Texto

Universidade Federal do Rio de Janeiro
Instituto de Matemática
Instituto Tércio Pacitti
Programa de Pós-Graduação em Informática

Negociação no mercado financeiro utilizando a rede neural sem peso WiSARD

Samara Alvarez Alves

Rio de Janeiro
2017

Samara Alvarez Alves

Negociação no mercado financeiro utilizando a rede neural sem peso WiSARD

Dissertação apresentada ao Programa de Pós-Graduação em Informática, Instituto de Matemática e Instituto Tércio Parcitti da Universidade Federal do Rio de Janeiro (área de concentração: Modelos e Arquiteturas para Sistemas Inteligentes), como parte dos requisitos necessários para a obtenção do Título de Mestre em Informática.

Universidade Federal do Rio de Janeiro

Instituto Tércio Pacitti de Aplicações e Pesquisas Computacionais

Programa de Pós-Graduação em Informática

Orientador: Priscila Machado Vieira Lima

Coorientador: Wouter Caarls

Rio de Janeiro

2017

Alves, Samara Alvarez
474n Negociação no mercado financeiro utilizando a rede neural sem peso WiSARD/ Samara Alvarez Alves. - - Rio de Janeiro, 2017
67 f.

Orientador: Priscila Machado Vieira Lima

Coorientador: Wouter Caarls

Dissertação (mestrado)- Universidade Federal do Rio de Janeiro
Instituto Tércio Pacitti de Aplicações e Pesquisas Computacionais
Programa de Pós-Graduação em Informática, 2017.

1. Negociações de Alta Frequência. 2. Rede Neural Sem Peso WiSARD. 3. Mercado Financeiro. 4. Regressão Ridge. I. Priscila Machado Vieira Lima, Orientador II. Wouter Caarls, Coorientador III. Universidade Federal do Rio de Janeiro IV. Negociação no mercado financeiro utilizando a rede neural sem peso WiSARD

Samara Alvarez Alves

Negociação no mercado financeiro utilizando a rede neural sem peso WiSARD

Dissertação apresentada ao Programa de Pós-Graduação em Informática, Instituto de Matemática e Instituto Tércio Parcitti da Universidade Federal do Rio de Janeiro (área de concentração: Modelos e Arquiteturas para Sistemas Inteligentes), como parte dos requisitos necessários para a obtenção do Título de Mestre em Informática.

Trabalho aprovado. Rio de Janeiro, 20 de Junho de 2017:

Priscila Machado Vieira Lima, Ph.D.

Wouter Caarls, Ph.D.

Josefino Cabral Melo Lima, Docteur

Claudio Miceli Farias, D.Sc.

Alberto Ferreira De Souza, Ph.D.

A minha família Adilson, Maria Rosa e Sabrina.

AGRADECIMENTOS

Agradeço a Deus por ter colocado em meu caminho pessoas incríveis, as quais acumulei débitos de gratidão pelo apoio e colaboração para a conclusão desse trabalho.

Agradeço aos meus pais, Adilson e Maria Rosa, e a minha irmã, Sabrina, por serem meus maiores pontos de equilíbrio e força.

Agradeço ao meu namorado, Raphael, por me acompanhar nessa jornada, tolerando minhas ausências e vibrando com cada pequena conquista.

Agradeço aos meus orientadores, Priscila Machado Vieira Lima e Wouter Caarls, por todos os conselhos, paciência, dedicação, otimismo e pela confiança sempre depositada.

Agradeço aos professores participantes da banca examinadora por aceitarem dividir comigo este momento tão importante e esperado: Josefino Cabral Melo Lima, Claudio Miceli Farias e Alberto Ferreira De Souza.

Agradeço aos professores Carlos Eduardo Pedreira e Josefino Cabral Melo Lima pelos preciosos aconselhamentos durante a fase de qualificação deste trabalho.

Agradeço a professora Jonice de Oliveira Sampaio por ter me recebido da melhor maneira possível no laboratório Cores.

Agradeço aos amigos do laboratório Cores pelo acolhimento, incentivo, discussões e projetos divididos ao longo desse caminho. Em especial, agradeço ao amigo Fabio Rangel pela ajuda valiosa em várias etapas.

Agradeço ao grande amigo Fabrício Firmino não só pelos conselhos, incentivos e paciência além do normal, mas por estar presente nos momentos em que eu mais precisei, nos quais muitas vezes abdicou de suas próprias tarefas para me ajudar.

Agradeço a grande amiga Priscila Mello por ter compartilhado comigo todos os passos, desde a inscrição no programa até a defesa.

Agradeço ao meu padrinho, Antônio Paulo, pela presença constante em todos os momentos em que precisei.

"Se eu vi mais longe, foi por estar sobre ombros de gigantes."
(Isaac Newton)

RESUMO

O presente trabalho analisa o desempenho da rede neural sem peso WiSARD aplicada às ações mais representativas negociadas na bolsa brasileira, BM&FBovespa, em três etapas. Na primeira etapa, a WiSARD é empregada na tarefa de previsão das tendências dos preços das ações baseada em uma estratégia que utiliza médias móveis. Na segunda etapa, é proposto um agente negociador (AN1) capaz de operar no mercado de transações diárias. Nesse agente, as melhores políticas de compra e venda são modeladas por meio de um processo de decisão de Markov (MDP) via programação dinâmica. De maneira a auxiliar a tomada de decisão, adota-se a WiSARD com o objetivo de previsão das tendências das ações com base na mesma estratégia estudada na primeira etapa. Na terceira etapa, um novo agente negociador (AN2) capaz de operar no mercado de alta frequência é apresentado. Este agente compõe-se, assim como o AN1, dos módulos de previsão e decisão. No módulo de previsão, é utilizado o modelo de regressão *ridge* com o objetivo de prever os valores futuros dos preços dos papéis transacionados. No módulo de decisão, a WiSARD é aplicada com o objetivo de aprender as regras estáticas do índice de força relativa (RSI) de maneira a identificar oportunidades de submissões de ordens de compra e venda neste mercado. Para a avaliação da primeira etapa, a acurácia média na previsão das tendências dos papéis em estudo e do tempo de processamento da WiSARD são comparadas aos desempenhos dos classificadores SVM e KNN. Nos resultados, a WiSARD apresentou boa acurácia e o menor tempo de processamento dentre todos os classificadores, sendo este um requisito para classificação em mercados de frequências mais altas. Os resultados experimentais mostraram que utilizar a estratégia do MDP permite que o agente tenha ganho médio maior e menor volatilidade se comparados aos lucros obtidos por uma estratégia simples. Na terceira etapa, os experimentos em um conjunto de dados reais do mercado de alta frequência revelaram ser possível codificar as regras do indicador RSI na WiSARD de forma compatível com o tempo de reação exigido pelas atualizações neste tipo de mercado.

Palavras-chaves: WiSARD. negociação de alta frequência. índice de força relativa. regressão *ridge*. processo de decisão de Markov.

ABSTRACT

This work analyzes the performance of the weightless neural network WiSARD applied to the most negotiated stocks in the brazilian market, BM&FBovespa, at three steps. At the first step, the WiSARD is employed in the task of forecasting stock price trends in a strategy that uses moving averages. At the second step, a trader agent proposed is able to negotiate in the daily transaction market. The best buying and selling policies are modeled as a Markov decision process (MDP) via dynamic programming. In order to assist the decision making, the WiSARD is adopted with the goal of forecasting stock price trends based on the same strategy studied in the first step. At the third step, a new trader agent able to negotiate in the high frequency trading market is proposed, similarly to the trader agent of the second step. This agent is composed of forecasting and decision modules. The forecasting module uses ridge regression in order to forecast future price movements. The decision model implements the relative strength indicator (RSI) trading rules into WiSARD. In the first evaluation step, we compared WiSARD with SVM and KNN classifiers to validate the forecasting accuracy and processing time. The WiSARD showed high accuracy and smaller processing time among all classifiers, which is a requirement in higher frequency markets. In the evaluation of the second step, we compared the final capital obtained by MPD polices with simple trading rules. The experimental results showed that the MDP strategy had better average and less volatile gain when compared to the simple strategy. In the third evaluation step, experimental results on a real dataset from the high frequency market showed that it is feasible to encode RSI indicator trading rules in WiSARD in a way that it is compatible to the reaction time required by online market updates.

Keywords: WiSARD. high frequency frading. relative strength indicator. ridge regression. Markov decision process.

LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema de sistema modelado como MDP (PELLEGRINI; WAINER, 2007). 18
Figura 2 – Hiperplano de máxima margem (HOREWICZ; JR; SILVA, 2006). . . 20
Figura 3 – Discriminador da WiSARD na fase de treino. 22
Figura 4 – Discriminador da WiSARD na fase de classificação. 22
Figura 5 – Fase de classificação da WiSARD. 23
Figura 6 – AN1 28
Figura 7 – AN2 31
Figura 8 – Quantidade de exemplos para cada fase na base de treino inicial. . . . 39
Figura 9 – Quantidade de exemplos para cada fase na base de teste. 39
Figura 10 – Acurácia dos classificadores para cada série temporal. 40
Figura 11 – Coeficientes da regressão *ridge* em função da regularização na granularidade de 1 minuto. 46

LISTA DE TABELAS

Tabela 1 – Tempo de estudo dos papéis analisados na segunda base de dados. . . 24
Tabela 2 – Estratégias de fases com médias móveis aritméticas (MMA). 26
Tabela 3 – Métricas e procedimentos aplicados nas bases de treino, validação e teste para o módulo de previsão. 35
Tabela 4 – Média do tempo de processamento em segundos para os classificadores na ação BBDC4. 41
Tabela 5 – Matriz de confusão WiSARD na ação BBDC4. 41
Tabela 6 – Matriz de confusão WiSARD na ação PETR4. 42
Tabela 7 – Matriz de confusão WiSARD na ação VALE5. 42
Tabela 8 – Comparação das acurácias dos classificadores e qauntidades de dias de treino e teste. 43
Tabela 9 – Comparação do capital final de ambas estratégias. 43
Tabela 10 – Comparação do retorno médio em um intervalo de 95% de confiança. 44
Tabela 11 – *P-valores* do teste ADF para a ação PETR4. 45
Tabela 12 – Matriz de correlação para a granularidade de 1 minuto. 47
Tabela 13 – Seleção de modelos PETR4 utilizando a granularidade de 1 minuto. . 47
Tabela 14 – Comparação das abordagens usando RMSE e MAE. 48
Tabela 15 – Sumário das negociações com *oráculo* para o próximo instante de tempo. 50
Tabela 16 – Sumário das negociações usando regressão *ridge*. 51

LISTA DE ABREVIATURAS E SIGLAS

WiSARD	*Wilkie, Stonham & Aleksander's Recognition Device*
AN1	Agente negociador 1
AN2	Agente negociador 2
RSI	Índice de força relativa
RLS	Mínimos quadrados recursivos com decaimento exponencial
MDP	Processo de decisão de Markov
SVM	Máquinas de vetor de suporte
KNN	K vizinhos mais próximos
AIC	Critério de informação Akaike
BIC	Critério de informação bayesiano
RMSE	Raiz do erro quadrático médio
MAE	Erro médio absoluto
MMA	Médias móveis simples
MME	Médias móveis exponencial
RAM	Random access memories
PN	Ação preferencial
ON	Ação ordinária
PETR4	Índice Petrobras PN
VALE5	Índice Vale PNA
BBDC4	Índice Bradesco PN
ITUB4	Índice Itau Unibanco PN
ABEV3	Índice Ambev ON
CIEL3	Índice Cielo ON

ITSA4	Índice Itau PN
BRFS3	Índice BR Foods ON
PETR3	Índice Petrobras PN
JBSS3	Índice JBS ON
ADF	*Augmented dickey fuller*

SUMÁRIO

1 INTRODUÇÃO 2
1.1 Cenário e escopo 2
1.2 Objetivos 3
1.3 Trabalhos correlatos 4
1.4 Estrutura do texto 7

2 CONCEITOS BÁSICOS 8
2.1 Mercado financeiro 8
2.1.1 Microestrutura de mercado 8
2.1.2 Negociações de alta frequência 9
2.1.3 Histórico mundial 9
2.1.4 Bolsa de valores brasileira 10
2.1.4.1 Sistema de transações 10
2.1.4.2 Índice bovespa 10
2.2 Técnicas de previsão 11
2.2.1 Análise técnica e fundamentalista 11
2.2.2 Conceitos básicos de séries temporais 11
2.2.3 Indicadores financeiros 13
2.2.3.1 Médias móveis 13
2.2.3.2 Bandas de Bollinger 14
2.2.3.3 Índice de força relativa 14
2.2.4 Modelos de previsão 15
2.2.4.1 Regressão *ridge* 15
2.2.4.2 Mínimos quadrados recursivos com decaimento exponencial 16
2.3 Técnicas de decisão 16
2.3.1 Regras estáticas 16
2.3.2 Modelo processo de decisão de Markov (MDP) 17
2.3.2.1 Definição do MDP 17
2.3.2.2 Iteração de valores 18
2.4 Técnicas de classificação 19
2.4.1 K vizinhos mais próximos (KNN) 19
2.4.2 Máquinas de vetores de suportes (SVM) 19
2.4.3 Redes neurais artificiais sem peso: modelo WiSARD 20
2.4.3.1 Treinamento da WiSARD 21

2.4.3.2 Classificação da WiSARD . . . 22
2.4.3.3 Binarização da entrada . . . 23

3 METODOLOGIA . . . 24
3.1 Base de dados . . . 24
3.1.1 Base de dados diários . . . 24
3.1.2 Base de dados alta frequência . . . 25
3.2 Estudos preliminares . . . 26
3.2.1 Previsão dos preços utilizando estratégias com médias móveis . . . 26
3.2.2 Agente negociador 1 (AN1): compra e venda com estratégias de médias móveis . . . 28
3.3 Agente negociador 2 (AN2) . . . 30
3.3.1 Módulo de previsão . . . 30
3.3.2 Módulo de decisão . . . 32
3.4 Métricas de análise . . . 33
3.4.1 Validação do módulo de previsão . . . 34
3.4.2 Validação do módulo de decisão . . . 35
3.5 Discussão . . . 36

4 RESULTADOS EXPERIMENTAIS . . . 38
4.1 Experimentos sobre a base de dados diários . . . 38
4.1.1 Experimentos com previsão de preços utilizando estratégias com médias móveis . . . 38
4.1.2 Experimentos com AN1: compra e venda com estratégias de médias móveis 42
4.2 Experimentos sobre a base de dados de alta frequência . . . 44
4.2.1 Experimentos com o módulo de previsão do AN2 . . . 45
4.2.2 Experimentos com o módulo de decisão do AN2 . . . 48
4.3 Discussão . . . 49

5 CONCLUSÃO . . . 53
5.1 Trabalhos futuros . . . 54

REFERÊNCIAS . . . 56

ANEXO A – CBIC . . . 61

1 INTRODUÇÃO

Nas operações das negociações automáticas do mercado financeiro as ofertas são transmitidas, distribuídas e executadas eletronicamente. A inovação tecnológica nessas operações encontra-se focada no aumento da velocidade de processamento das transações de forma a permitir a diminuição dos custos e a ampliação dos ganhos de eficiência nos processos de execução das ordens de compra e venda. Nesse sentido, uma das transações mais comuns de agentes de *software* é a negociação automatizada em mercados eletrônicos.

1.1 CENÁRIO E ESCOPO

Negociações no mercado financeiro podem ocorrer com frequências variadas compondo diferentes estratégias, as quais respeitam a regularidade estabelecida pelo agente que inspeciona o mercado e o modo como proceder nesse comércio. Muitos participantes trabalham com estratégias do tipo *buy and hold*, as quais se constituem em comprar ações e esperar prazos longos para formar um patrimônio. Outros participantes, por sua vez, optam por negociações com frequências de médio prazo que podem ser diárias, mensais, trimestrais, etc. Há, ainda, participantes que adotam estratégias de comercializações intradiárias. Estas se traduzem em várias transações durante um mesmo dia, e, portanto, classificam-se em estratégias de curto prazo.

O crescimento das negociações em mercados eletrônicos e a sua expansão por diferentes tipos de plataformas ampliou o acesso das transações de instrumentos financeiros, ao mesmo tempo que estimulou a inovação das estratégias de negociação. Nesse contexto, as negociações de alta frequência assumiram uma significativa relevância no cenário global dos mercados financeiros (ANGEL; HARRIS; SPATT, 2011). A atuação dos agentes, nesse tipo de negociação, ocorre, comumente, por meio de algoritmos próprios, nos quais a submissão e o cancelamento de ordens são realizadas em volumes elevados em intervalos de tempo que vão de microssegundos a dezenas e centenas de segundos dentro de um dia.

