,23%	3,26%	2,58%	6,39%	4,93%	4,62%	5,98%	5,54%	14,10%
Índice Sharpe	-2,28	-6,26	-0,54	2,89	10,82	-1,008	2,28	8,32	5,75
% Perda Média	-1,50%	-2,20%	-2,28%	-4,57%	-4,03%	-3,57%	-3,50%	-2,95%	-3,71%
% Ganho Médio	2,08%	2,22%	1,71%	5,21%	5,13%	4,04%	5,60%	5,20%	12,72%
% Dias Positivo	9,50%	10,00%	14,50%	11,50%	10,50%	9,50%	9,00%	10,50%	6,50%
% Dias Negativo	11,50%	12,50%	9,00%	10,00%	5,50%	10,00%	11,00%	9,00%	10,00%
% Gatilhos Positivos	22,62%	21,74%	30,85%	26,74%	29,17%	24,36%	22,50%	26,92%	19,12%
% Gatilhos Negativos	27,38%	27,17%	19,15%	23,26%	15,28%	25,64%	27,50%	23,08%	29,41%
Acurácia	45,00%	44,50%	51,00%	54,50%	55,00%	49,00%	50,00%	56,50%	52,00%
Precisão	44,71%	44,95%	52,87%	57,73%	52,50%	49,02%	51,25%	57,61%	43,48%
Revocação	37,62%	49,00%	44,66%	52,83%	44,68%	50,00%	40,20%	52,48%	47,62%
Especificidade	52,53%	40,00%	57,73%	56,38%	64,15%	48,00%	60,20%	60,61%	55,17%
F1	40,86%	46,89%	48,42%	55,17%	48,28%	49,50%	45,05%	54,92%	45,45%

Tabela 13: Resultado de % retorno financeiro dos *baselines*

Ativo	<i>Baseline</i>		
	<i>Buy-and-hold</i>	Aleatório	Inversa
BOVA11	21,10%	5,30%	-71,40%
CIEL3	12,71%	8,52%	-80,54%
ITUB4	23,92%	14,03%	-82,16%
PETR4	52,90%	27,47%	-95,35%
USIM5	-1,63%	3,66%	-98,93%
CMIG4	38,12%	14,16%	-94,82%
GGBR4	35,23%	24,47%	-96,43%
KROT3	65,29%	33,21%	-88,64%
GOLL4	34,40%	26,56%	-98,97%

Para validar a metodologia, realizaram-se uma série de experimentos utilizando dados reais da Bolsa de Valores de São Paulo. Foram utilizados nove conjuntos de dados de ativos: BOVA11, CIEL3, ITUB4, PETR4, USIM5, CMIG4, GGBR4, KROT3 e GOLL4. Todos os dados de entrada dos algoritmos foram tratados; utilizou-se a série de retorno na escala logarítmica dos preços e volume em uma janela deslizante.

Os resultados foram promissores, visto que é possível mostrar que, em geral, os metaclassificadores possibilitaram melhores ganhos, apresentando boa acurácia na classificação, com até 57%, além de resultados financeiros satisfatórios, com ganhos de até 100% acima do valor de capital inicialmente investido, já descontando custos operacionais.

Foi possível observar que o modelo proposto nesse trabalho tem resultados melhores que os classificadores individuais e os *baselines*, com raras exceções. Os resultados podem ser considerados promissores com indicativos, inclusive, de seu potencial de aplicação em cenários reais de investimentos.

7 Trabalhos Futuros

O campo de estudos de previsões em bolsas de valores oferece uma infinidade de possibilidades. Desta maneira, esse trabalho pode ser estendido de diversas formas. Outros atributos que ajudem a melhorar os resultados podem ser estudados, por exemplo, indicadores de sentimento de notícias relacionadas a ativos, volumes de dados relacionados em redes sociais ou mesmo dados sobre buscas na *web*. Do ponto de vista financeiro, é notório que a estratégia de investimento é tão importante quanto prever corretamente o comportamento do mercado. Desta forma, entende-se que a avaliação de estratégias mais robustas de negociação levaria a resultados melhores. Por fim, é preciso avaliar o arcabouço em um cenário real.

Agradecimentos

Os autores gostariam de agradecer aos revisores e editores da Revista Economia Aplicada.