Os algoritmos de *software*, enquanto modelos computacionais orientados, permitem a execução das ordens no mercado seguindo parâmetros previamente definidos. Nesse contexto, a importância cada vez mais relevante dos algoritmos próprios para negociação de instrumentos financeiros impulsionou os recentes trabalhos de pesquisas

na área de transações de alta frequência.

1.2 OBJETIVOS

Os algoritmos que modelam negociações de alta frequência enfrentam dois desafios: o de receber uma grande quantidade de dados a cada milésimo de segundo e o de ter de reagir rapidamente às mudanças ocorridas no mercado. Nesse sentido, os algoritmos aplicados no cenário de alta frequência pertencem às classes dos algoritmos *online*, uma vez que novos dados de entrada são revelados sequencialmente. Isso significa que após cada nova entrada, rápidas decisões devem ser tomadas em resposta às atualizações do mercado para garantir um tempo de reação adequado. A manipulação eficiente da memória torna-se, portanto, uma necessidade para um algoritmo aplicado nesse cenário (LOVELESS; STOIKOV; WAEBER, 2013).

Posto isso, o presente trabalho analisa o desempenho da rede neural sem peso WiSARD (*Wilkie, Stonham & Aleksander's Recognition Device*) (ALEKSANDER; THOMAS; BOWDEN, 1984) aplicada às ações mais representativas negociadas na bolsa brasileira BM&FBovespa, em três etapas. Na primeira etapa, a acurácia da WiSARD é avaliada na tarefa de previsão das tendências, definidas por meio de estratégias baseadas em médias móveis, dos preços diários das ações: PETR4, VALE5 e BBDC4. Na segunda etapa, é proposto um primeiro agente negociador (AN1) autônomo, capaz de negociar no mercado brasileiro, composto por dois módulos: um módulo de previsão e um módulo de decisão. Nesse contexto, o módulo de previsão é composto pela WiSARD na tarefa de previsão dos preços, seguindo a mesma modelagem da primeira parte do trabalho. No módulo de decisão, com o objetivo de encontrar a melhor política para identificar oportunidades de negociação, modela-se o mercado por meio de um processo de decisão de Markov (MDP) via programação dinâmica. Essa segunda etapa é aplicada nas séries de preços diários das ações: ITUB4, ABEV3, BBDC4, PETR4, CIEL3, ITSA4, BRFS3, PETR3, JBSS3 e VALE5.

A terceira etapa, por sua vez, propõe um segundo agente (AN2) autônomo capaz de perceber as tendências e movimentações da série de preços da ação PETR4 no cenário de negociações de alta frequência. O AN2 compõe-se, assim como o AN1, dos módulos de previsão e decisão. Para o módulo de previsão, é utilizado o modelo de regressão *ridge* com o objetivo de prever os valores futuros dos preços da ação, de maneira rápida e precisa, a fim de auxiliar o módulo de decisão a identificar as melhores estratégias de negociação. No modelo de regressão escolhido é utilizado um termo de regularização na função de perda, que serve para reduzir a variância dos coeficientes de regressão e, portanto, a variância do erro de previsão. No módulo de decisão, emprega-se WiSARD

na função de aprendizado das regras do indicador técnico, índice de força relativa (RSI) (WILDER, 1978), com o objetivo de identificar oportunidades de submissões de ordens de compra e venda no mercado da ação PETR4.

Nessa terceira parte do trabalho, a rede neural sem peso WiSARD foi eleita para a tarefa de escolha das melhores estratégias em função das características do cenário, o qual necessita de uma ferramenta que permita adicionar um novo exemplo sem a necessidade de retreinar toda a base novamente. Além disso, como o tempo de resposta às movimentações do mercado definem parte do sucesso do negociador, para esta conjuntura se faz importante trabalhar com uma arquitetura que priorize essa característica.

Na avaliação da primeira etapa, a WiSARD apresenta boa acurácia e o baixo tempo de processamento dentre todos os classificadores comparados, sendo este um requisito para classificação em mercados de frequências mais altas. Na avaliação da segunda etapa, é observado que utilizar a estratégia do MDP permite que o agente tenha ganho médio maior e menor volatilidade se comparados aos lucros obtidos pela estratégia simples de mercado. Na terceira etapa, os experimentos em um conjunto de dados reais do mercado de alta frequência revelaram ser possível codificar as regras do indicador RSI na WiSARD de forma compatível com o tempo de reação exigido pelas atualizações neste tipo de mercado.

1.3 TRABALHOS CORRELATOS

Os mercados financeiros representam tópicos de constante interesse para a organização econômica e social da sociedade moderna. Muitos fatores macroeconômicos podem afetar um mercado financeiro, incluindo situações políticas, condições econômicas, oferta e demanda, expectativas dos investidores, entre outros fatores (HUANG; NAKAMORI; WANG, 2005). A análise de investimento estuda todos esses fatores para prever os preços futuros de uma ação e apoiar decisões lucrativas sobre quando comprar ou vender ações. O problema de previsão do mercado de ações tem sido amplamente estudado nas áreas de finanças, engenharia e matemática nos últimos anos, devido ao seu potencial ganho financeiro (YOO; KIM; JAN, 2005). Nesse cenário, o sucesso de um investidor se caracteriza não apenas pela qualidade da informação que é usada para a tomada das decisões de compra ou venda, mas, também, pelo tempo de reação às mudanças observadas nesse mercado.

Nas últimas décadas, várias abordagens têm sido propostas para prever os mercados de ações e fornecer sistemas de apoio à tomada de decisão (TEIXEIRA; OLIVEIRA, 2010). Estudos anteriores que utilizam dados de negociações no mercado de ações

endereçam diversos aspectos presentes na literatura financeira; em sua maioria, analisam a volatilidade, o retorno, as estratégias de negociação e a previsão do comportamento dos instrumentos financeiros. Modelos estatísticos, como regressão em séries temporais, suavização exponencial e média móvel integrada, pressupõem que as séries temporais em estudo são geradas a partir de um processo linear (KUMAR; MURUGAN, 2013) e tentam modelar o processo subjacente para fazer previsões sobre os valores futuros da série. Por outro lado, técnicas de computação, como redes neurais artificiais têm sido, também, aplicadas no estudo da previsão de séries temporais financeiras, tais como redes neurais *feedforward* (FFNN), máquinas de vetor de suporte (SVM), redes neurais probabilísticas (PNNs) e sistemas neuro fuzzy (CAVALCANTE; OLIVEIRA, 2014).

O maior obstáculo da área de negociações de alta frequência concentra-se na dificuldade de informações disponíveis, uma vez que muitos negociadores bem sucedidos optam por não divulgar suas estratégias, de maneira a utilizá-las apenas para o seu próprio lucro (ALDRIDGE, 2009). Além disso, na literatura dessa área, a maioria dos trabalhos baseia-se em estratégias que utilizam indicadores técnicos na previsão do comportamento do mercado e em recursos de decisão apoiadas em processos de *market making*, que consiste em enviar simultaneamente uma ordem *bid* e uma ordem *ask* para o mercado.

Como exemplo de trabalhos com foco em estratégias de negociação, em (JABBUR et al., 2014) os autores propuseram um agente atuante no mercado de alta frequência, com base em estratégias construídas a partir dos princípios das ondas de *elliot*, responsável por identificar as oportunidades de investimentos. Essa estratégia contou com uma técnica de transação *market making*. A abordagem foi aplicada aos papéis BBDC4, BBSA 3, USIM5, PETR4 e VALE 5 da BM&F Bovespa em intervalos de tempo de 1, 5, 10 e 15 minutos. Nesse trabalho, foi observado que, embora as menores granularidades proporcionassem maiores oportunidades na escala de negociações de alta frequência, em todos os experimentos, geraram um risco maior para as estratégias, pois as tendências verificadas na série temporal de preços em intervalos de tempos menores foram mais incertas. Outro ponto importante foi a verificação das estratégias das ondas de *elliot* e do processo de *market making* em situações realistas do mercado de ações. Como trabalho futuro, os autores sugeriram a introdução de estratégias combinadas a alguns indicadores que têm uma boa performance nesse tipo de mercado, tais quais: o média móvel convergente e divergente (MACD) (APPEL, 1985), os índices de movimentos direcionais (ADX) (WILDER, 1978) e o índice de força relativa (RSI).

Em (GIACOMEL; GALANTE; PEREIRA, 2015) os autores propuseram um agente negociador baseado em uma rede neural *ensemble* com o objetivo de predizer

o movimento da ação (alta ou queda), em vez de prever o seu valor futuro. Para esse método, os experimentos foram testados em dois diferentes cenários: a bolsa de valores norte-americana (menos volátil) e a bolsa de valores brasileira (mais volátil). Na bolsa norte-americana, aplicou-se uma granularidade diária para monitorar o mercado e, na bolsa brasileira, foi adotada a granularidade de 15 minutos. Na arquitetura, composta de duas redes neurais artificiais, foram recebidos como entrada os últimos valores de abertura, de máximo, de mínimo e de fechamento do intervalo que antecede a classificação em 'alta', 'baixa' ou 'não sabe'. As informações da rede foram introduzidas em um agente negociador no mercado com o objetivo de decidir como operar no próximo período de tempo. Nos experimentos, a estratégia foi considerada satisfatória se o agente atingiu uma taxa de ganho acima de 50%. O capital final obtido foi comparando as estratégias mais comuns: a estratégia *buy-and-hold* e uma abordagem trivial que assume que se a ação subiu ou desceu no período anterior ela seguirá esse movimento para o próximo período. Nesse trabalho, foi observado boa performance da rede para o suporte de estratégias e a gestão de carteiras. Como trabalho futuro, o autores verificaram a necessidade de se adotar estratégias com suporte por meio de indicadores técnicos no auxílio da classificação dos próximos movimentos do mercado.

O uso de rede neural de múltiplas camadas foi muito explorado na área financeira, (SILVA et al., 2014) utilizou uma MLP para predizer oscilações positivas, predefinidas de R$ 0.04 em períodos de tempo de 5, 10 e 15 minutos. Como entrada na rede foram utilizados os últimos valores de abertura, de máximo, de mínimo e de fechamento do intervalo, além de indicadores financeiros como: médias móveis, médias móveis exponenciais, índice *commodity channel* (CCI), taxa de mudança (ROC), média móvel convergente e divergente (MACD), os índices de movimentos direcionais (ADX), índice de força relativa (RSI), bandas de Bollinger, indicador *aroon* e oscilador de momento de Chande. A análise estatística dos resultados mostrou que a rede neural é mais eficaz em oscilações de curto prazo (5 minutos) quando comparada com os resultados obtidos em períodos mais longos (10 ou 15 minutos), por permitir um número maior de ordens submetidas à bolsa.

O trabalho (SOUZA; FREITAS; ALMEIDA, 2010) empregou a rede neural sem peso Virtual Generalized Random Access Memory (VG-RAM) com o objetivo de prever os retornos semanais de 46 ações da BM&FBovespa. Nos experimentos desse artigo, os desempenhos da rede VG-RAM foram comparados aos alcançados pela rede neural autoregressiva (ARNN). Nos resultados experimentais, os autores observaram que os níveis de erros foram similares na previsão das duas abordagens, contudo a execução da VG-RAM foi 5000 vezes mais rápida. Essa vantagem motivou a proposta de um sistema que negocia ações no mercado financeiro de alta frequência (SOUZA; FREITAS;

ALMEIDA, 2012), no qual a compra e a venda das ações foram realizadas a cada 4 minutos com base na previsão da rede neural VG-RAM WNN, para cada uma das 46 séries temporais de preços da BM&FBovespa. A compra das ações mais promissoras foram realizadas no tempo atual t e vendidas no tempo futuro $t + 4$. Após cada venda foram computados os retornos do investimento considerando a comissão de R$ 5,00 por ordem (R$ 10,00 por negociação), uma taxa de imposto de 2% sobre a comissão da corretora e uma taxa de 0,026% sobre o volume negociado. Ao longo de toda a base de dados, o agente executou 202 negociações que inciadas com um capital R$ 40.000,00 resultaram em um capital de R$ 54.164,21, o que corresponde um aumento de 35,4% em um mês.

Em (FREITAS; FREITAS; SOUZA, 2016) é descrita uma arquitetura de negociação robusta, denominada *intelligent trading architecture* (ITA), que teve como objetivo decompor a negociação no mercado financeiro em tarefas designadas a agentes autônomos diferentes, com uma coordenação mínima entre eles. As tarefas de negociações desse sistema foram divididas nos seguintes subproblemas: geração de sinal, negociação e operação. A geração de sinais implementou assessoria de investimento para avaliar dados de mercado relativos a um conjunto de ativos em busca de oportunidades de negociação. A negociação observou esses sinais gerados e desenvolveu estratégias de transações, aplicando conjuntos de regras predefinidas e restrições que produzem decisões para manter ou liquidar posições em um conjunto de ativos. A operação observou as demandas e as liquidações de posições de maneira a convertê-las em ordens de compra e venda, além de enviar essas ordens ao mercado e monitorar sua execução. A arquitetura ITA empregou o *carnegie mellon navigation* (CARMEN), proposto em (MONTEMERLO; ROY; THRUN, 2003), que é um *software* de controles de robôs baseado em uma estrutura de comunicação, na qual grupos de mecanismos permitem aos processos transferirem informação entre si. Além disso, o módulo do sistema responsável pelos envios de ordens para a bolsa de valores por meio do *limit order books* (LOB) superou os desempenhos das implementações de referência em todos os parâmetros avaliados.

1.4 ESTRUTURA DO TEXTO

O trabalho está dividido em 5 capítulos, incluída esta introdução. O Capítulo 2 apresenta o cenário em que os dados estão inseridos e as técnicas de previsão e decisão adotadas nas etapas que compõem esta dissertação. O Capitulo 3 aborda a metodologia usada nos experimentos do sistema de negociação proposto e a metodologia de cada uma das etapas. O Capitulo 4 expõe os resultados dos experimentos e a análise e o Capitulo 5 as conclusões e trabalhos futuros.

2 CONCEITOS BÁSICOS

A análise dos dados do mercado financeiro de ações aplicada ao presente trabalho é a análise técnica. Nela, o comportamento histórico de uma ação é entendido como uma série temporal financeira. Portanto, este capítulo descreve o cenário em que os dados em análise estão inseridos, os conceitos básicos necessários para o entendimento das propriedades de uma série temporal e os instrumentos estudados para a previsão do seu comportamento e a tomada de decisão de compra e venda das ações. Cabe esclarecer, também, que os modelos de classificação apresentados neste capítulo podem ser empregados tanto na tarefa de previsão como na tarefa de decisão.

2.1 MERCADO FINANCEIRO

2.1.1 Microestrutura de mercado

As ações comercializadas no mercado financeiro, primário ou secundário, são certificados de compra de uma empresa constituída como sociedade anônima. Essas companhias operam com uma modalidade societária na qual o capital é dividido aos acionistas em formas de ações, fazendo com que a responsabilidade seja proporcional à quantidade de ações adquiridas.

As negociações no mercado primário são ofertas públicas que proporcionam receitas para a companhia. Uma vez negociadas primariamente, essas ações são transacionadas no mercado secundário por meio de operações nas bolsas de valores, ou mesmo em mercados de balcão, podendo ser a vista; a termo; a futuro; ou por meio de opções. Essas negociações são mediadas, principalmente, por corretoras junto às bolsas de valores e executadas dentro do espaço das mesmas pelos seus funcionários durante um período de funcionamento, denominado pregão, e após o pregão principal, denominado *after market*.

O preço disponível para a venda imediata é denominado preço *bid*, enquanto o preço disponível para a compra imediata é denominado preço *ask*. Como nem sempre o preço aceito pelo participante para a venda é compatível com o preço aceito por um outro participante para a compra, define-se como *spread* a diferença entre o preço *bid* e o preço *ask*.

As operações de compra ou de venda tomadas pelos participantes descrevem quais movimentações de preços são benéficas aos mesmos e quais não são. A posição curta,

ou vendida, é tomada quando os participantes esperam que o preço da ação decresça, por sua vez, a posição longa ou comprada é tomada quando os participantes esperam um aumento futuro do preço da ação. No momento em que uma ordem é enviada ao mercado uma posição é aberta, e, posteriormente, quando a transação é efetivada a posição é fechada.