Referências Bibliográficas

- A ERNST (2014), 'Find the right people, processes and technology to manage record-to-report risks', *Managing Operational Tax Risk*.
- ADVFN (2010), 'Entenda o que é o IGPM'. Acesso em: 6 jan. 2019.
URL: Disponível em: <https://br.advfn.com/indicadores/igpm>
- AGAPITOS, A., BRABAZON, A. & O'NEILL, M. (2017), 'Regularised gradient boosting for financial time-series modelling', *Computational Management Science* v. 14(n. 3), p. 367–391.
- Almeida, C. (2016), 'Os 10 fatos mais marcantes de 2015', Disponível em: <https://super.abril.com.br/sociedade/os-10-fatos-mais-marcantes-de-2015/>. Acesso em: 6 jan. 2019.
- ANGHEL, M. G. (2013), 'Technical analysis versus fundamental analysis of securities', *Romanian Statistical Review Supplement* v. 61(n. 2), p. 257–262.
- ARMAKI, A. G., FALLAH, M. F., ALBORZI, M. & MOHAMMADZADEH, A. (2017), 'A hybrid meta-learner technique for credit scoring of banks customers', *Int J Res Appl Sci Eng Technol* v. 7(n. 5), p. 2073–2082.
- ASHBY, W. R. (1960), *Design for a brain: the origin of adaptive behavior*, 2nd ed. edn, Wiley, New Jersey.
- ASSAF NETO, A. (2009), *Mercado financeiro*, 9. ed. edn, Atlas, São Paulo.
- BANZHAF, W., FRANCONI, F. D., KELLER, R. E. & NORDIN, P. (1998), *Genetic programming: an introduction on the automatic evolution of computer programs and its applications*, Morgan Kaufmann Publishers Inc., San Francisco.
- BARAK, S., ARJMAND, A. & ORTOBELLI, S. (2017), 'Fusion of multiple diverse predictors in stock market', *Inf Fusion* v. 36(n. 1), p. 90–102.
- BARRYMORE, J. (2017), 'Como funcionam as tendências do mercado de ações', Disponível em: <http://empresasefinancas.hsw.uol.com.br/tendencias-mercado-de-acoas.htm>. Acesso em: 6 fev. 2017.
- BAYES, T. (1763), 'An essay towards solving a problem in the doctrine of chances', *Philos Trans R Soc Lond A* v. 53(n. 1), p. 370–418.
- BOLSA BRASIL BALCÃO (2017), 'Site da B3'. Acesso em: 6 fev. 2017.
URL: Disponível em: <http://www.b3.com.br>
- BOX, G. E. P. & JENKINS, G. M. (1976), *Time series analysis: forecasting and control*, 2nd ed. edn, Holden-Day, San Francisco.
- BREIMAN, L. (1996), 'Bagging predictors', *Mach Learn* v. 24(n. 2), p. 123–140.
- BREIMAN, L. (2001), 'Random Forests', *Mach Learn* v. 45(n. 1), p. 5–32.
- BÚSSOLA DO INVESTIDOR (2017), 'Site do Bússola do Investidor'. Acesso em: 31 jan. 2017.
URL: Disponível em: <https://www.bussoladoinvestidor.com.br/>

- CAFFÉ, M. I. R., PEREZ, P. S. & BARANAUSKAS, J. A. (2012), 'Evaluation of stacking on biomedical data', *Journal of Health Informatics* v. 4(n. 3), p. 67–72.
- CAVALCANTE, R. C., BRASILEIRO, R. C., SOUZA, V. L. F., NOBREGA, J. P. & OLIVEIRA, A. L. I. (2016), 'Computational intelligence and financial markets: a survey and future directions', *Expert Syst Appl* v. 55(n. 15), p. 194–211.
- COHEN, W. W. (1995), Fast effective rule induction, in 'In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 12', San Francisco, pp. 115–123.
- CRUZ, R. M. O., SABOURIN, R., CAVALCANTI, G. D. C. & ING-REN, T. (2015), 'META-DES: a dynamic ensemble selection framework using meta-learning', *Pattern Recognit* v. 48(n. 5), p. 1925–1935.
- DAVIS, J. & GOADRICH, M. (2006), The relationship between precision-recall and ROC curves, in 'In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 23', New York, pp. 233–240.
- DE MOURA, F. A. (2006), O uso de redes neurais artificiais na previsão de tendências no mercado de ações, PhD thesis, Dissertação (Mestrado em Engenharia de Produção), Universidade Federal de Pernambuco, Recife, 2006.
- DI PERSIO, L. & HONCHAR, O. (2016), 'Artificial neural networks approach to the forecast of stock market price movements', *International Journal of Economics and Management Systems* v. 1(n. 1), p. 158–162.
- DIETTERICH, T. G. (2000), Ensemble methods in machine learning, in 'In: INTERNATIONAL WORKSHOP ON MULTIPLE CLASSIFIER SYSTEMS, 1', Berlin, pp. 1–15.
- DRUCKER, H., BURGESS, C. J. C., KAUFMAN, L., SMOLA, A. & VAPNIK, V. (1997), Support vector regression machines, in 'In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS, 10', Cambridge, pp. 155–161.
- DUARTE, F. A., SATO, R. S. & LORENA, A. C. (2018), Uma Aplicação de meta-aprendizagem no mercado euro/dólar, in 'In: WORKSHOP OF ARTIFICIAL INTELLIGENCE APPLIED TO FINANCE, WAIAF 2019', São José dos Campos.
- DŽEROSKI, S. & ŽENKO, B. (2004), 'Is combining classifiers with stacking better than selecting the best one?', *Mach Learn* v. 54(n. 3), p. 255–273.
- ELEVEN FINANCIAL (2017), 'O que é taxa CDI e como ela funciona?', Disponível em: <https://elevenfinancial.com/o-que-e-taxa-cdi-e-como-ela-funciona>. Acesso em: 6 jan. 2019.
- FREUND, Y. (1999), An adaptive version of the boost by majority algorithm, in 'In: ANNUAL CONFERENCE ON COMPUTATIONAL LEARNING THEORY, 12', Santa Cruz, pp. 102–113.
- GIACOMEL, F., GALANTE, R. & PEREIRA, A. (2015), An algorithmic trading agent based on a neural network ensemble: a case of study in North American and Brazilian stock markets, in 'In: INTERNATIONAL CONFERENCE ON WEB INTELLIGENCE AND INTELLIGENT AGENT TECHNOLOGY, 2015', Singapore, pp. 230–233.

- GISLASON, P. O., BENEDIKTSSON, J. A. & SVEINSSON, J. R. (2006), 'Random forests for land cover classification', *Pattern Recognit Lett* v. 27(n. 4), p. 294–300.
- GOLDBERG, D. E. (1989), *Genetic algorithms in search, optimization and machine learning*, 1st ed. edn, Addison-Wesley Longman Publishing Co., Inc., New York.
- HAND, D. J. & YU, K. (2001), 'Idiots Bayes not so stupid after all?', *Int Stat Rev* v. 69(n. 3), p. 385–398.
- HEBB, D. O. (1949), *The organization of behavior: a neuropsychological theory*, Psychology Press, New York.
- HO, T. K. (2001), *Multiple classifier combination: lessons and next steps*, Vol. v. 47 of *Series in machine perception and artificial intelligence*, World Scientific, chapter c. 7, pp. p. 171–198.
- HOLLAND, J. H. (1975), *Adaptation in natural and artificial systems*, University of Michigan Press, Ann Arbor.
- KAMPOURIDIS, M. & OTERO, F. E. B. (2015), 'Heuristic procedures for improving the predictability of a genetic programming financial forecasting algorithm', *Soft comput* v. 21(n. 1), p. 295–310.
- KITCHENHAM, B. (2004), Procedures for performing systematic reviews, Technical report, Keele University and NICTA.
- KOZA, J. R. (1992), *Genetic programming: on the programming of computers by means of natural selection*, MIT Press, Cambridge.
- KUNCHEVA, L. I. (2004), *Combining pattern classifiers: methods and algorithms*, 2nd ed. edn, John Wiley & Sons, Inc., Hoboken.
- MC CULLOCH, W. S. & PITTS, W. (1943), 'A logical calculus of the ideas immanent in nervous activity', *Bull Math Biol* v. 5(n. 4), p. 115–133.
- METATRADER (2017), 'Plataforma de Negociação MetaTrader 5'. Acesso em: 6 fev. 2017.
URL: Disponível em: <https://www.metatrader5.com/>
- MYSKOVA, R., HAJEK, P. & OLEJ, V. (2018), 'Predicting abnormal stock return volatility using textual analysis of news a meta-learning approach', *Amfiteatru Economic* v. 20(n. 47), p. 185–201.
- NAMETALA, C. A. L., PIMENTA, A., PEREIRA, A. C. M. & CARRANO, E. G. (2016), An automated investment strategy using artificial neural networks and econometric predictors, in 'In: BRAZILIAN SYMPOSIUM ON INFORMATION, XII, SYSTEMS ON BRAZILIAN SYMPOSIUM ON INFORMATION SYSTEM, 2016', Vol. v. 1, Porto Alegre, pp. p. 152–159.
- NEAPOLITAN, R. E. (2003), *Learning bayesian networks*, Prentice-Hall, Inc., Upper Saddle River.
- NORONHA, M. (2003), *Análise técnica: teorias ferramentas estratégias*, 5. ed. edn, Editec, Rio de Janeiro.

PATEL, J., SHAH, S., THAKKAR, P. & KOTTECHA, K. (2015), 'Predicting stock market index using fusion of machine learning techniques', *Expert Syst Appl* v. 42(n. 4), p. 2162–2172.

PEARL, J. (1988), *Probabilistic reasoning in intelligent systems: networks of plausible inference*, Morgan Kaufmann Publishers Inc., San Francisco.

PIMENTA, A., GUIMARÃES, F. G., CARRANO, E. G., NAMETALA, C. A. L. & TAKAHASHI, R. H. C. (2014), Gold miner: a genetic programming based algorithm applied to Brazilian stock market, in 'In: SYMPOSIUM ON COMPUTATIONAL INTELLIGENCE AND DATA MINING, 2014', Orlando, pp. p. 397–402.

PLATT, J. C. (1998), Fast training of support vector machines using sequential minimal optimization, in 'Advances in Kernel methods - support vector learning', In: Schoelkopf B., Burges C.J.C., Smola, A.J. (eds.), MIT Press, Cambridge.

QUINLAN, J. R. (1993), *C4.5: programs for machine learning*, 5th ed. edn, Morgan Kaufmann Publishers Inc., San Francisco.

RAMOS, J. P. S. (2003), 'Fruit sorting using artificial neural networks: bidimensional case', *Ciênc Agrotec* v. 27(n. 2), p. 356–362.

ROSENBLATT, F. (1958), 'The perceptron: a probabilistic model for information storage and organization in the brain', *Psychol Rev* v. 65(n. 6), p. 386–408.

SCHAPIRE, R. E. (1990), 'The strength of weak learnability', *Mach Learn* v. 5(n. 2), p. 197–227.

SEEWALD, A. K. (2002), How to make stacking better and faster while also taking care of an unknown weakness, in 'In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 19', San Francisco, pp. p. 554–561.

SEKER, S. E., MERT, C., AL NAAMI, K., AYAN, U. & ÖZALP, N. (2013), Ensemble classification over stock market time series and economy news, in 'In: INTERNATIONAL CONFERENCE ON INTELLIGENCE AND SECURITY INFORMATICS, 2013', Seattle, pp. p. 272–273.

STROUSTRUP, B. (2000), *The C++ programming language*, 3rd ed. edn, Addison-Wesley Longman Publishing Co., Inc., Boston.

STUDENT (1908), 'The probable error of a mean', *Biometrika* v. 6(n. 1), p. 1–25.