Na posição fechada, é possível contabilizar se as decisões tomadas pelo negociador resultaram em lucro ou prejuízo. Uma forma de pré-determinar o fechamento de uma posição é adotando as estratégias de ordem *stop-loss* ou *stop-gain*. Nelas, garante-se um limite de perda aceitável para o negociador. Dessa forma, quando esse limite é atingido, a posição é fechada de maneira a impedir maiores perdas.

2.1.2 Negociações de alta frequência

O termo negociações de alta frequência, derivado do inglês *High Frequency Trading (HFT)* é impreciso, pois não possui definição legal ou regulatória. Em sua descrição mais genérica, são programas de plataformas que se utilizam de computadores de alta performance para transacionar um grande número de ordens em velocidades muito rápidas.

Esse tipo de mercado faz uso de algoritmos de negociação de maneira a automatizar tomadas de decisões, submeter e administrar ordens após a submissão. Daí, a utilização de computadores de alta complexidade para analisar múltiplos mercados e executar ordens levando em considerações as condições expostas pelos cenários.

2.1.3 Histórico mundial

Os mecanismos de negociações de valores mobiliários exibem um estado contínuo de evolução desde 1602, quando a bolsa de Amsterdam despontou como a primeira bolsa de valores mundial. Posteriormente, na década de 1960, as informações financeiras eram distribuídas manualmente, normalmente através de *ticker tapes*.

Apenas em 1971, com a criação da *National Association of Securities Dealers Automated Quote (NASDAQ)*, inicia-se a era do mercado eletrônico de negociação de ações. Pouco tempo depois, em 1976, a New York Stock Exchange (NYSE) introduz um sistema de transmissão de ordens de compra e venda. Em razão disso, em 1980, os programas de negociações eletrônicas se tornam ainda mais populares (HASBROUCK, 1996).

No final da década de 90, com o advento das redes eletrônicas de comunicação,

definidas como *Electronic Communication Networks (ECNs)*, mudanças significativas permitiram a extensão do tempo de negociação, conhecido como operações *overnight*.

Contudo, a real incorporação de concorrência entre plataformas de negociações foi iniciada primeiro nos Estados Unidos nos anos 2000, quando a *Securities and Exchange Commission (SEC)* instituiu que todas as trocas internas existentes fossem conectadas, de modo que os preços pudessem ser facilmente acessados para apoiar de forma eficaz as negociações no mercado. A *SEC 2005* promulgou o regulamento de sistemas de mercados permitindo o desenvolvimento dos mecanismos atuais de negociação desse país.

2.1.4 Bolsa de valores brasileira

Com a integração da BM&F (bolsa de derivativos) e da Bovespa (bolsa de ações) foi criada, em maio de 2008, a BM&FBovespa. Ainda é a única bolsa de valores mobiliários no país.

2.1.4.1 Sistema de transações

As transações na bolsa de valores ocorrem em uma cadeia de serviços de negociação e pós-negociação (procedimentos que ocorrem após as operações), listadas abaixo:

- Plataforma de negociação: sistema que permite que vendedores e compradores realizem os negócios.
- Câmara de compensação: sistema que realiza os cálculos das posições compradas e vendidas e atua no controle de risco de mercado.
- Câmara de liquidação: sistema que controla e processa as transações dos títulos negociados.
- Central depositária: sistema responsável pela contabilização e guarda dos ativos negociados.

No Brasil, a BM&FBovespa realiza todos os serviços necessários para os participantes do mercado, tais como: transações de compra e venda; compensações; controle do risco; liquidação; e custódia completa dos títulos.

2.1.4.2 Índice bovespa

O Ibovespa é uma carteira teórica estruturada a partir de critérios, regras e procedimentos incluídos no manual de definições e procedimento dos índices

da BM&FBovespa. O principal objetivo é servir como um indicador do desempenho médio dos ativos de maior volume negociado e de maior representatividade na lista da BM&FBovespa.

2.2 TÉCNICAS DE PREVISÃO

2.2.1 Análise técnica e fundamentalista

A teoria do mercado eficiente (FAMA, 1970) pressupõe que as informações sejam acessíveis a todos os seus participantes, uma vez que elas são incorporadas aos preços das ações. Assim, a constante atualização das convicções desses indivíduos sobre os próximos movimentos do mercado acarreta sua aleatoriedade (FAMA, 1965). Essa proposta defende que os preços do mercado de ações seguem um passeio aleatório (FAMA, 1995).

Um passeio aleatório é um processo em que as alterações dos preços no próximo período de tempo independem das alterações de períodos de tempo anteriores. Estatisticamente, isso significa que cada movimento de preço observado no mercado é independente das informações históricas do mesmo, e, portanto, que esses movimentos seguem a propriedade de *Markov*.

Contudo, como é o objetivo de todo sistema de negociação encontrar formas de distinguir entre movimentos de preços previsíveis e aleatórios duas abordagens principais são encontradas na literatura para auxiliar na previsão desse comportamento do mercado de ações: a análise fundamentalista e a análise técnica. A análise fundamentalista compõe-se do conjunto de estudos e análises macroeconômicas das empresas que operam no mercado financeiro (RAPOSO, 2001). Assim, ela se atém a estudar os fatores econômicos que influenciam o preço da ações (MURPHY, 1999).

A análise técnica é composta por ferramentas gráficas e técnicas matemáticas que buscam prever os movimentos das cotações futuras das ações que são negociadas na bolsa de valores. Sendo assim, nessa análise, é observado o comportamento histórico da ação como uma série temporal. Aplicando-se esta abordagem, acredita-se que o histórico de variação do preço de uma determinada ação tenda a se repetir ao longo do tempo. Cumpre destacar que, no presente trabalho, optou-se por adotar a análise técnica.

2.2.2 Conceitos básicos de séries temporais

Uma série temporal pode ser definida como um conjunto sequencial de observações em intervalos de tempo de uma variável aleatória (MADDALA; LAHIRI, 1992).

Elas podem, ainda, ser decompostas em tendência e sazonalidade. A tendência indica o comportamento das observações a longo prazo, ou seja, identifica os momentos de crescimento, de decrescimento ou estabilidade e, ainda, a velocidade com que essas mudanças ocorrem. Já a sazonalidade indica as oscilações de subida e descida que ocorrem em um determinado período.

A proposição de estacionariedade das séries temporais refere-se a sua aleatoriedade em torno de uma média constante (BUENO, 2008). Para a construção de um teste de raiz unitária, suponha-se que a variável aleatória Y_t possa ser representada por:

$$Y_t = \phi Y_{t-1} + \varepsilon \tag{2.1}$$

Em que ϕ é uma raíz unitária e ε é um ruído estocástico. Para que a série temporal Y_t seja estacionária, a restrição $|\phi| < 1$ deve ser atendida. Logo, as hipóteses do teste podem ser definidas como:

$$\begin{aligned} H_0 &: \phi = 1 \ (Y_t \text{ é não estacionária}) \\ H_1 &: |\phi| < 1 (Y_t \text{ é estacionária}) \end{aligned}$$

Subtraindo Y_{t-1} em cada lado da Equação 2.1, tem-se:

$$\Delta Y_t = (\phi - 1)Y_{t-1} + \varepsilon = \tau Y_{t-1} + \varepsilon \tag{2.2}$$

Dessa forma, as novas hipóteses são dadas por:

$$\begin{aligned} H_0 &: \tau = 0 \ (Y_t \text{ é não estacionária}) \\ H_1 &: \tau < 0 \ (Y_t \text{ é estacionária}) \end{aligned}$$

Um teste de estacionariedade muito utilizado é o teste *augmented dickey fuller* (ADF) (DICKEY; FULLER, 1979). Antes de aplicar este teste é válido inspecionar os dados de maneira a descobrir um modelo adequado. Os três modelos básicos utilizados nesse teste são:

- Modelo simples: $Y_t = \phi Y_{t-1} + \varepsilon$

- Modelo com intercepto: $Y_t = \beta_0 + \phi Y_{t-1} + \varepsilon$
- Modelo com intercepto e tendência: $Y_t = \beta_0 + \beta_1 t + \phi Y_{t-1} + \varepsilon$

O parâmetro β_0 é o intercepto, também denominado drift da série; β_1 é o coeficiente de tendência e ϕ é o coeficiente de presença de raiz unitária. Para todos os modelos acima o teste ainda adiciona uma componente ao modelo que considera o número de defasagens tomado na série. A escolha do tamanho da maior defasagem, de modo que os resíduos da série não sejam correlacionados, pode ser executada, entre outros meios, pelos critério de informação Akaike (AIC) (AKAIKE, 1987).

A série de preços das ações são tipicamente não estacionárias, ou seja, sua média e variância alteram-se ao longo do tempo. Para contornar esse problema, na literatura os dados financeiros são analisados pelo retorno das séries de preços (ALDRIDGE, 2009). Uma medida de retorno simples pode ser calculada como mostrado na Equação 2.3, na qual R_t é o retorno do período t, P_t é o preço do instrumento financeiro de interesse no período t, e P_{t-1} é o preço do instrumento financeiro no período $t-1$.

$$R_t = \frac{P_t}{P_{t-1}} - 1 \tag{2.3}$$

2.2.3 Indicadores financeiros

2.2.3.1 Médias móveis

Os preços intradiários do mercado de negociação podem ser muito voláteis, pois estão sujeitos aos efeitos da microestrutura de mercado e ao comportamento das negociações (como mudanças no pregão, horário de almoço, horário de abertura do pregão e horário de fechamento, efeitos de fuso horário). Para minimizar a influência deste ruído e sua propagação na modelagem, faz-se uso de médias móveis para obter um sinal suavizado (VELLA; NG, 2014). O objetivo desse indicador é remover as distorções produzidas pelo mercado, permitindo que o investidor identifique mais claramente as mudanças nas tendências dos preços.

Os indicadores de médias móveis são amplamente usados uma vez que a sua forma de construção e quantificação são simples e fáceis de serem testadas (MURPHY, 1999). Neste trabalho, fez-se uso de dois tipos deles: o indicador de médias móveis simples (MMA) e o indicador de médias móveis exponenciais (MME). No cálculo de médias móveis simples, todos os preços no intervalo de tempo possuem a mesma relevância. Ao

passo que, no cálculo da média móvel exponencial, os dados mais recentes são ponderados com importância superior aos dados mais antigos do intervalo.

Para o cálculo da média móvel exponencial, sejam P_i, $i = 1, ..., t$ os dados dos preços históricos da ação e λ o fator de decaimento exponencial, ou seja, o peso associado aos dados mais recentes da ação. A média móvel exponencial do preço no instante de tempo i, portanto, pode ser calculada pela seguinte expressão:

$$MME(P_i) = \lambda\ P_i + (1 - \lambda) MME(P_{i-1}) \tag{2.4}$$

2.2.3.2 Bandas de Bollinger

Este trabalho faz uso das bandas de Bollinger a fim de estabelecer os pontos de encerramento das posições do negociador. Essas bandas (limites) são traçadas a um determinado número de desvios padrão da média do ativo. Sendo assim, suponha-se que $\text{MMA}(P_t)$ seja a média móvel simples e $\sigma(P_t)$ o desvio dos preços da ação, e $z = 1, 2$ ou 3, isto é, de 1 até 3 desvios da média. As bandas de Bollinger podem ser definidas como:

$$\begin{aligned} \text{Banda (Limite) Superior} &= \text{MMA}(P_t) + z * \sigma(P_t) \\ \text{Banda (Limite) Inferior} &= \text{MMA}(P_t) - z * \sigma(P_t) \end{aligned}$$

Desse modo, é natural entender que os preços das ações estarão, na maior parte do tempo, dentro do limite das bandas e que, portanto, elas podem ajudar a encontrar os futuros valores de máximos e mínimos para os preços.

2.2.3.3 Índice de força relativa

Índice de força relativa, do inglês *relative strength index* (RSI), é um indicador que mede as mudanças dos preços no mercado financeiro e a velocidade com que elas ocorrem. Esse indicador oscila entre 0 e 100 e funciona como um termômetro do esgotamento do mercado. Para um valor de RSI alto, interpreta-se que movimento de compra da ação perdeu o seu estímulo pois os preços estão muito altos. Por outro lado, para um valor de RSI baixo, interpreta-se que o movimento de venda da ação esgotou-se pois os preços estão muito baixos. Portanto, a tarefa desse indicador é gerar sinais que indicam a compra em momentos em que o preço da ação está *oversold* e a venda em momentos em que o preço da ação está *overbought*.

Para o cálculo desse indicador considere-se que t_1 e t_2 são os intervalos subsequentes de negociação da ação e que Pt_i o último preço negociado no período i, onde $i = 1, 2$. Denota-se por U a mudança positiva nos preços, ou seja, quando o preço negociado no segundo período é maior que o negociado no primeiro período, $U = Pt_2 - Pt_1 > 0$. Já se a mudança é negativa, ou seja, se o preço negociado no segundo período é menor que o negociado no primeiro, denota-se por D essa alteração, onde $D = Pt_2 - Pt_1 < 0$. A fórmula de cálculo desse indicador é apresentada a seguir:

$$\text{RSI} = 100 - \frac{100}{1 + \text{RS}} \tag{2.5}$$

Onde $\text{RS} = \frac{\text{EMA}(U)}{\text{EMA}(D)}$. EMA$(U)$ é o cálculo da média móvel exponencial das mudanças positivas dos preços e EMA(D) é o cálculo das médias móveis exponenciais das mudanças negativas dos preços.

2.2.4 Modelos de previsão

2.2.4.1 Regressão *ridge*

O modelo de regressão considera duas séries temporais (X_t, Y_t) e presume que as variáveis X e Y têm relação linear. Em notação matricial, o conjunto de preços negociados pode ser descrito como um vetor $\boldsymbol{y} = (y_0, y_1, ..., y_t)^T$ e o conjunto de variáveis independentes do modelo por uma matriz $\boldsymbol{X}$. Uma vantagem desse modelo é que ele permite a escolha das hipóteses (variáveis independentes) que mais se adaptam ao cenário de estudo. Supondo que a variável dependente do modelo, $\boldsymbol{y}$, tenha uma relação linear com as variáveis independentes, $\boldsymbol{X}$, essa relação pode ser escrita como:

$$\boldsymbol{y} = \boldsymbol{\beta X} + \boldsymbol{\varepsilon}. \tag{2.6}$$

Em que $\boldsymbol{\varepsilon}$ é o vetor de ruídos estocásticos com média zero. A abordagem mais comum para estimar o vetor de parâmetros $\boldsymbol{\beta}$ utiliza métodos de mínimos quadrados ordinários, em que $\boldsymbol{\beta}$ é escolhido de modo a minimizar a soma dos resíduos quadrados da regressão. A solução para este problema de minimização é dada pela equação:

$$\hat{\boldsymbol{\beta}} = (\boldsymbol{X^T X})^{-1} \boldsymbol{X^T y} \tag{2.7}$$

A proposta da regressão *ridge* inclui um termo de regularização de norma l2 na função de perda (HORN; JOHNSON, 1990), a qual permite reduzir a variância dos

coeficientes da regressão e, portanto, a variância do erro do modelo de previsão. Sendo assim, essa abordagem estima o vetor de parâmetros $\boldsymbol{\beta}$ por meio do método de mínimos quadrados com um fator de penalização λ, em que $\lambda \geq 0$:

$$\min_{\beta} \sum_{j=0}^{t} (y_j - \beta_0 - \beta_1 \mathbf{x}_j - ... - \beta_k \mathbf{x}_j)^2 + \lambda \sum_{j=0}^{k} \beta_j^2 \tag{2.8}$$

2.2.4.2 Mínimos quadrados recursivos com decaimento exponencial

Mínimos quadrados recursivos com decaimento exponencial, do inglês *recursive least squares* (RLS), considera um método recursivo que atualiza os parâmetros $\boldsymbol{\beta}$ de forma sequencial e minimiza a seguinte equação:

$$\min_{\beta} \sum_{j=0}^{t} \alpha^{(t-j)} (y_j - \beta_0 - \beta_1 x_j - ... - \beta_k x_j)^2 \tag{2.9}$$

A matriz $\mathbf{M}$ e o vetor $\mathbf{v}$, a cada momento t em que um novo preço é negociado, são descritos pelas equações a seguir:

$$\mathbf{M_t} = \alpha \mathbf{M_{t-1}} + \mathbf{X_t^T X_t} \tag{2.10}$$

$$\mathbf{v_t} = \alpha \mathbf{v_{t-1}} + \mathbf{X_t^T y_t} \tag{2.11}$$

Após cada tempo t, o melhor estimador de $\boldsymbol{\beta}$ é igual a $\mathbf{M_t^{-1} v_t}$. A vantagem do RLS é ser mais eficiente computacionalmente que a sua abordagem clássica. Nesse contexto, a regressão *ridge*, como descrita anteriormente, também pode ser transformada de forma recursiva adicionando o fator de regularização da Equação 2.8 na Equação 2.9 (VAN WATERSCHOOT; ROMBOUTS; MOONEN, 2005).