TAN, A. C. & GILBERT, D. (2003), 'Ensemble machine learning on gene expression data for cancer classification', *Appl Bioinformatics* v. 2(n. 3), p. 75–83.

THORSTENSEN, V. H. (1976), A teoria da eficiência no mercado de capitais. Uma revisão da literatura e dos trabalhos empíricos. O modelo de Random walk aplicado ao índice de mercado de ações Bovespa, PhD thesis, Dissertação (Mestre em Administração de Empresas), Escola de Administração de Empresas de São Paulo, Fundação Getúlio Vargas, São Paulo, 1976.

- TKÁČ, M. & VERNER, R. (2016), 'Artificial neural networks in business: two decades of research', *Appl Soft Comput* v. 38(n. 1), p. 788–804.
- TSAY, R. S. (2005), *Analysis of financial time series*, 2nd ed. edn, John Wiley & Sons, Inc., Hoboken.
- VAPNIK, V. N. (1995), *The nature of statistical learning theory*, 1st ed. edn, Springer-Verlag New York, Inc., New York.
- VAPNIK, V. N. & CHERVONENKIS, A. Y. (1971), 'On the uniform convergence of relative frequencies of events to their probabilities', *Theory Probab Appl* v. 16(n. 2), p. 264–280.
- VARGA, G. (2001), 'Índice de sharpe e outros indicadores de performance aplicados a fundos de ações brasileiros', *Revista de Administração Contemporânea* v. 5(n. 3), p. 215–245.
- WERBOS, P. J. (1994), *The roots of backpropagation: from ordered derivatives to neural networks and political forecasting*, 1st ed. edn, John Wiley & Sons, Inc., Hoboken.
- WIDROW, B. & HOFF, M. E. (1960), Adaptive switching circuits, in 'In: IRE WESCON CONVENTION RECORD, PART 4', New York, pp. p. 96–104.
- WIDROW, B. & HOFF, M. E. (1962), *Associative storage and retrieval of digital information in networks of adaptive "neurons"*, Springer, Boston, pp. p. 160–160.
- WITTEN, I. H. & FRANK, E. (2005), *Data mining: practical machine learning tools and techniques*, 2nd ed. edn, Morgan Kaufmann Publishers Inc., San Francisco.
- WITTEN, I. H., FRANK, E., TRIGG, L., HALL, M., HOLMES, G. & CUNNINGHAM, S. J. (1999), 'Weka: practical machine learning tools and techniques with java implementations'.
- WOLPERT, D. H. (1992), 'Stacked generalization', *Neural Netw* v. 5(n. 2), p. 241–259.
- ZHANG, M. & ZHOU, Z. (2014), 'A review on multi-label learning algorithms', *IEEE Trans Knowl Data Eng* v. 26(n. 8), p. 1819–1837.