2.3 TÉCNICAS DE DECISÃO

2.3.1 Regras estáticas

Indicadores técnicos determinam regras estáticas dos momentos de compra e venda das ações no mercado financeiro. Em (WILDER, 1978), o desenvolvedor do indicador RSI, apresentado na Seção 2.2.3.3, estipulou que um sinal de compra é definido quando o indicador atingir valores iguais ou inferiores a 30, enquanto um sinal de venda é emitido quando o indicador atinge valores iguais ou superiores a 70. Regras

alternativas com relação a esses valores extremos foram propostas posteriormente a essa primeira publicação, com base em análises gráficas das tendências desse indicador. Em (RODRÍGUEZ-GONZÁLEZ et al., 2011), por exemplo, os autores propuseram um sistema de negociação que delimitava a compra da ação para valores do RSI entre 30 e 35 e a venda quando o RSI atinge valores entre 65 e 70.

Outra regra muito utilizada no mercado financeiro é a determinação de pontos de *stop-gain* e *stop-loss*. Esses pontos são empregados como ferramentas de gerenciamento de risco que disparam ordens de venda ou compra automaticamente, as quais permitem encerrar a posição atual, tão logo o valor do ativo atinja esses pontos determinados no início das operações. O parâmetro *stop-gain* determina em que ganho máximo o sistema deve fechar a posição, enquanto o parâmetro *stop-loss* determina a perda máxima admissível para cada posição. Uma alternativa a esses pontos de *stop* fixos são os *stop-móveis* que permitem a construção de bandas de ganho e perda máximas adaptadas as movimentações da série de preços.

2.3.2 Modelo processo de decisão de Markov (MDP)

Nos processos de decisão de Markov, do inglês Markov *decision process* (MDP), o agente deve experimentar o ambiente e avaliar as ações que foram tomadas. Dessa forma, são escolhidas as ações que maximizam não apenas as recompensas imediatas, mas também as recompensas futuras. No presente trabalho, o algoritmo estudado para a solução do MDP itera os valores de cada estado do processo por meio de programação dinâmica.

2.3.2.1 Definição do MDP

Os processos de decisão de Markov são processos estocásticos nos quais recompensas são atribuídas às transições de estados. Esses processos obedecem à propriedade de Markov; ou seja: o efeito de uma ação em um estado depende apenas da ação e do estado atual do sistema (e não de como o processo chegou a tal estado); e modelam a possibilidade de um agente interferir periodicamente no sistema executando ações.

Esse processo pode ser representado por uma tupla $(\Omega_s, \Omega_a, R, P)$, onde: Ω_s é um espaço de estados finito; Ω_a é um espaço de ações finito; R é a recompensa imediata de uma transição; e P é a função distribuição de probabilidade das transições de estado, representadas na Equação 2.12. Define-se, ainda, $\gamma \in [0, 1]$ como o fator que representa a diferença de importância entre as recompensas futuras e as recompensas atuais. A função de transição de estado são as probabilidades de transições para um estado s' no tempo

$t+1$ dada uma ação a e um estado s no tempo t:

$$P(s'|s,a) = P(s_{t+1} = s'|s_t = s, a_t = a) \tag{2.12}$$

Assim sendo, em cada etapa, o agente em algum estado s toma uma decisão $a = \pi(s)$ com base apenas nesse estado. Essa ação permite a transição do agente para um novo estado s' com uma recompensa correspondente, $R(s,a,s')$. A solução para um processo de decisão Markov gera uma política ótima π^*, que mapeia cada estado e as ações que maximizam as recompensas das futuras transições de estado (PUTERMAN, 2014).

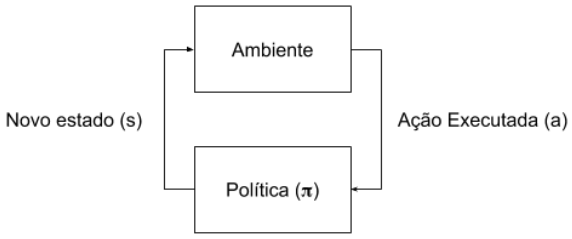

Figura 1 – Esquema de sistema modelado como MDP (PELLEGRINI; WAINER, 2007).

2.3.2.2 Iteração de valores

Existe uma grande quantidade de algoritmos para a solução de MDP's. Alguns dos algoritmos trabalham diretamente com políticas, enquanto outros trabalham com *funções valor*.

A função valor $V(s)$ permite ao agente selecionar ações que maximizam a recompensa imediata correspondente a esse estado, somada à utilidade descontada esperada do próximo estado, supondo-se que o agente escolha a ação *ótima*. A *função valor* é dada pela equação de Bellman (SINGH; COHN et al., 1998):

$$V^*(s) = \max_{a\in\Omega_a} \sum_{s'\in\Omega_s} P(s'|s,a)(R(s,a,s') + \gamma V(s')) \tag{2.13}$$

Seja $V_k(s)$ o valor para o estado s na k-ésima iteração. A etapa de iteração, chamada atualização de Bellman, é dada por:

$$V_k(s) \longleftarrow \max_{a\in\Omega_a} \sum_{s'\in\Omega_s} P(s'|s,a)(R(s,a,s') + \gamma V_{k-1}(s')) \tag{2.14}$$

A Equação 2.14 aproxima a Equação 2.13 iterativamente. Portanto, resolver um MDP equivale a calcular a função de valor resultada de uma política ótima, a qual é definida como:

$$\pi^*(s) = \text{argmax}_{a \in \Omega_a} \sum_{s' \in \Omega_s} P(s'|s,a) \left(R(s,a,s') + \gamma V(s')\right) \tag{2.15}$$

2.4 TÉCNICAS DE CLASSIFICAÇÃO

2.4.1 K vizinhos mais próximos (KNN)

K vizinhos mais próximos, do inglês *k nearest neighbors* (KNN) (FUKUNAGA; NARENDRA, 1975), é um método simples que pode ser aplicado aos problemas de classificação em que a categorização de um dado exemplo baseia-se em uma medida de similaridade com os k exemplos mais próximos do corpus de treino (CUNNINGHAM; DELANY, 2007). Nos problemas de classificação, a classe do novo exemplo é definida pela classe mais comum entre os k vizinhos mais próximos. No caso de $k = 1$, então o novo exemplo é atribuído à classe de seu único vizinho.

Dois pontos principais a serem determinados na aplicação do KNN são: a métrica de distância e o valor de k. As métricas de distância, comumente usadas para variáveis contínuas, são a distância euclidiana, a distância *manhattan* e a distância de *minkowski*. Já para o caso de variáveis discretas, a métrica utilizada é a distância de *hamming*, que compara cada *bit* e aumenta em 1 caso os *bits* sejam diferentes.

Na escolha dos valores de k, é recomendável utilizar valores ímpares. No entanto, esse valor ótimo varia de base para base. Além disso, valores de k muito pequenos interferem no processo de classificação por promover maior sensibilidade do método aos pontos de ruídos nos dados, enquanto valores muito grandes de k podem fazer com que a vizinhança do novo exemplo inclua elementos de outras classes (EVERITT et al., 2011). Algoritmos de otimização podem ser empregados na tarefa da escolha do valor de k que endereça o problema, contudo o desempenho do modelo pode ser prejudicado no processo. Por isso em muitas estudos a escolha desse k é realizada de maneira empírica.

2.4.2 Máquinas de vetores de suportes (SVM)

Maquinas de vetores de suportes, do inglês *support vector machines* (SVM) (VAPNIK; KOTZ, 1982), é um modelo de forte suporte teórico e expressivo sucesso empírico, formulado inicialmente por Vapnik (VAPNIK, 1995) como um classificador não

linear que opera em um espaço de dimensão maior do que o espaço original do conjunto de *features* da base de dados (SOTIROPOULOS et al., 2014).

O SVM corresponde a um método pautado nos princípios provenientes da teoria do aprendizado estatístico (CORTES; VAPNIK, 1995), a qual garante ao modelo as seguintes características: boa capacidade de generalização, robustez em grandes dimensões, convexidade da função objetivo e teoria bem definida dentro dos conceitos matemáticos e estatísticos.

Esse modelo implementa um mapeamento não-linear dos dados de entrada para um espaço de características de alta-dimensão, em que um hiperplano *ótimo* é construído para separar os dados linearmente em duas classes. Sendo assim, quando os dados de treinamento são linearmente separáveis, o hiperplano *ótimo* é aquele que apresenta margem de separação como representada na Figura 2 no espaço de característica dos dados.

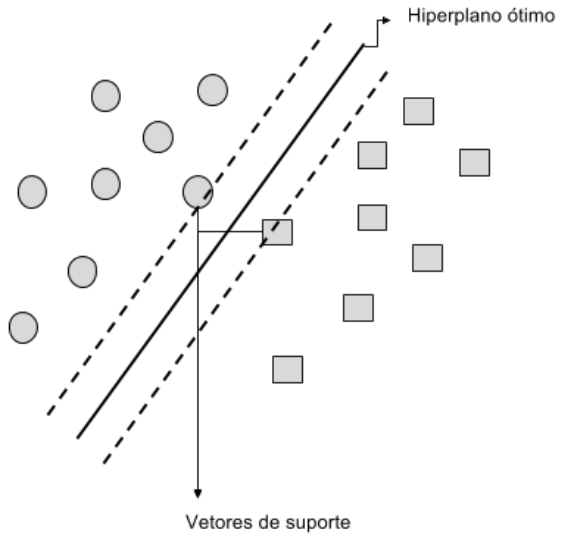

Figura 2 – Hiperplano de máxima margem (HOREWICZ; JR; SILVA, 2006).

Caso os dados de treino apresentem sobreposições em diversas classes, dados não-linearmente separáveis, uma generalização desse conceito é aplicada.

2.4.3 Redes neurais artificiais sem peso: modelo WiSARD

As redes neurais sem peso são também chamadas de redes neurais baseadas em *random access memories* (RAM), pois as informações aprendidas são armazenadas em memória RAM que funcionam como neurônios artificiais. Esses neurônios recebem entradas binárias que são armazenas nessa memória. A WiSARD (ALEKSANDER; THOMAS; BOWDEN, 1984) é um modelo especial de redes neurais sem peso ampla-

mente utilizado em diversas áreas de pesquisa, (CARDOSO et al., 2016), (CARNEIRO; FRANÇA; LIMA, 2015), (GRIECO et al., 2010), com o objetivo de reconhecer padrões que modificam o conteúdo de memórias de acesso aleatório e acumular aprendizado.

Das vantagens desse tipo de rede elencadas em (ALEKSANDER, 1998), destacam-se o rápido treinamento e reconhecimento de padrões e a simplicidade da implementação. Essas características a tornam apropriadas às aplicações em mercados de negociações de alta frequência, já que o agente responsável por tomar as decisões de compra e venda, nesse cenário, precisa reagir de maneira rápida às constantes atualizações do mercado de maneira a se manter competitivo frente aos demais participantes. Dessa forma, eficiência computacional e gerenciamento de memória são características indispensáveis em sua composição.

Este modelo é composto por unidades denominadas discriminadores, sendo cada um deles formado por um conjunto de RAM's responsáveis por uma classe do problema a ser estudado. Cada uma dessas RAM's, por sua vez, tem um número fixo de *bits* de endereçamento aleatoriamente conectado aos padrões de entrada. Como esses padrões de entrada são conectados diretamente aos *bits* de endereçamento da RAM's, eles devem ser convertidos em uma representação binária. A presença de um padrão estimula a linha correspondente do discriminador que procede ao correspondente registro na memória relacionada à linha ativa. Na fase de treinamento, verifica-se o estado de gravação da informação na memória, enquanto na fase de reconhecimento verifica-se o estado de recuperação da informação armazenada (ALEKSANDER; MORTON, 1990).

2.4.3.1 Treinamento da WiSARD

No início do treinamento, as posições de endereçamento das RAM's em cada discriminador encontram-se zeradas. Ao longo dessa fase, ocorre a modificação dos conteúdos armazenados nessas posições. Cumpre esclarecer que a escolha randômica das posições dos *bits* de entrada deve sempre ser a mesma, para todos os discriminadores da WiSARD, assim como para todos os padrões de entrada, de maneira a garantir a integridade do processo de treinamento na fase de reconhecimento.

A Figura 3 representa um discriminador, durante a fase de treinamento, composto por um conjunto de 5 RAM's com 3 *bits* de endereçamento, os quais recebem um padrão de entrada convertido em uma representação binária. Nesta fase, esse padrão de entrada é apresentado somente ao discriminador da classe correspondente. Como é possível observar nessa figura, os valores recebidos nos *bits* de entrada de cada RAM são usados para armazenar o valor 1 na sua posição de endereço.

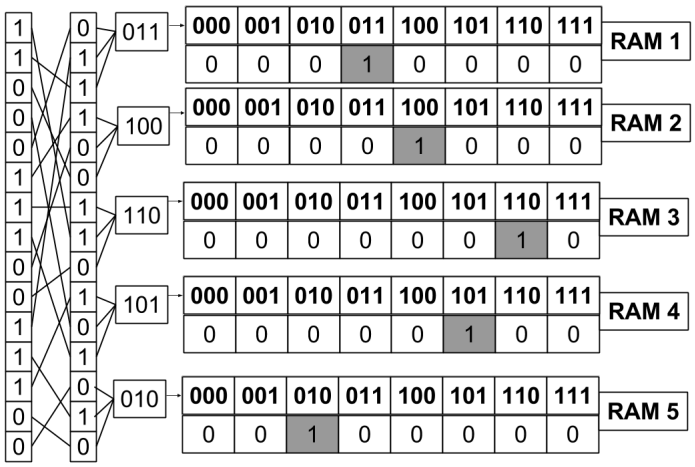

Figura 3 – Discriminador da WiSARD na fase de treino.

2.4.3.2 Classificação da WiSARD

Na fase de classificação, a mesma entrada é apresentada para todos os discriminadores. A Figura 4 representa o mesmo discriminador treinado na Figura 3 na fase atual de classificação. Nesse processo, os valores recebidos nos *bits* de entrada de cada RAM são usados para retornar o valor binário armazenado durante a fase de treinamento. Sendo assim, como a resposta do discriminador é a soma do número de memórias que retornaram 1, a classe do discriminador com o maior valor de resposta é selecionado como a resposta do modelo WiSARD, como ilustrado na Figura 5.

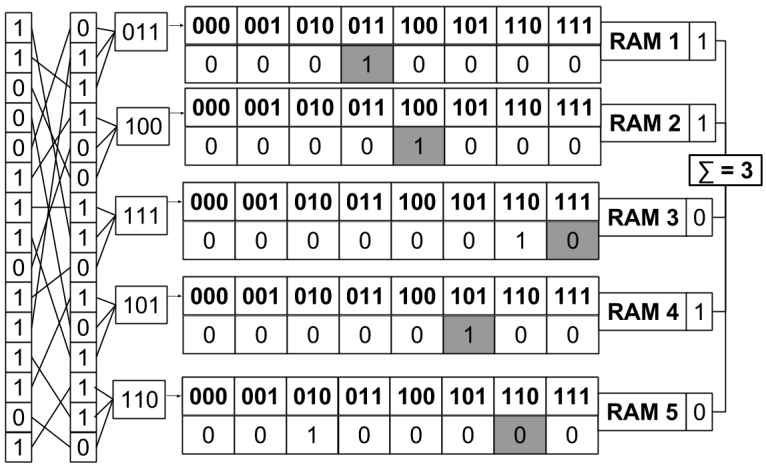

Figura 4 – Discriminador da WiSARD na fase de classificação.

Um problema apresentado pela WiSARD é a saturação da rede: perda da capacidade de reconhecimento quando os discriminadores recebem treinamento em excesso. Essa saturação pode ser reconhecida quando todos os discriminadores respondem positivamente a um determinado exemplo, podendo haver empates no placar ou retorno de valores muito próximos por mais de um discriminador, o que não permite uma classificação confiável. Uma maneira encontrada para contornar esse problema consistiu

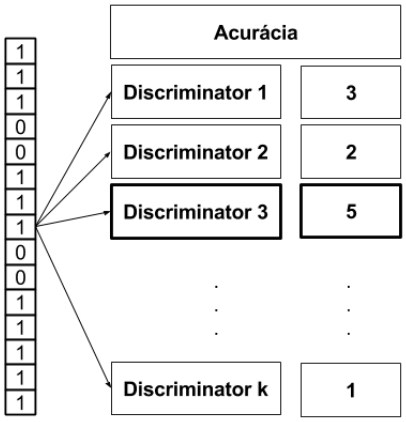

Figura 5 – Fase de classificação da WiSARD.

no emprego do mecanismo de *bleaching*. Esse mecanismo faz uso, durante a etapa de classificação, de posições de memórias endereçadas com valores associados maiores que o valor de *bleaching* predefinido.