8 Apêndices

Figura 11: Comparação drawdown e % retornos financeiros - BOVA11

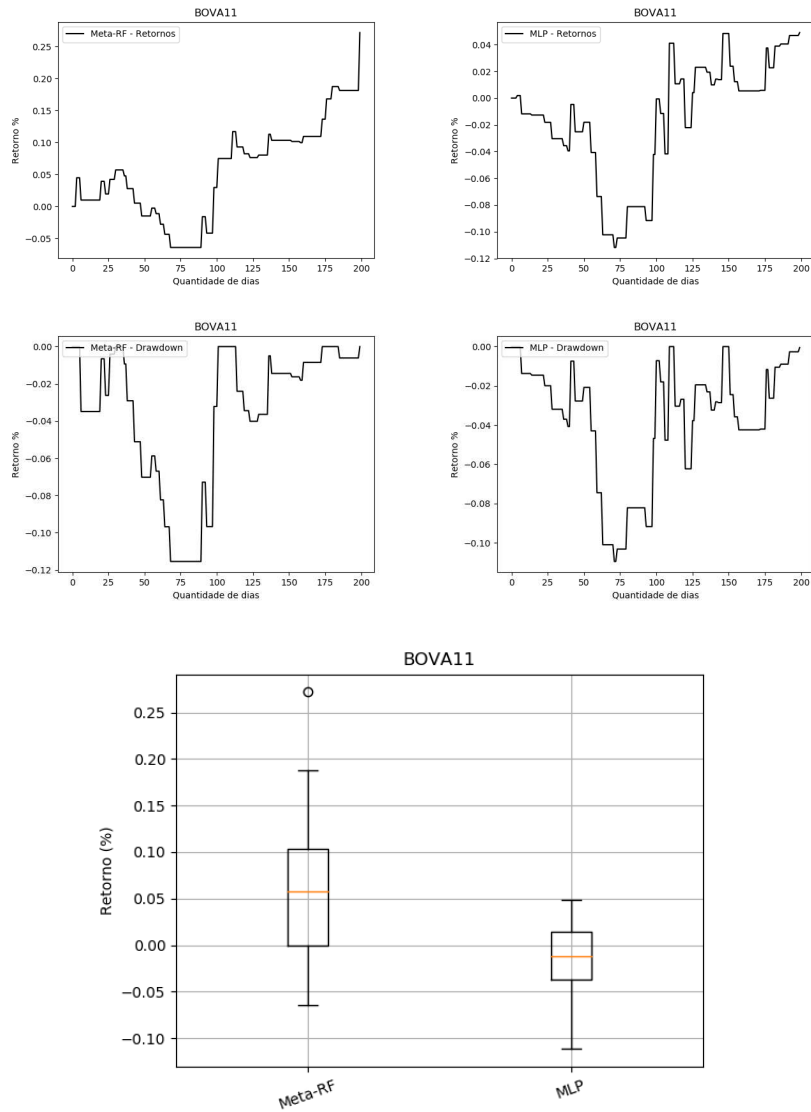


Figura 12: Comparação drawdown e % retornos financeiros - CIEL3

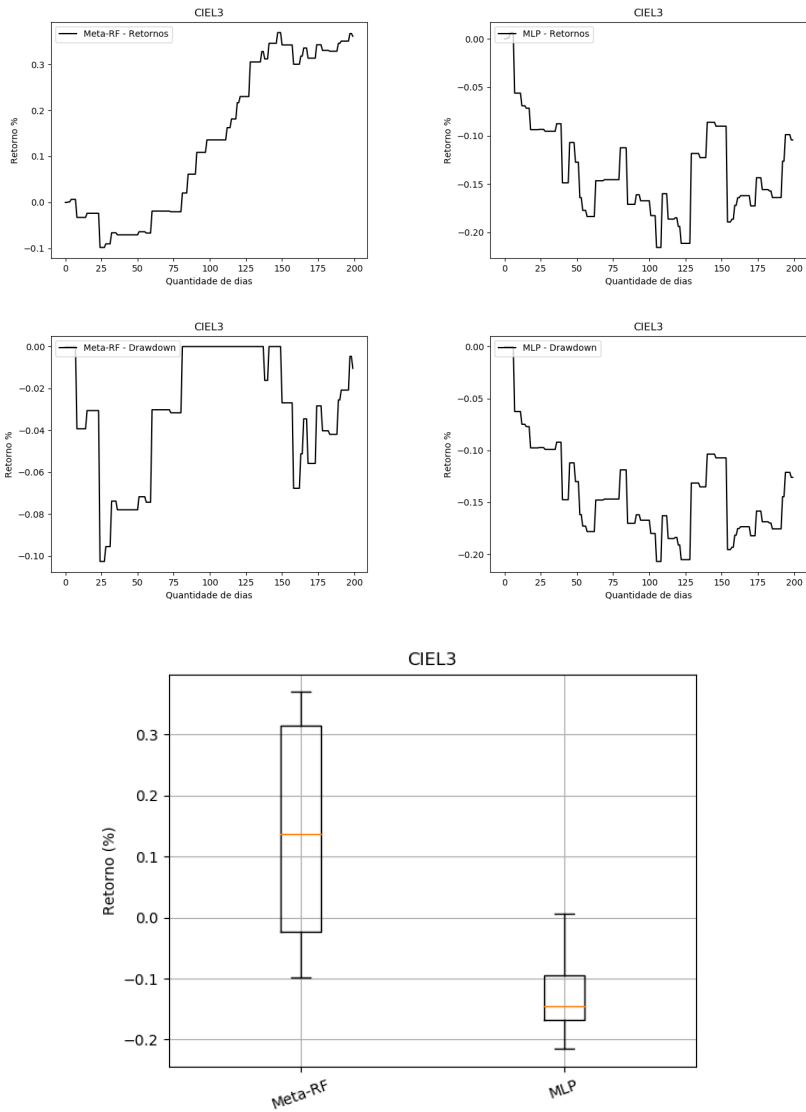


Figura 13: Comparação *drawdown* e % retornos financeiros - ITUB4

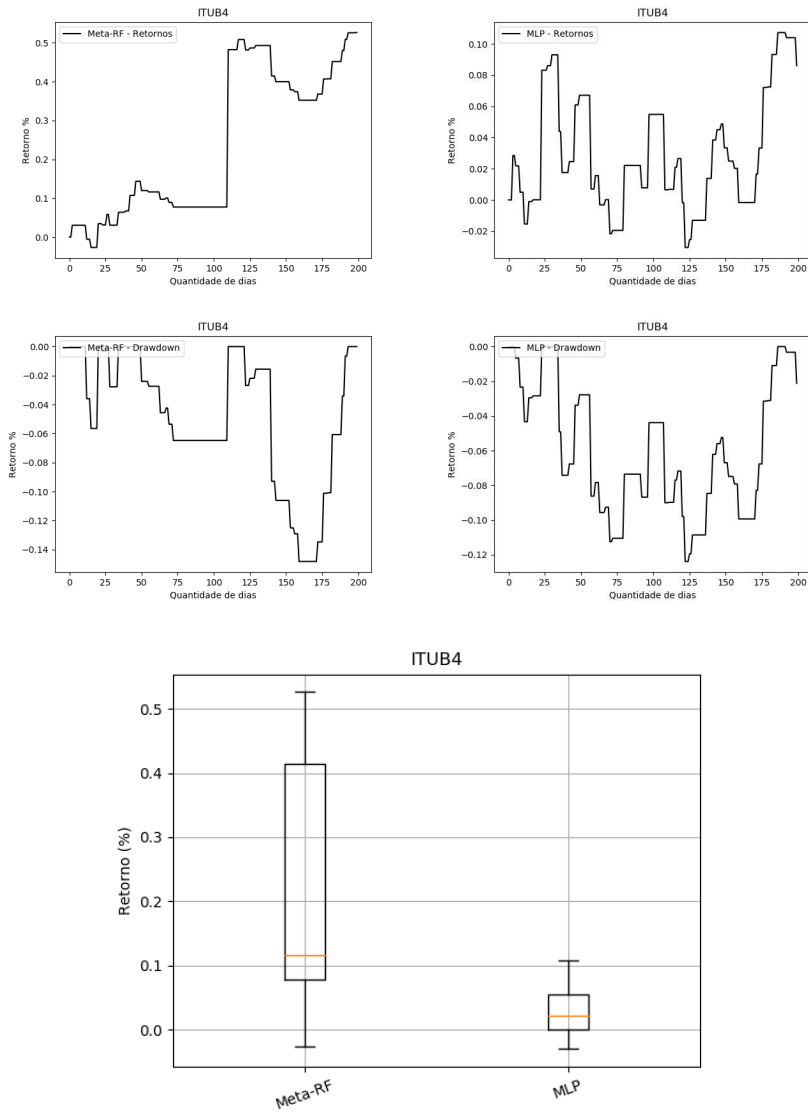


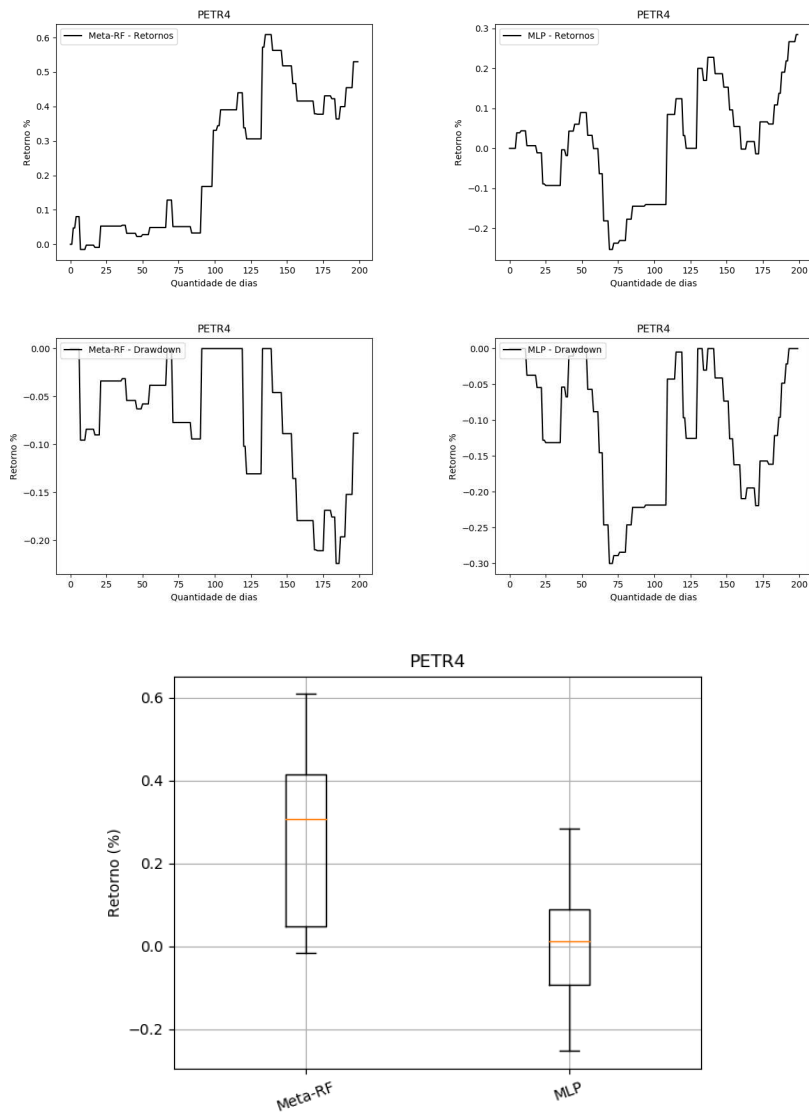
Figura 14: Comparação *drawdown* e % retornos financeiros - PETR4