Para utilizar esse mecanismo, a fase de treinamento deve ser alterada no seguinte aspecto: em vez de armazenar 1 na memória responsável, incrementa-se 1 ao conteúdo da mesma. Sendo assim, terminada a fase de treinamento, os valores do conteúdo de cada memória variam de 0 a X, onde X é o número de padrões de treinamento (GRIECO et al., 2010).

2.4.3.3 Binarização da entrada

As entradas da rede devem ser binarizadas, uma forma de fazê-lo é adotar a estratégia de binarização por meio de termômetros, em que cada valor de entrada é dividido em faixas de valores com o *bit* zero anotado nas faixas de valores menores que o valor de entrada e o *bit* um anotado nas faixas de valores maiores ou iguais ao valor de entrada. Embora esse tipo de representação necessite de um número grande de *bits* para representar números com precisão elevada a WiSARD continua com bom aproveitamento mesmo com grandes padrões de entrada.

3 METODOLOGIA

Neste capítulo, são descritas as metodologias das três etapas que compõem o presente trabalho como forma de apresentar o processo de maturação da arquitetura dos agentes aplicados no mercado financeiro. Uma vez discorrida as duas primeiras etapas, é apresentada a metodologia detalhada de um agente que tem como objetivo analisar o mercado de alta frequência e tomar decisões de compra e venda.

3.1 BASE DE DADOS

3.1.1 Base de dados diários

Primeiramente, dados diários das séries de preços da Petrobras PN (PETR4), Vale PNA (VALE5) e Bradesco PN (BBDC4) foram analisados no período de 02 de fevereiro de 2009 a 30 de junho de 2015. A seguir, com o objetivo de ampliar o tempo de observações da base de dados e a quantidade de papéis para compor a carteira, a nova base de estudo adicionou 7 novas séries temporais diárias das ações mais negociadas no mercado brasileiro, a saber Itau Unibanco PN (ITUB4), Ambev ON (ABEV3), Cielo ON (CIEL3), Itau PN (ITSA4), BR Foods ON (BRFS3), Petrobras PN (PETR3), JBS ON (JBSS3), correspondendo ao período de 02/01/2008 a 05/10/2015. Como alguns papéis só foram negociados na BM&FBovespa após o dia 02/01/2008, apresenta-se na Tabela 8 o tempo de estudos das 10 ações, a partir da data em que elas começaram a ser comercializadas até 05/10/2015.

Tabela 1 – Tempo de estudo dos papéis analisados na segunda base de dados.

Série	**Data de Início**	**Data de Fim**
PETR4	02/01/2008	05/10/2015
VALE5	02/01/2008	05/10/2015
BBDC4	02/01/2008	05/10/2015
ITUB4	20/05/2009	05/10/2015
ABEV3	11/11/2013	05/10/2015
CIEL3	18/12/2009	05/10/2015
ITSA4	02/01/2008	05/10/2015
BRFS3	10/12/2009	05/10/2015
PETR3	02/01/2008	05/10/2015
JBSS3	02/01/2008	05/10/2015

3.1.2 Base de dados alta frequência

Os dados utilizados na terceira etapa correspondem às séries de preços *tick-a-tick* da PETR4, no período de 30 de setembro de 2015 a 31 de outubro de 2015. Esse conjunto de dados foi coletado através do pacote CRAN da plataforma R (PERLIN; RAMOS, 2016). A base de dados originais compreende o preço e a quantidade negociada a cada *timestamp*, este último registrado como a data e a hora, incluindo os milésimos de segundos, de cada transação. Em (ALDRIDGE, 2009) é afirmado ser um mês suficiente para analisar negociações de alta frequência, porque a pequena granularidade já resulta em um conjunto de dados muito grande.

Os horários do mercado a vista brasileiro funcionam da seguinte maneira: os cancelamentos das ordens ocorrem de 9h30 a 9h45; a pré-abertura funciona de 9h45 a 10h00; a negociação, propriamente dita, é realizada de 10h00 a 16h45; o *call* de fechamento opera de 16h55 a 17h00; e o *after market* decorre de 17h25 a 18h00 [1]. Sendo assim, optou-se por avaliar a negociação das ações no horário de 9h50 a 17h00, uma vez que o mercado de alta frequência não opera nos horários de abertura ou no *after market* devido à alta volatilidade dos preços percebida nesses intervalos de tempo.

Em contraste com os dados tradicionais de baixa frequência, que são regularmente espaçados, os dados de alta frequência ocorrem em intervalos irregulares de tempo (ALDRIDGE, 2009), e, muitas vezes, é possível observar mais de uma negociação no mesmo instante. Dessa forma, com o objetivo de espaçar a base regularmente, no primeiro pré-processamento, anotou-se o preço médio e a quantidade total negociada a cada *timestamp*. No segundo pré-processamento da base, adotou-se a uma interpolação linear ponderada no tempo entre negociações subsequentes considerando um intervalo fixo de tamanho de um minuto. O objetivo principal dessa abordagem proposta em (DACOROGNA et al., 2001) é a suposição de que em qualquer momento as negociações não observadas se encontram em uma linha reta que conecta as duas negociações vizinhas. Matematicamente, esse método pode ser expresso da seguinte forma:

$$\hat{P}_t = P_{t_A} + (P_{t_D} - P_{t_A}) * \frac{t - t_A}{t_D - t_A} \tag{3.1}$$

$\hat{P}_t$ e t são o preço e o tempo incluídos na base por meio desse pré-processamento, t_A é o *timestamp* da última observação antes do tempo t, P_{t_A} é o valor do preço observado no instante t_A, t_D é o *timestamp* da primeira observação depois do tempo t e P_{t_D} é o valor do preço observado no instante t_D. O volume, por sua vez, foi mantido como 0

[1] Todos os períodos seguem o UTC-3:00

para esses tempos em que de fato não ocorreram transições, de maneira a manter a base fiel ao volume de negociações reais.

3.2 ESTUDOS PRELIMINARES

Nos estudos preliminares (primeira e segunda etapa do trabalho), adotaram-se estratégias para a previsão das séries temporais em fases definidas por meio dos indicadores de médias móveis. O conjunto de fases comumente empregado nessas estratégias são fase de recuperação, fase de acumulação, fase altísta, fase de aviso, fase de distribuição e fase baixista (NEOLOGICA,). As definições dessas fases requerem a comparação entre os preços de fechamento da ação no dia (PF) e duas médias móveis, uma de um período mais longo, MMA_L, e uma de um período mais curto, MMA_S, como apresentado na Tabela 2. Essas fases das estratégias correspondem às classes do problema de classificação.

Tabela 2 – Estratégias de fases com médias móveis aritméticas (MMA).

Recuperação	**Acumulação**	**Altísta**
$PF > MMA_S$	$PF > MMA_S$	$PF > MMA_S$
$PF < MMA_L$	$PF > MMA_L$	$PF > MMA_L$
$MMA_S < MMA_L$	$MMA_S < MMA_L$	$MMA_S > MMA_L$
Aviso	**Distribuição**	**Baixista**
$PF < MMA_S$	$PF < MMA_S$	$PF < MMA_S$
$PF > MMA_L$	$PF < MMA_L$	$PF < MMA_L$
$MMA_S > MMA_L$	$MMA_S > MMA_L$	$MMA_S < MMA_L$

3.2.1 Previsão dos preços utilizando estratégias com médias móveis

A primeira etapa do trabalho, que compõe esta dissertação, resultou no artigo aceito e apresentado no 12° Congresso Brasileiro de Inteligência Computacional (CBIC) (ALVES et al., 2015), em outubro de 2015. Nela, apurou-se a previsão das fases dos preços seguindo as estratégias de médias móveis apresentadas na Tabela 2 utilizando os dados das séries temporais da primeira base descrita na Seção 3.1.1. A escolha da rede neural sem peso WiSARD para ser empregada nessa tarefa de classificação das fases proveio da característica dessa rede em se adaptar ao mecanismo do cenário do mercado financeiro, no qual a aprendizagem ocorre de forma *online*, já que os dados são obtidos de forma sequencial (FONTENLA-ROMERO et al., 2013).

A modelagem de cada dia da série foi classificada em uma das seis possíveis fases seguindo as regras da Tabela 2, transformando a série de preços em uma sequência de fases, em que a média móvel curta era de 50 períodos (MMA_{50}) e a média móvel longa era de 100 (MMA_{100}). A janela de tempo para a previsão do próximo preço foi de

5 dias. Dessa maneira uma sequência de classes dos 5 dias anteriores era aplicada com o propósito de predizer a classe do próximo dia.

Para modelar essa sequência de cinco dias no formato de um vetor de *features* (ou retina no caso do classificador WiSARD), adotou-se um modelo no qual cada dia é representado por um vetor com 6 *bits*. Cada um desses 6 *bits* representa uma classe da estratégia de médias móveis. Apenas um *bit* pode assumir o valor 1, sendo este o responsável por representar a classe ao qual àquele dia pertence. O vetor de *features* foi, dessa forma, constituído pela concatenação dos 5 dias consecutivos que antecediam o dia da previsão, possuindo ao final 30 *bits* em sua estrutura. Para os classificadores KNN e SVM a modelagem do vetor de cinco dias anteriores correspondeu as fases corretas dos respectivos dias sem a necessidade de binarização das mesmas.

Primeiramente, treinou-se com os 1023 primeiros exemplos, que correspondiam a 64,54% da base de cada série. Em seguida, para cada dia subsequente, executou-se a previsão da classe daquele dia e, independentemente do acerto, adicionou-se aquele exemplo com sua classificação correta à base de treino. O fato de adicionar o exemplo à base de treino, independentemente do acerto, é uma estratégia que pode ser adotada no cenário de uma classificação real, visto que é possível saber a real classe de um determinado intervalo após o mesmo já ter ocorrido.

Para validar a acurácia e o tempo de treino e reconhecimento da WiSARD, decidiu-se utilizar como classificadores de comparação o SVM e o KNN. Para ambos, os parâmetros foram obtidos de forma empírica, utilizando-se o processo de validação e a série temporal BBDC4. Já no caso do SVM, foram comparadas as seguintes funções de *kernel*: *radial basis function*, *polynomial*, linear e *sigmoid*, visto que para operar em uma dimensão maior que a do espaço de *features* original o SVM depende desse tipo de função.

De maneira a avançar com os estudos desta primeira etapa, na segunda foi construído um agente negociador capaz de tomar decisões de compra e venda no mercado financeiro brasileiro. A segunda base de dados também descrita na Seção 3.1.1, foi ampliada, ou seja, inseriram-se sete novos papéis e aumentou-se o período de estudo desde o início de comercialização dessas ações no mercado brasileiro até o dia 05/10/2015, como explicado na Tabela 8. Ademais, em (VELLA; NG, 2014) os autores especificam que a escolha das janelas de médias móveis deve ser tal que os mecanismos para identificar tendências não podem ser sensíveis a ponto de absorver somente as flutuações de curto prazo; mas também não podem ser muito longas a ponto de levar a reações tardias a esses movimentos. Com a introdução de agente negociador, essa análise do tamanho das médias

móveis tonou-se um parâmetro importante, visto que oportunidades de comercializações podem ser perdidas com o uso das médias móveis longas, como aquelas aplicadas nesta primeira etapa.

3.2.2 Agente negociador 1 (AN1): compra e venda com estratégias de médias móveis

Na segunda parte do trabalho, foi proposto um agente negociador 1 (AN1) constituído por dois módulos: o de previsão e o de decisão, apresentado na Figura 6. O módulo de previsão ficou responsável por classificar a fase do próximo dia e alimentar o módulo de decisão com essa informação. Já o módulo de decisão ficou encarregado de decidir a ação, compra ou venda, a ser tomada no período atual. Nesse contexto, a fim de encontrar a melhor política para identificar oportunidades de negociação optou-se pela modelagem desse mercado por meio de um processo de decisão de Markov via programação dinâmica. Como essa modelagem negligencia efeitos de longo prazo sobre as tendências de preços das ações, a WiSARD foi adotada para auxiliar na decisão de negociação final.

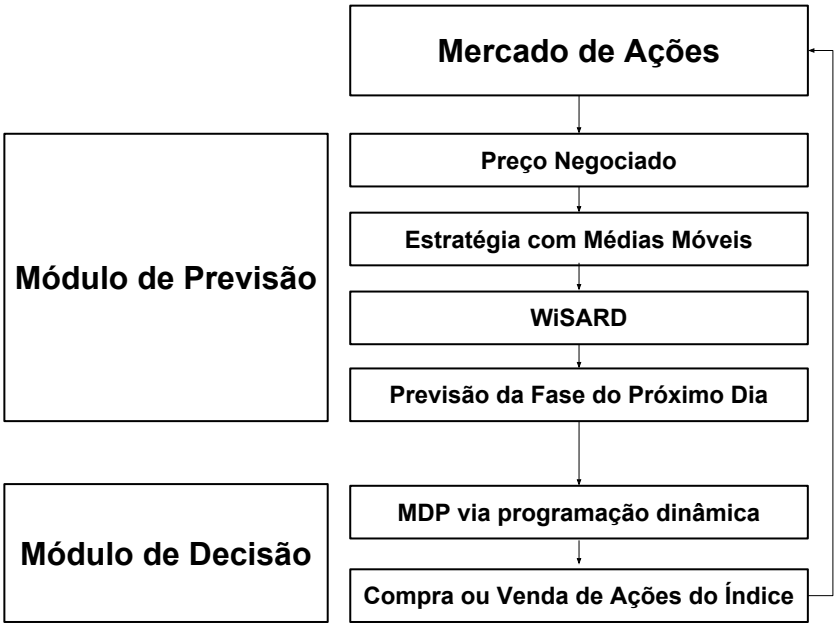

Figura 6 – AN1

Na validação dessa etapa 80% da base foi utilizada para treino e a mesma validação *online* do trabalho anterior foi adotada nesse, ou seja, para cada dia subsequente, independentemente da resposta do classificador da próxima fase, o valor correto correspondendo ao preço daquele dia foi adicionado à base de treino. Assim como na

metodologia da primeira etapa, descrita na Seção 3.2.1, o objetivo da WiSARD foi o de prever a tendência para o dia seguinte. Para avaliar esse primeiro módulo, comparou-se o tempo de previsão e processamento da abordagem, novamente, com o KNN e o SVM.

No módulo de previsão, a classificação da fase do preço no próximo dia adotou a mesma estratégia apresentada na Tabela 2, na qual cada dia da série foi classificado em uma das seis fases. A previsão da fase do dia seguinte baseou-se nas fases de 5 dias anteriores. Porém, optou-se por construir o vetor de características (ou retina no caso do classificador WiSARD) contemplando cada um dos cinco dias anteriores com um vetor de 3 bits. O primeiro bit de cada vetor recebeu o valor 1 se $PF > MMA_S$; o segundo recebeu o valor 1 se $PF < MMA_L$; e o terceiro recebeu o valor 1 se $MMA_S < MMA_L$. O comprimento total da estrutura foi, portanto, composta por 15 partes no total.

No módulo de decisão foram consideradas políticas em que o AN1 sempre comercializa o número máximo de ações possíveis com o capital disponível no momento. Em todas essas transações foi adotado o valor da tarifa sugerida pela BM&FBovespa no valor de $0,0325\%$, desconsiderando, contudo, o valor de corretagem. De maneira a evitar políticas ultrapassadas, o MDP foi construído através do cálculo das probabilidades de transição de estados e preços das ações considerando uma janela de 200 dias antes do dia atual, valor esse que permite ao agente um número considerável de observações históricas da série temporal. A função que itera os valores da política ótima apresentada na Seção 2.3.2.2 foi aplicada para recalcular a política de negociação a cada 10 dias.

Para avaliar o desempenho do módulo de decisão, separadamente da capacidade observada no módulo de previsão, comparou-se o capital final obtido pelo AN1 usando uma abordagem com 100% de acurácia para a classificação da próxima fase. As duas possíveis ações do AN1 foram definidas por: $a = 0$, se ele não executa nenhuma negociação e $a = 1$, se ele toma uma posição, seja de venda ou de compra. Definiu-se, ainda, como estado do AN1, a combinação da fase com o fato dele ter ação (1) ou não (0). Dessa forma, o espaço de ações foi definido por: $\Omega_a = \{0, 1\}$ e o espaço de estados por:

$$\Omega_s = \{(Fase_1, 0), (Fase_1, 1), (Fase_2, 0), (Fase_2, 1), ..., (Fase_6, 0), (Fase_6, 1)\}$$

.