Figura 15: Comparação *drawdown* e % retornos financeiros - USIM5

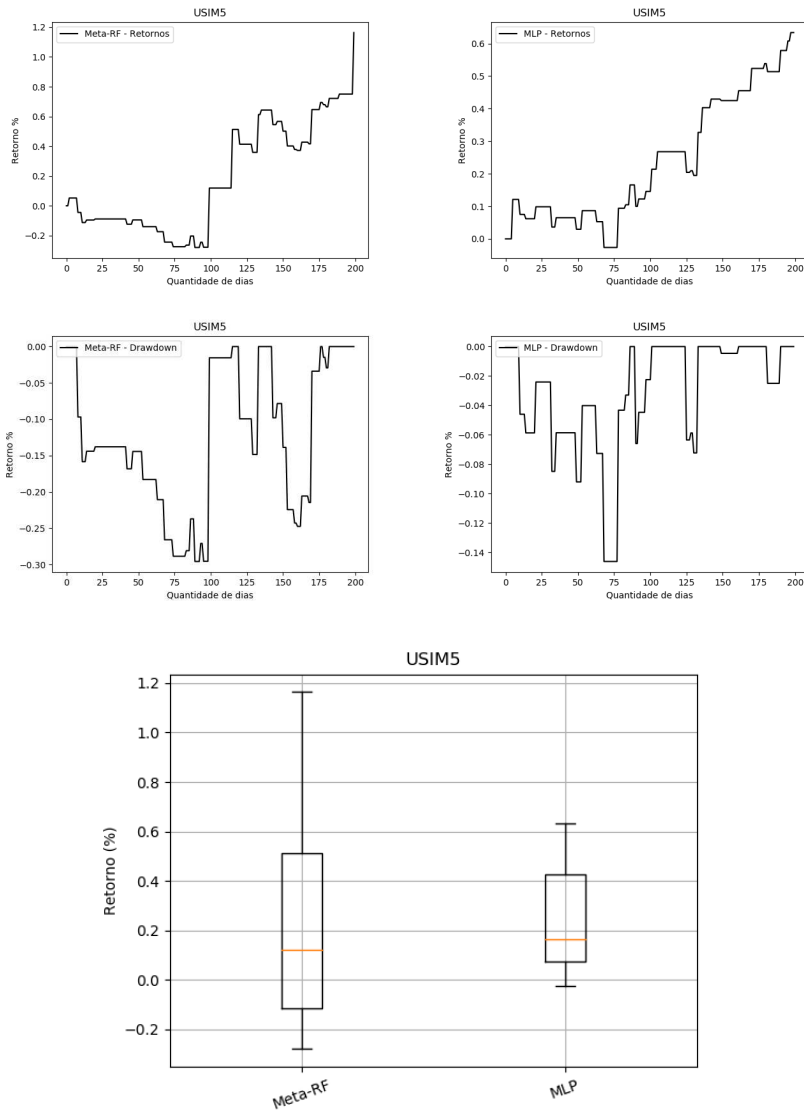


Figura 16: Comparação *drawdown* e % retornos financeiros - CMIG4

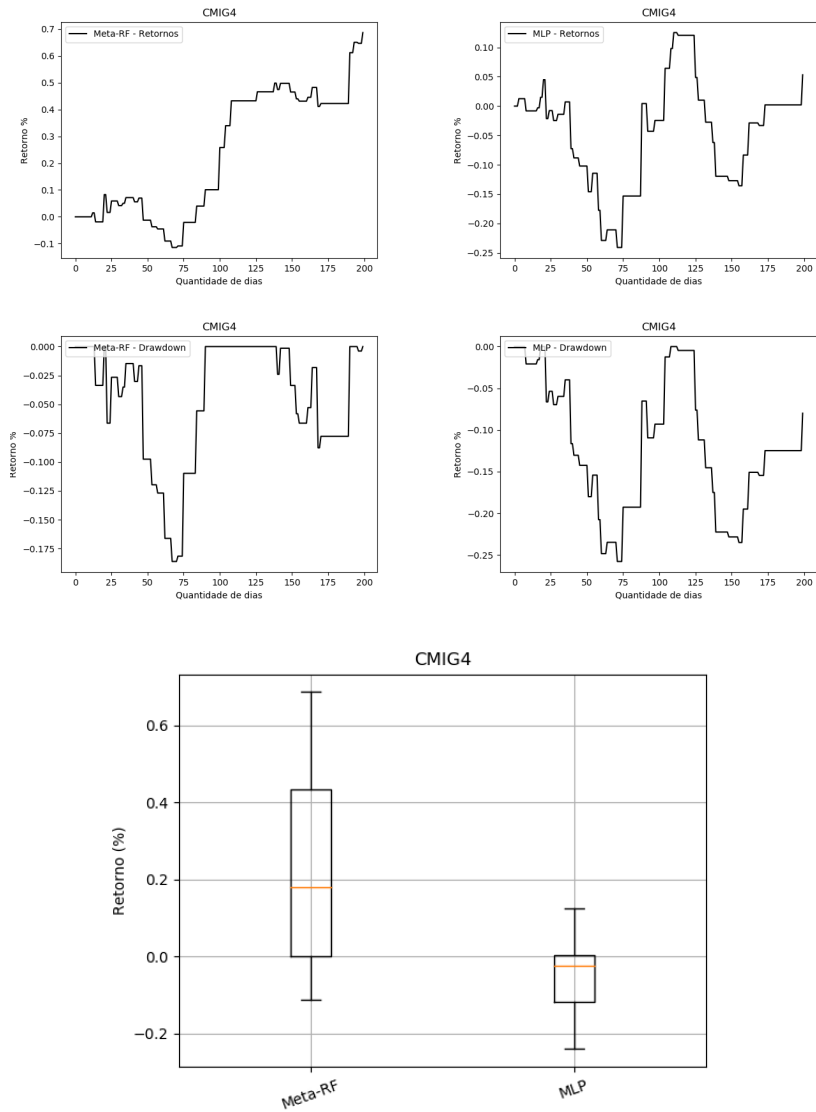
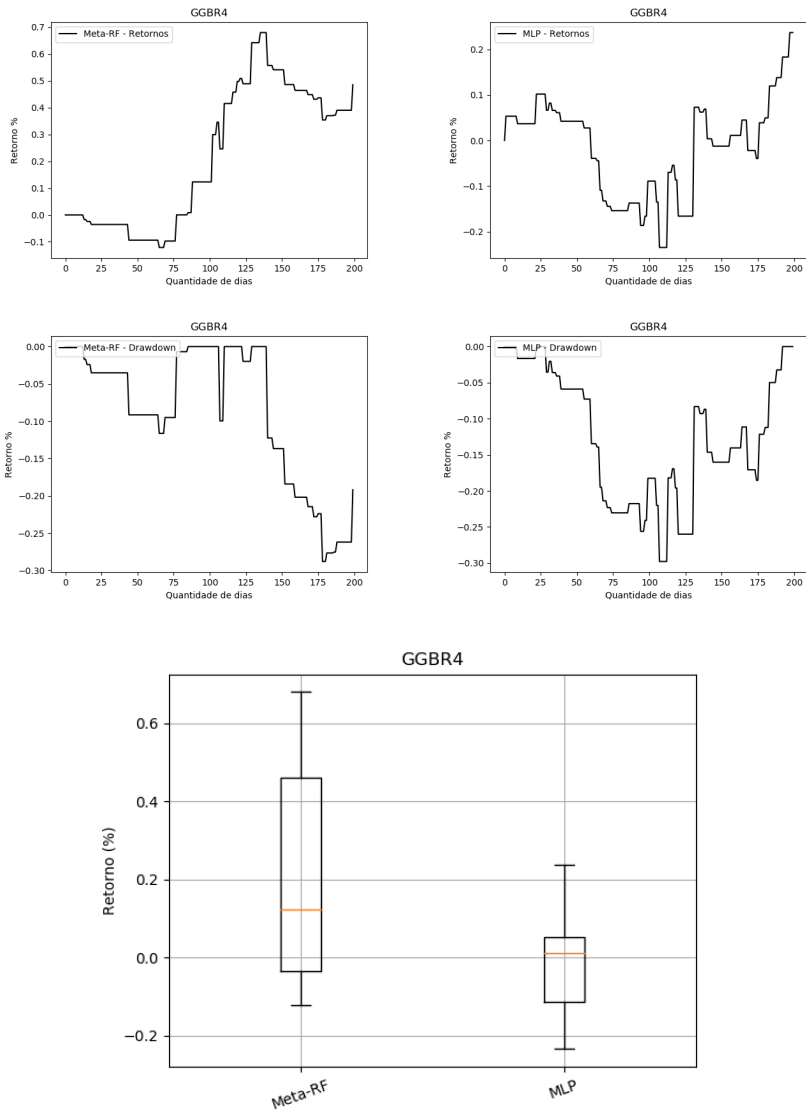