As recompensas do AN1 foram definidas seguindo a regra: $-(1 + 0.0325\%)$ do preço negociado, se o agente comprou ações; $(1 - 0.0325\%)$ do preço negociado, se o agente vendeu ações; e 0, se nenhuma posição foi tomada. Outro ponto importante explorado nesse trabalho foi a seleção do tamanho ideal das médias móveis a serem

aplicadas na determinação das fases da estratégia, a qual derivou de uma política simples de compra no primeiro ponto de baixa e venda no primeiro ponto de alta.

Com o propósito de avançar mais no estudo do mercado financeiro, optou-se por estudar as negociações de alta frequência, posto que a evolução das plataformas das bolsas de valores, impulsionadas pelos investimentos em desempenho computacional, instituíram frequências de transações na escala de milésimos de segundos (NETTLES et al., 2015). Com o objetivo de estudar mais profundamente o módulo de decisão, priorizou-se o aprendizado da rede neural sem peso WiSARD empregada nesse segundo módulo.

3.3 AGENTE NEGOCIADOR 2 (AN2)

A terceira etapa do trabalho descreve um agente negociador 2 (AN2) capaz de transacionar de forma autônoma no cenário de negociação de alta frequência. O AN2 compõe-se de um módulo de previsão e um módulo de decisão. O primeiro módulo prevê os preços futuros e alimenta o módulo de decisão. O segundo módulo aplica os preços previstos para calcular os indicadores técnicos usados para treinar a rede neural sem peso WiSARD na decisão de comprar ou vender ações, como ilustrado na Figura 7.

Cabe esclarecer, também, que a rentabilidade de uma estratégia de compra e venda é limitada pela frequência de negociação escolhida, contudo a melhor granularidade (tempo em que o agente monitora o comportamento da ação) utilizada no mercado financeiro não é divulgado pelas empresas, as quais priorizam esse sigilo em prol de seu próprio lucro (ALDRIDGE, 2009). Sendo assim, optou-se por utilizar as granularidades de 1, 5, 10 e 15 minutos, assim como muitos trabalhos recentes na área (JABBUR et al., 2014), (GIACOMEL; GALANTE; PEREIRA, 2015), (SILVA et al., 2014).

3.3.1 Módulo de previsão

Com objetivo de modelar os movimentos futuros dos preços usando o histórico da série, a maioria dos modelos lineares requer que as propriedades distributivas dos dados, média e variância, permaneçam aproximadamente constantes ao longo do tempo, ou seja, estacionárias, (ALDRIDGE, 2009). No entanto, dados financeiros são frequentemente não-estacionários. Analisaremos esses dados definidos da seguinte forma:

$$R_t = \frac{P_t}{P_{t-k}} - 1 \tag{3.2}$$

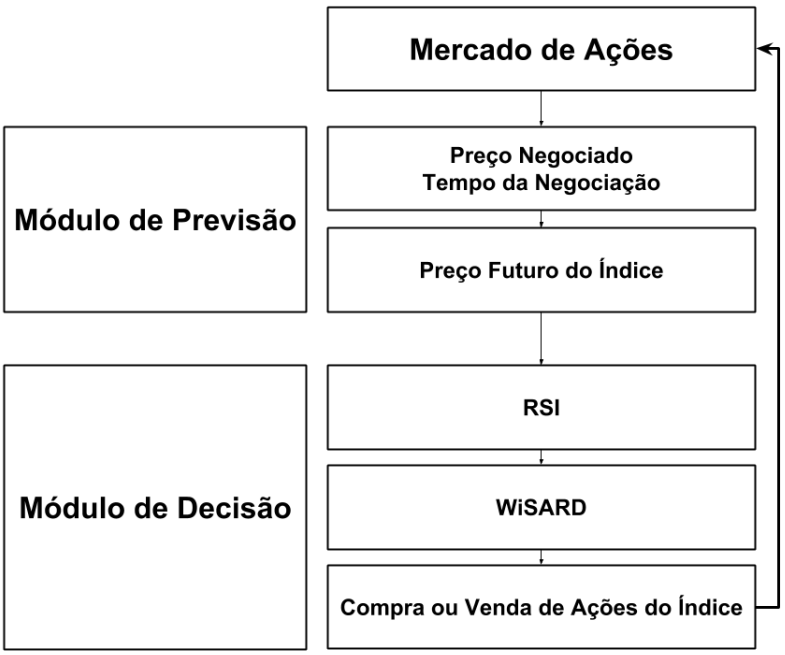

Figura 7 – AN2

Onde k é a granularidade do intervalo, R_t é o retorno da ção no tempo t, P_{t-k} e P_t são o primeiro e o último preços desse intervalo de tempo, respectivamente. De forma a não perder informações inseridas dentro do intervalo, utilizou-se uma janela de deslizante para compô-los. Portanto, em um intervalo de 5 minutos, por exemplo, o primeiro intervalo começa no tempo t_0 e termina no tempo t_5. O segundo intervalo é iniciado no tempo t_1 e finalizado no tempo t_6, e assim sucessivamente.

Para definir o módulo de previsão, utilizou-se um modelo de regressão *ridge*, como explicado na Seção 2.2.4.1. Neste modelo o vetor de variáveis dependentes, $\boldsymbol{y}$, foi definido pelos retornos da série de preços, enquanto a matriz de variáveis independentes, $\boldsymbol{X}$, foi composta pelo tempo da negociação; por uma combinação de médias móveis longa (MMA_L) e curta (MMA_S) e por um componente de suavização exponencial (EXP). Esta última foi definida pela seguinte equação:

$$\widehat{P_i} = \alpha\ P_{i-1} + (1-\alpha)\widehat{P}_{i-1}. \tag{3.3}$$

Em que $\widehat{P_i}$ define o valor estimado do preço P_i, $i = 1, ..., t$ e α representa o fator de decaimento exponencial, isto é, o quanto de importância para a previsão dos próximos dados é associado ao preço anterior. Desse modo, quanto mais alto for o valor de α, mais suave será o sinal de entrada que contribui para a previsão dos preços.

3.3.2 Módulo de decisão

O módulo de tomada de decisão recebe do mercado as informações dos dados históricos da ação e o retorno no próximo instante de tempo $\hat{R}_{t+1}$ calculado no módulo de previsão. De posse dessas informações, o AN2 calcula, por meio da função inversa da Equação 2.3, o preço no final do intervalo de avaliação:

$$\hat{P}_{t+1} = P_{t+1-k} * (\hat{R}_{t+1} + 1) \tag{3.4}$$

Em que P_{t+1-k} é o primeiro preço do intervalo de tempo de granularidade k, $\hat{R}_{t+1}$ é a previsão do retorno do intervalo e $\hat{P}_{t+1}$ é o preço previsto do final do intervalo. Em seguida, o AN2 calcula o valor do RSI, onde γ é o fator de decaimento exponencial deste indicador, no instante $t + 1$, seguindo o algoritmo:

Algorithm 1 Cálculo RSI

function EMA(P, k)
  for i **do** 1: n
    diff $= \hat{P}_{i+1} - P_{i+1-k}$ ▷ Calcular a diferença de preços no intervalo
    if diff > 0 **then**
      $\text{ema}_u = \alpha * |\text{diff}| + (1 - \alpha) * \text{ema}_u$ ▷ Calcular a média móvel exponencial das mudanças positivas dos preços até o presente intervalo
      $\text{ema}_d = \alpha * 0 + (1 - \alpha) * \text{ema}_d$
    end if
    if diff < 0 **then**
      $\text{ema}_d = \alpha * |\text{diff}| + (1 - \alpha) * \text{ema}_d$ ▷ Calcular a média móvel exponencial das mudanças negativas dos preços até o presente intervalo
      $\text{ema}_u = \alpha * 0 + (1 - \alpha) * \text{ema}_u$
    end if
    if diff $= 0$ **then**
      $\text{ema}_u = \alpha * 0 + (1 - \alpha) * \text{ema}_u$
      $\text{ema}_d = \alpha * 0 + (1 - \alpha) * \text{ema}_d$
    end if
  end for
end function

function RSI($\text{ema}_d, \text{ema}_u$)
  if $\text{ema}_d = 0$ **then**
    return 0
  else
    rs $= \text{ema}_u / \text{ema}_d$
    rsi $= 100 - 100/(1 + \text{rs})$
    return rsi
  end if
end function

O módulo de decisão do AN2 usou o modelo de rede neural sem peso WiSARD para aprender as regras de decisão baseadas no rsI. A regra estática adotada aconselha o sistema a comprar ações se este indicador é inferior a 30 e a vender se for maior do que 70. A rede foi alimentada com as entradas convertidas em representação binária usando uma codificação que registra o valor do indicador. Para esta modelagem, optou-se por adotar a estratégia de binarização por meio de termômetros, em que cada valor do indicador é dividido em faixas de valores com o *bit* 0 anotado nas faixas de valores menores ou iguais ao valor de entrada e o *bit* 1 anotado nas faixas de valores maiores ou iguais ao valor de entrada. Como o RSI varia entre 0 e 100 o tamanho do termômetro é definido como $(max - min)/parts$, onde $parts$ representa a quantidade partições do vetor, max e min representa o máximo e o valor mínimo do indicador, respectivamente.

3.4 MÉTRICAS DE ANÁLISE

A teoria do mercado eficiente pressupõe que os preços do mercado de ações seguem um passeio aleatório (FAMA, 1995). Isso significa que a informação sobre o mercado é acessível a todos os investidores o que diminui a probabilidade de detectar uma oportunidade de lucro nas negociações. Dessa forma, contradizer essa teoria é defender que as mudanças nos preços das ações não são aleatórias, e que, portanto, as oportunidades de negociações têm previsibilidade consistente. Testes de eficiência do mercado avaliam as séries temporais das ações de maneira a encontrar os mercados de maior ineficiência, ou seja, aqueles com as maiores oportunidades de lucro. (ALDRIDGE, 2009) formalmente especifica que um passeio aleatório segue a definição a seguir:

$$P_t = P_{t-1} + \varepsilon \tag{3.5}$$

Onde P_t e P_{t-1} são os preços da ação no tempo t e no tempo anterior $t-1$, respectivamente. Para avaliar se os dados de alta frequência das séries de preços em estudo no presente trabalho seguem um passeio aleatório, aplicou-se o teste Dickey Fuller Aumentado (DICKEY; FULLER, 1979). A hipótese nula do teste é que no modelo simples, representado na Equação 3.6, $\phi = 1$. Onde ϕ é o coeficiente de presença de raiz unitária e ε é um ruído branco de média 0.

$$P_t = \phi P_{t-1} + \varepsilon \tag{3.6}$$

3.4.1 Validação do módulo de previsão

Nesta seção são definidas as métricas de avaliação do desempenho do AN2 no módulo de previsão. Com o objetivo de adotar uma avaliação própria para o cenário de aprendizado *online* janelas deslizantes foram utilizadas. Nesse sentido, a primeira sequência de dados da base forma a primeira base de treino dos retornos históricos das ações. Em seguida, para cada instante de tempo subsequente, tenta-se prever o retorno da ação, e independente do acerto do modelo de previsão, adiciona-se aquele exemplo com sua previsão correta a base de treino.

A avaliação desse módulo ocorreu em três etapas aplicadas, respectivamente, nas bases de treino, validação e teste. Na primeira etapa, selecionou-se os parâmetros: fator de regularização, λ, (Equação 2.8) e fator de decaimento exponencial, α, (Equação 3.3). Para a escolha do parâmetro λ, da regressão *ridge*, é preciso que se mantenha equilíbrio entre o ajuste e a complexidade do modelo. Um critério amplamente utilizado para avaliar a escolha desse fator é o critério de informação de *akaike* (AIC) (SCHWARZ et al., 1978), que mede o equilíbrio entre o ajuste e a complexidade do modelo.

Na segunda etapa, avaliou-se a seleção das variáveis independentes do modelo de regressão *ridge* (tempo da negociação, média móvel longa (MMA_L), média móvel curta (MMA_S) e suavização exponencial (EXP)). As etapas de treino e validação foram executadas até que todas as combinações possíveis das hipóteses dos preços fossem apuradas. Nesse contexto da segunda etapa, as seguintes métricas foram aplicadas: raiz do erro quadrático médio, do inglês *root mean square error* (RMSE), erro médio absoluto, do inglês *mean absolute error* (MAE), o C_p de Mallows (MALLOWS, 1973), o critério de informação de Akaike (AIC) e o critério de informação de bayesiano (BIC) (SCHWARZ et al., 1978). Para os cálculos das métricas, suponha $\hat{\boldsymbol{r}}$, o vetor de n retornos estimados e $\boldsymbol{r}$, o vetor de n retornos observados correspondente às entradas para a função que gerou as previsões, então RMSE da previsão pode ser estimada por:

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(\hat{r}_i - r_i)^2}{n}} \tag{3.7}$$

A métrica MAE é calculado pela seguinte expressão:

$$MAE = \frac{\sum_{i=1}^{n}|\hat{r}_i - r_i|}{n} \tag{3.8}$$

Consequentemente, pode-se entender que o melhor modelo de previsão dentre os avaliados, será aquele que obtiver menores valores de RMSE e MAE. As três próximas

métricas (C_p de Mallows, AIC e BIC) foram empregadas na seleção das variáveis independentes (tempo da negociação, média móvel longa (MMA_L), média móvel curta (MMA_S) e suavização exponencial (EXP)) que melhor explicavam a variável dependente (retornos da série de preços) no modelo de regressão *ridge*. Essas métricas são definidas a seguir:

$$C_p = \frac{\sum_{i=1}^{n}(\hat{r}_i - r_i)^2}{MSE} - n + 2 * (p + 1) \tag{3.9}$$

Em que p é a quantidade de variáveis independentes do modelo. A estratégia usada para selecionar modelos com esse critério é identificar os que retornam C_p próximo do número $(p + 1)$.

$$AIC = 2 * p + n * log \sum_{i=1}^{n}(\hat{r}_i - r_i)^2 \tag{3.10}$$

$$BIC = p * log(n) + n * log \sum_{i=1}^{n}(\hat{r}_i - r_i)^2 \tag{3.11}$$

Essas duas últimas métricas aumentam de forma proporcional ao crescimento da soma dos quadrados dos erros. Sendo assim, a seleção dos modelos baseado nesses critérios deve ser caracterizada pela escolha daqueles que retornam os menores valores de AIC e BIC. Na terceira etapa da avaliação deste módulo, comparou-se o modelo de regressão *ridge* e o modelo de mínimos quadrados recursivos com decaimento exponencial (RLS) proposto em (LOVELESS; STOIKOV; WAEBER, 2013) por meio das métricas RMSE e MAE. Na Tabela 3, resumiu-se cada procedimento e suas respectivas métricas aplicadas a cada uma dessas bases.

Tabela 3 – Métricas e procedimentos aplicados nas bases de treino, validação e teste para o módulo de previsão.

Etapas	**Base**	**Métricas**	**Procedimentos**
Etapa 1	Treino	RMSE e AIC	Seleção dos parâmetros α e λ
Etapa 2	Validação	RMSE, MAE, AIC e BIC	Avaliação das hipóteses da *ridge*
Etapa 3	Teste	RMSE, MAE	Comparação dos modelos *ridge* e RLS

3.4.2 Validação do módulo de decisão

Neste módulo, avaliaram-se as estratégias de negociações adotadas pelo AN2 e o desempenho da rede WiSARD na aplicação das regras estáticas do indicador técnico RSI. Para a avaliação das estratégias de negociação, utilizou-se a metodologia apresentada em (ALDRIDGE, 2009). Esta abordagem consiste em dividir todas as oportunidades

comerciais em compras e vendas lucrativas e não lucrativas. Estas oportunidades são determinadas com base nos parâmetros *stop-gain* e *stop-loss* decididos antes do treino. O ponto *stop-loss* é definido quando a ação atinge o último preço negociado menos z vezes o desvio padrão dos preços históricos, e *stop-gain*, o ponto no qual a ação atinge o último preço negociado mais z vezes o desvio padrão dos preços históricos. Como explicado na Seção 3.3.2, as negociações, sejam elas compras ou vendas, serão definidas como lucrativas, caso a ação atinja o ponto de *stop-gain* antes do ponto de *stop-loss*.

A métrica empregada na tarefa de avaliação das submissões de ordens de compra e venda foi a taxa de acerto, a qual mede a razão entre o número de negociações lucrativas para o agente e o total de negociações. Nesse sentido, o AN2 é considerado rentável se essa taxa for superior a 50%, como o método de avaliação usado em (GIACOMEL; GALANTE; PEREIRA, 2015).

$$\text{Taxa Acerto} = \frac{\text{Número total de negociações lucrativas}}{\text{Número total de negociações}} \tag{3.12}$$

Vale explicar que a métrica de taxa de acerto foi adotada pois o objetivo foi avaliar se o agente era capaz de submeter ordens de compra e venda compatíveis com a movimentação da ação no mercado. Essa métrica, contudo, não examina o lucro do agente nas operações.

Analisou-se nesse módulo, por fim, a acurácia média da WiSARD, e os tempos de processamento a cada novo dado na base, durante o treinamento e o reconhecimento dos padrões de entrada, de forma a verificar se estes eram compatíveis com os tempos de negociação no mercado de alta frequência. Cabe destacar, ainda, que nestes procedimentos a mesma avaliação *online* adotada no módulo de previsão foi empregada neste módulo de decisão.

3.5 DISCUSSÃO

Neste capítulo, foram descritas as metodologias das três etapas que participaram do processo de maturação da estrutura do AN2. Na primeira etapa, uma base de dados diária de três dos papéis mais líquidos negociados no Ibovespa foi analisada no período de 02 de fevereiro de 2009 a 30 de junho de 2015. O objetivo foi verificar a precisão da WiSARD na previsão de fases do comportamento dessas ações por meio de estratégias com tamanhos de médias móveis empregadas nas frequências de médio e longo prazo.

A segunda etapa, por sua vez, implementou o AN1 composto pelos módulos de previsão e decisão. Para esse estudo, ampliou-se a base de dados, na qual foram inseridos sete novos papéis do Ibovespa. No módulo de previsão empregou-se a WiSARD na tarefa de classificação da fase do próximo instante de tempo e alimentou-se o segundo módulo com essa informação. No módulo de decisão foi avaliado o desempenho de um processo de decisão de Markov via programação dinâmica com base na mesma estratégias de médias móveis aplicadas na primeira etapa. Outro ponto importante foi a análise do comportamento dos módulos de previsão e decisão com a estratégia de médias móveis em frequências menores de negociações.

Com o propósito de avançar mais no estudo do mercado financeiro, optou-se por estudar as negociações de alta frequência, posto que a evolução das plataformas das bolsas de valores, impulsionadas pelos investimentos em desempenho computacional, instituíram frequências de transações na escala de milésimos de segundos (NETTLES et al., 2015). Com o objetivo de estudar mais profundamente o módulo de decisão, priorizou-se o aprendizado da rede neural sem peso WiSARD empregada no módulo de decisão, visto que o cenário de alta frequência necessita de eficiência computacional e de uso de memória adaptáveis às reações rápidas das atualizações do mercado.

Para a terceira etapa foi possível o uso de uma base de dados das negociações da série de preços *tick-a-tick* negociados na BM&FBovespa. A arquitetura do AN2 também foi composta por dois módulos. No primeiro, empregou-se o modelo de regressão *ridge* na tarefa de previsão do comportamento dos preços com o objetivo de evitar o *overfitting* da modelagem. No segundo módulo, as regras estáticas do indicador técnico RSI foram implementadas na WiSARD.

4 RESULTADOS EXPERIMENTAIS

Neste capítulo, são apresentados e discutidos os resultados experimentais de cada uma das etapas apresentadas no Capítulo 3. Com foco no desempenho da WiSARD aplicada em cada uma delas. Cabe especificar que os experimentos no modelo WiSARD adotados ao longo deste Capítulo utilizou a biblioteca *pywann*[1].

4.1 EXPERIMENTOS SOBRE A BASE DE DADOS DIÁRIOS

4.1.1 Experimentos com previsão de preços utilizando estratégias com médias móveis

Os resultados desta Seção referem-se à primeira etapa do trabalho descrita na Seção 3.2.1. O objetivo dos experimentos foi avaliar e comparar a acurácia e o tempo de processamento da base de treino e de teste para cada um dos classificadores, WiSARD, KNN e SVM, na tarefa de previsão da próxima fase do preços de cada um das ações em estudo: PETR4, VALE5 e BBDC4, no período de 02 de fevereiro de 2009 a 30 de junho de 2015.

A base de treino foi composta pelos 1023 primeiros preços sequenciais de cada uma das séries, correspondentes ao intervalo de 02 de fevereiro de 2009 a 26 de março de 2013. Já a base de teste foi composta pelos preços das ações do dia 27 de março de 2013 ao dia 30 de junho de 2015. As Figuras 8 e 9 apresentam a quantidade de exemplos para cada classe da base de treino e da base de teste, respectivamente. O processo de validação utilizado nos experimentos desta Seção compreendeu duas etapas. Primeiramente, treinou-se com os 1023 primeiros exemplos, que correspondiam a 64,54% da base de cada série. Em seguida, para cada dia subsequente, executou-se a previsão da classe daquele dia e, independentemente do acerto, adicionou-se aquele exemplo com sua classificação correta à base de treino.

A escolha da melhor configuração da WiSARD considerou uma retina composta por 30 *bits* em sua estrutura, assim como explicado na Seção 3.2.1. Dessa forma, estimou-se os parâmetros da rede comparando, de forma empírica, a acurácia no processo de validação na base BBDC4 ao variar o número de *bits* de endereçamento e o uso ou não do mecanismo de *bleaching*. Repetiu-se esse experimento de validação 30 vezes

[1] <https://github.com/firmino/PyWANN>

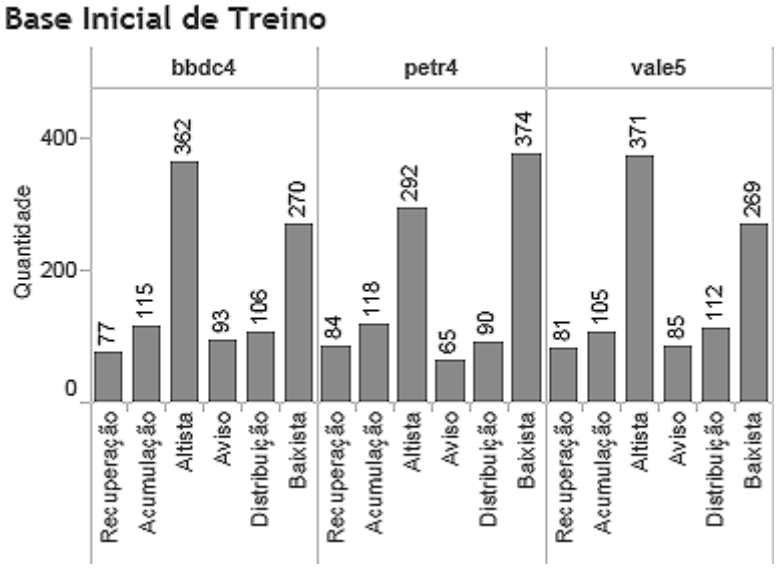

Figura 8 – Quantidade de exemplos para cada fase na base de treino inicial.

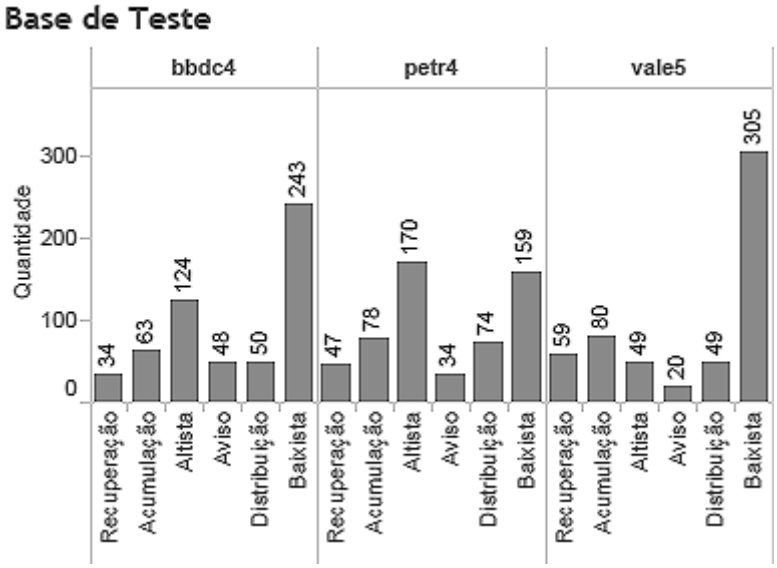

Figura 9 – Quantidade de exemplos para cada fase na base de teste.

para verificar o desvio padrão da acurácia do classificador, uma vez que por haver um mapeamento aleatório da retina nas memórias a acurácia resultante dessas repetições pode variar. A configuração da WiSARD que resultou na melhor acurácia utilizou 4 *bits* com *bleaching*. O desvio padrão calculado nesse processo foi baixo: 0,82%, 0,90% e 1,09% para as séries BBDC4, PETR4 e VALE5, respectivamente, o que confirmou a boa precisão do classificador.

Os melhores parâmetros dos classificadores de comparação, SVM e KNN, também foram obtidos empiricamente em um processo de validação da acurácia na base BBDC4. No caso do KNN, o valor de k igual a 7 foi obtido iterativamente até que a

acurácia fosse menor que 50%. Já para o SVM, foi realizada uma comparação entre as funções de *kernel*: *radial basis function*, *polynomial*, linear e *sigmoid*. Essas funções de *kernel* foram aplicadas no processo de validação, variando o valor de γ em uma taxa de 0.1 em cada uma delas, buscando a que resultasse em uma melhor acurácia. A função que apresentou os melhores resultados foi a *radial basis function*, com a constante γ inicializada em $0,5$, definida na Equação 4.1. Após esse processo, refinou-se a busca na vizinhança desse parâmetro, porém não se obteve melhor acurácia.

$$K(x_i, x_j) = e^{-\gamma||(x_i - x_j)||^2} \tag{4.1}$$

Após o ajuste dos melhores parâmetros, para cada um dos modelos estudados, comparou-se a acurácia deles nas três séries temporais de preços. Na Figura 10, é possível perceber que a WiSARD apresentou acurácia muito próxima àquela do SVM nas ações PETR4 e BBDC4, embora tenha obtido uma acurácia inferior na ação VALE5. Para esse ação, o KNN apresentou melhor acurácia, embora próxima da acurácia do SVM. Além dessa análise, avaliou-se o comportamento da WiSARD em cada classe de exemplo, tendo em vista que existem classes específicas para compra e venda de ativos. Portanto, visando a uma validação do quão correta pode estar uma classificação dado que se encontra em uma determinada classe, construiu-se uma matriz de confusão para a classificação da WiSARD em cada ação.

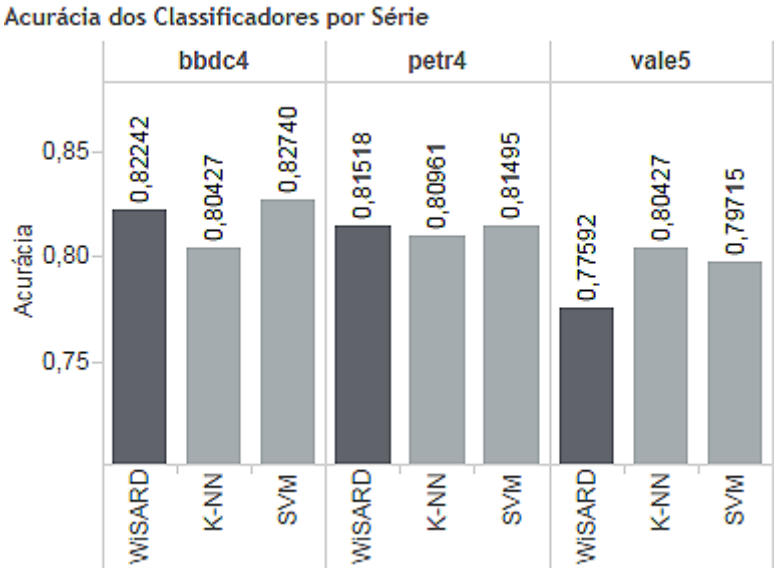

Figura 10 – Acurácia dos classificadores para cada série temporal.

Nas Tabelas 5, 6 e 7, apresentam-se as matrizes de confusão do classificador WiSARD, com os parâmetros definidos anteriormente, nas séries BBDC4, PETR4 e VALE5, respectivamente. É possível perceber na Tabela 7 do ação VALE5 que os erros

das classes distribuição e altista da VALE5 foram maiores que nos outros ações nas Tabelas 6 e 5. A classificação da WiSARD foi prejudicada nessa série pois no período em estudo as bases de treino e teste indicaram alterações que resultaram em proporções diferentes de exemplos das classes dessas duas bases, principalmente a classe baixista, como pode ser visto nas Tabelas 8 e 9.

O último experimento calculou o tempo médio de processamento para as duas etapas da validação: treinamento com a base de treino; e reconhecimento e treinamento com a base de teste para a ação BBDC4. Sendo assim, na primeira etapa, o tempo calculado corresponde ao treino de cada um dos classificadores para os 1023 primeiros dados. Já na segunda etapa é calculado o tempo para que o classificador faça a previsão da próxima fase combinado ao tempo para o treino da fase correta daquele dia. A Tabela 4 apresenta as médias dos tempos de processamento das duas etapas, onde todos os classificadores obtiveram um desvio padrão menor do que 0,01%. Cabe salientar que o SVM e o KNN usaram a biblioteca *sklearn* (PEDREGOSA et al., 2011), a qual adota implementação otimizada. Apesar da implementação da WiSARD ser sequencial, é possível perceber pela Tabela 4 que ela possui menor tempo para as duas etapas, além de obter a vantagem de ser um modelo de custo computacional menor que do SVM. Essa vantagem permite que a WiSARD seja usada na tarefa de aprendizado *online* com intervalos menores que os dos outros classificadores.

Tabela 4 – Média do tempo de processamento em segundos para os classificadores na ação BBDC4.

Classificador	Treinamento base de treino	Reconhecimento e treinamento base de teste
WiSARD	0,054	0,25
SVM	0,03	4,5
KNN	-	29,7

Tabela 5 – Matriz de confusão WiSARD na ação BBDC4.

	Rec.	Ac.	Alt.	Av.	Dis.	Baix.
Recuperação	42,5%	7,4%	2,9%	0,0%	0,0%	47,3%
Acumulação	5,1%	80,9%	2,7%	0,4%	0,1%	10,8%
Altista	0,0%	3,2%	87,5%	6,3%	2,8%	0,1%
Aviso	0,0%	0,0%	29,0%	56,9%	14,0%	0,1%
Distribuição	0,0%	0,0%	3,2%	16,3%	80,5%	0,0%
Baixista	4,5%	2,8%	0,2%	0,1%	1,6%	90,8%

Tabela 6 – Matriz de confusão WiSARD na ação PETR4.

	Rec.	Ac.	Alt.	Av.	Dis.	Baix.
Recuperação	52,3%	14,8%	0,1%	0,0%	0,0%	32,8%
Acumulação	12,6%	85,5%	0,0%	0,0%	0,0%	1,9%
Altista	0,0%	4,7%	87,9%	6,1%	1,0%	0,2%
Aviso	0,0%	0,0%	63,8%	31,1%	5,1%	0,0%
Distribuição	0,0%	0,0%	5,5%	7,5%	86,9%	0,2%
Baixista	6,6%	0,0%	0,0%	0,0%	3,8%	89,6%

Tabela 7 – Matriz de confusão WiSARD na ação VALE5.

	Rec.	Ac.	Alt.	Av.	Dis.	Baix.
Recuperação	48,1%	9,5%	0,0%	0,0%	0,0%	42,4%
Acumulação	11,7%	75,7%	0,4%	0,0%	0,0%	12,2%
Altista	0,2%	8,0%	68,8%	20,1%	2,9%	0,0%
Aviso	0,0%	0,0%	50,7%	40,3%	9,0%	0,0%
Distribuição	0,6%	3,7%	8,7%	13,5%	67,1%	6,4%
Baixista	6,8%	2,6%	0,0%	0,0%	1,3%	89,3%

4.1.2 Experimentos com AN1: compra e venda com estratégias de médias móveis

Os resultados desta Seção referem-se a segunda etapa descrita na Seção 3.2.2. O objetivo dos experimentos foi avaliar o desempenho do AN1 no mercado brasileiro, negociando as ações PETR4, VALE5 e BBDC4, ITUB4, ABEV3, CIEL3, ITSA4, BRFS3, PETR3 e JBSS3 correspondendo ao período de 02/01/2008 a 05/10/2015, apresentados na Tabela 8 da Seção 3.2.2.