Figura 17: Comparação *drawdown* e % retornos financeiros - GGBR4



...

Figura 18: Comparação *drawdown* e % retornos financeiros - KROT3

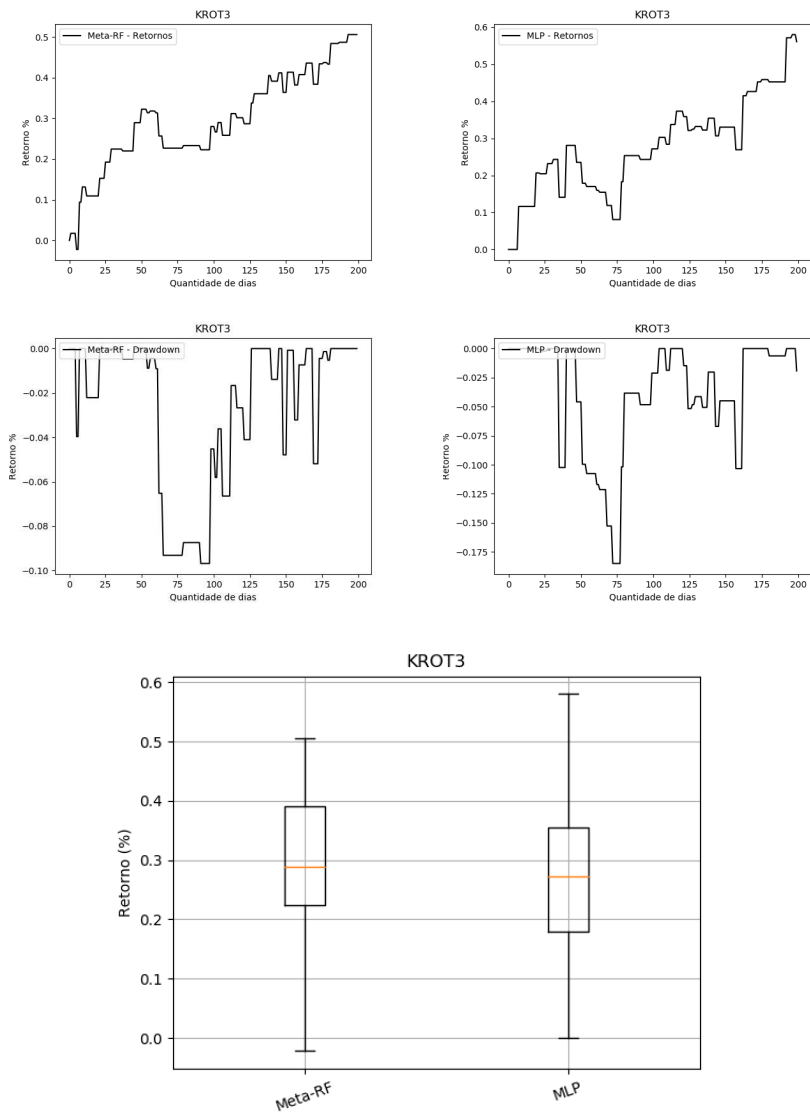


Figura 19: Comparação *drawdown* e % retornos financeiros - GOLL4