O primeiro experimento avaliou a acurácia dos classificadores SVM, KNN e WiSARD na previsão da fase do preço para o próximo dia. Na Tabela 8 são discriminados, para cada série de preços, a quantidade de dias de treino e teste e a acurácia de cada um dos classificadores. Nela é possível perceber que a WiSARD teve acurácia próxima do SVM e maior que o KNN para a maioria das séries, como por exemplo: ABEV3, PETR4, CIEL3, ITSA4, BRF3, PETR3, JBS3 e VALE5. Cabe destacar também que embora a WiSARD não ter superado a acurácia do SVM ela é adaptável as mudanças de tendências das fases.

Posteriormente, de posse da previsão dos classificadores, o segundo experimento comparou o capital final obtido pela melhor política do MDP e por regras simples (regras do mercado), as quais direcionam o AN1 a comprar ação, se a fase de previsão for baixista, ou, a vender, se for altista, já que estes constituem os pontos fundos e topos das séries de preços. Na Tabela 9 são apresentados os resultados para cada um das

ações em estudo, onde o capital inicial do AN1 era de $R\$10.000,00$. É possível verificar que a política do MDP foi superior às políticas do mercado nas ações: IUTB4, ABEV3, BBDC4, PETR4, ITSA4, PETR3 e VALE5. Ademais, das três ações em que o MDP não conseguiu superar a política do mercado, é possível perceber que, para os BRFS3 e JBSS3, as acurácias dos classificadores foram as mais baixas. Sendo assim, um terceiro experimento foi realizado, com o objetivo de verificar o comportamento do desempenho do módulo de decisão que recebe a informação da próxima fase utilizando um modelo de previsão com 100% de acurácia, definido como *oráculo*.

Tabela 8 – Comparação das acurácias dos classificadores e qauntidades de dias de treino e teste.

	Dias		Classificadores		
Series	Treino	Teste	SVM	KNN	WiSARD
ITUB4	1224	307	85,29%	82,03%	**81,37%**
ABEV3	355	89	68,18%	57,95%	61,36%
BBDC4	1534	384	45,95%	40,99%	40,21%
PETR4	1524	381	66,05%	63,95%	65,26%
CIEL3	1108	277	88,77%	87,32%	**87,68%**
ITSA4	1514	379	49,47%	48,15%	48,68%
BRFS3	1145	287	45,80%	37,76%	44,41%
PETR3	1522	381	70,26%	69,74%	**72,34%**
JBSS3	1533	384	39,67%	35,51%	36,55%
VALE5	1534	384	56,66%	49,08%	55,09%

Tabela 9 – Comparação do capital final de ambas estratégias.

Classificadores	SVM		KNN		WiSARD	
Estratégia	MDP	Mercado	MDP	Mercado	MDP	Mercado
ITUB4	**12.973,00**	9.590,00	9.871,00	7.408,00	10.575,00	11.669,00
ABEV3	**11.015,00**	10.615,00	10.990,00	10.480,00	10.985,00	10.235,00
BBDC4	12.938,00	9.028,00	**16.069,00**	8.586,00	12.985,00	9.553,00
PETR4	9.307,00	**11.078,00**	9.346,00	666,00	7.340,00	5.441,00
CIEL3	8.420,00	9.282,00	8.542,00	**10.770,00**	8.079,00	9.520,00
ITSA4	**15.208,00**	9.136,00	13.631,00	8.831,00	13.896,00	11.352,00
BRFS3	9.602,00	10.000,00	9.024,00	11.017,00	9.940,00	**11.445,00**
PETR3	9.240,00	10.000,00	**9.549,00**	815,00	8.058,00	5.478,00
JBSS3	13.372,00	20.428,00	15.145,00	**22.563,00**	12.799,00	16.941,00
VALE5	9.271,00	7.251,00	8.931,00	6.840,00	**9.435,00**	1.338,00

A Tabela 10 apresenta um resumo dos resultados das comparações das estratégias obtidas com o MDP e das estratégias típicas do mercado, considerando um capital inicial de $R\$10.000,00$. Por essa tabela é possível perceber que o intervalo de 95% de confiança para o capital final com a estratégia do MDP é menor que com a estratégia adotada no mercado. Desse modo, empregar a estratégia do MDP permite que o AN1 obtenha ganho médio maior e menos volatilidade que utilizando as estratégias mais comuns no mercado.

As representações das estratégias criaram um *trade-off* entre o MDP e os classificadores na escolha das médias móveis ideais. A política do MDP comportou-se melhor com médias móveis menores, porque elas permitem que o AN1 , no módulo de decisão, reaja rapidamente e obtenha lucro, mesmo quando o movimento da série seja de tendência de baixa. Por outro lado, os classificadores apresentaram melhor desempenho na tarefa de decisão com médias móveis mais longas, uma vez que as fases do preço no próximo dia se tornam mais previsíveis. Um estudo empírico foi feito e as melhores médias móveis para o agente foram 5 e 10 para as médias móveis curta e longa, respectivamente, julgando os melhores resultados do MDP. Por fim, como o AN1, via programação dinâmica (Seção 2.3.2.2), conseguiu melhorar a política de negociação no mercado utilizando o classificador *oráculo*, como pode ser visto na Tabela 10, considerou-se importante avaliar o desempenho de um agente composto por um módulo de previsão com base em um modelo de regressão.

Tabela 10 – Comparação do retorno médio em um intervalo de 95% de confiança.

Política	MDP	Mercado	MDP	Mercado
Classificador	Média	Média	IC 95%	IC 95%
Oráculo	26.713,20	37.579,50	6.303,28	17.963,89
WiSARD	10.409,20	9.297,20	**1.407,47**	2.667,40
KNN	11.109,80	8.797,60	1.728,81	3.791,51
SVM	**11.134,60**	10.640,80	1.436,82	2.226,22

4.2 EXPERIMENTOS SOBRE A BASE DE DADOS DE ALTA FREQUÊNCIA

Os resultados desta Seção referem-se à terceira etapa do trabalho, que descreve o AN2, apresentado na Seção 3.3. O objetivo dos experimentos foi avaliar o desempenho do AN2 no mercado de alta frequência da ação PETR4, no período de 30 de setembro de 2015 a 31 de outubro de 2015. A base de dados da série foi dividida em amostras de treinamento, validação e teste, seguindo os respectivos percentuais: 30%, 30% e 40%. Sendo assim, os 30% primeiros dados na sequência foram incluídos na base de treino; os próximos 30% dos dados sequenciais foram adicionados à base de validação e os 40% restantes foram empregados na base de teste.

De maneira a avaliar se a série temporal de preços de alta frequência, assim como a maioria dos dados financeiros, é não estacionária aplicou-se o teste ADF (CHEUNG; LAI, 1995), onde a hipótese nula é a presença de raiz unitária na série temporal (ou seja, a série não é estacionária). Nesse experimento, foi verificado se os preços da ação PETR4 seguiriam um modelo de passeio aleatório, isto é, não seria

permitido a previsão do seu comportamento ao longo do tempo. Para tal, analisou-se no teste os dados dos preços seguindo apenas o primeiro pré-processamento da base explicado na Seção 3.1.2.

Tabela 11 – *P-valores* do teste ADF para a ação PETR4.

	1 min	5 min	10 min	15 min
Preço	0.1998	0.2527	0.2735	0.2810

Consoante resultados apresentados na Tabela 11, verifica-se que, para todas as granularidades em estudo da ação PETR4 não foram encontradas evidências suficientes para rejeitar a hipótese de que essa série de preços é não estacionária, uma vez que todos os *p-valores* são maiores que 20%. Contudo, após a sequência de pré-processamentos dos dados e da transformação em retornos descrita na Equação 2.3, o *p-valor* em todos os casos foi menor que 0.00001. Dessa maneira, existem evidências suficientes para rejeitar a hipótese de que a série de retornos é não estacionária ao nível de significância de 0.001%. Consequentemente, as propriedades estatísticas dos retornos não se alteram ao longo do tempo, o que garante a convergência da previsão.

4.2.1 Experimentos com o módulo de previsão do AN2

A validação do módulo de previsão foi constituída de duas etapas. Na primeira, foram ajustados os melhores parâmetros dos métodos de regressão *ridge* e de mínimos quadrados recursivos com decaimento exponencial (RLS) proposto em (LOVELESS; STOIKOV; WAEBER, 2013). Já na segunda etapa, compararam-se os erros de previsão cometidos por esses dois modelos. Usou-se o `scikit-learn` (PEDREGOSA et al., 2011) como suporte para o algoritmo de regressão *ridge* e o `padasip`[2] para implementação do algoritmo recursivo de mínimos quadrados.

Os parâmetros de decaimento exponencial e os tamanhos das médias móveis foram estimados comparando o RMSE em um algoritmo *grid search*, que caracteriza a busca exaustiva através de um subconjunto especificado manualmente dos valores possíveis dos parâmetros. Nesse primeiro experimento, empregaram-se os dados brutos da base de dados (*tick-a-tick*) em uma janela de tamanho 10 minutos. A melhor média móvel longa (MMA_L) foi a de tamanho 5 e a melhor média móvel curta (MMA_S) foi a de tamanho 2. O melhor fator de decaimento exponencial encontrado foi o valor de $\alpha = 0.001$ para as duas abordagens. No modelo *ridge*, α é utilizado no cálculo da variável independente suavização exponencial (EXP), definida na Equação 3.3.

[2] <https://github.com/matousc89/padasip.git>

A segunda análise dos parâmetros compreendeu a escolha do fator de regularização (λ) do modelo *ridge* por meio do critério AIC (AKAIKE, 1987). A seleção desse parâmetro deve ser realizada de maneira a ponderar entre o ajuste e a complexidade do modelo. Se o valor de λ é muito grande, então o efeito da regularização domina a função de mínimos quadrados fazendo com que os coeficientes da regressão sejam próximos de zero. Por outro lado, se o valor de λ é muito pequeno, esse efeito é contrário e a função de mínimos quadrados passa a ter um peso maior que a regularização, promovendo grandes oscilações nos valores dos coeficientes da regressão. Os valores testados de λ foram 1, 0.1, 0.01, 0.001, 0.0001, 0.00001, 0.000001, 0.0000001 e 0.00000001. Encontrou-se o valor ótimo de $\lambda = 1e - 0.5$ para a granularidade de 1 minuto. A Figura 11 ilustra a variação dos valores dos coeficientes do modelo para os diferentes valores de λ testados.

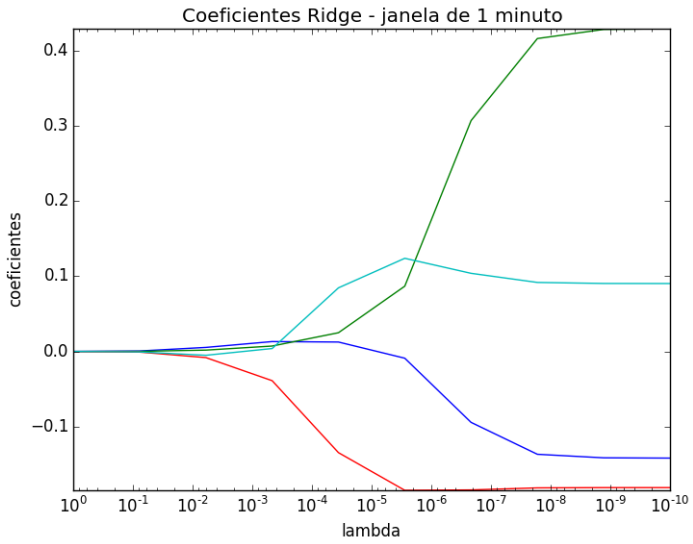

Figura 11 – Coeficientes da regressão *ridge* em função da regularização na granularidade de 1 minuto.

De maneira a selecionar as variáveis independentes da regressão, analisou-se primeiro a correlação entre elas. Na Tabela 12 nota-se que as variáveis MMA_L e MMA_S são fortemente correlacionadas. A presença de correlação forte entre as variáveis pode significar a existência de multicolinearidade, levando o modelo a produzir coeficientes de regressão imprecisos. Uma das alternativas na presença de multicolinearidade é fazer uso de um método de regressão adequado, como por exemplo a regressão *ridge*, e avaliar, cuidadosamente, as variáveis incluídas no modelo evitando a combinação de variáveis com alta correlação (positiva ou negativa).

Na terceira etapa do trabalho, optou-se por comparar as métricas: RMSE, MAE, C_p, AIC e BIC, para todas as combinações possíveis de variáveis independentes com o objetivo de selecionar as melhores variáveis do modelo. A Tabela 13 apresenta as

Tabela 12 – Matriz de correlação para a granularidade de 1 minuto.

	log(Tempo)	EXP	MA_S	MA_L
log(Tempo)	1.	0.6738	0.3560	0.3565
EXP	0.6738	1	0.6797	0.6811
MA_s	0.3560	0.6797	1	0.9995
MA_l	0.3565	0.6811	0.9995	1

combinações possíveis das variáveis independentes (modelos) com as respectivas métricas. A estratégia usada para selecionar o modelo por meio do RMSE, MAE, AIC e BIC é identificar aquele que resulta nos menores valores dessas métricas. Já para o critério do C_p a estratégia é identificar modelos com C_p próximo de $p+1$, onde p é o número de variáveis independentes do modelo. É possível perceber, pelos resultados da Tabela 13, que esse último critério (C_p) não foi útil, nesse conjunto de dados, pois para cada um dos modelos, com o mesmo número p de variáveis, os resultados da métrica foram os mesmos.

A primeira seleção das variáveis avaliou 4 modelos diferentes, cada um com apenas uma variável. O modelo com a variável MMA_L retornou os menores valores das métricas. Em seguida, avaliou-se os modelos com combinações das demais variáveis independentes com a variável MMA_L. Cabe ressaltar que não avaliou-se a combinação $MMA_L + MMA_S$ uma vez que essas duas variáveis, como explicado anteriormente, comprometem os coeficientes do modelo em vista da presença de multicolinearidade. Como nenhum outro modelo apresentou melhores resultados das métricas, na base de teste a regressão *ridge* será composta do modelo apenas com a variável MMA_L.

Tabela 13 – Seleção de modelos PETR4 utilizando a granularidade de 1 minuto.

Modelo	RMSE	MAE	C_p	AIC	BIC
log(Tempo)	0.0018613	0.0013511	4.0	-12542.32	-12536.43
EXP	0.0018613	0.0013511	4.0	-12542.37	-12536.48
MMA_S	0.0018611	0.0013511	4.0	-12543.12	-12537.23
MMA_L	**0.0018611**	**0.0013510**	**4.0**	**-12543.10**	**-12537.20**
MMA_L+log(Tempo)	0.0021743	0.0015379	6.0	-11706.99	-11695.2
$MMA_L + EXP$	0.0021656	0.0015307	6.0	-11728.43	-11716.64
MMA_L+log(Tempo) $+EXP$	0.0021595	0.0015364	8.0	-11741.62	-11723.94

O último experimento com o módulo é apresentado na Tabela 14, na qual avaliou-se a acurácia dos modelos de previsão *ridge* e RLS por meio das métricas RMSE e MAE para o modelo selecionado da Tabela 13. É possível constatar que o modelo de regressão *ridge* exibe resultados melhores que a abordagem RLS para todas as granularidades. Com o intuito de avaliar se estatisticamente os erros produzidos pelas hipóteses das duas abordagens de previsão são significativamente diferentes, foi aplicado

o teste *Welch*. A hipótese nula desse teste é a de os erros médios absolutos dos modelos comparados são significativamente iguais. Cabe destacar que esse teste foi escolhido pois não é exigido a presença de homocedasticidade, o que torna o teste robusto mesmo na presença de desigualdade das variâncias dos erros das regressões. Portanto, como os *p-valores* do teste são todos menores que 0.001, verificam-se evidências suficientes para rejeitar a hipótese nula de que os modelos *ridge* e RLS são estatisticamente equivalentes.

Tabela 14 – Comparação das abordagens usando RMSE e MAE.

Granularidade	1 min	5 min	10 min	15 min
RMSE *Ridge*	0.00160	0.00298	0.00403	0.00467
RMSE RLS	0.00223	0.00403	0.00541	0.00607
MAE *Ridge*	0.00117	0.00216	0.00303	0.00349
MAE RLS	0.00159	0.00290	0.00401	0.00463
Estatística Teste Welch	-13.17	-5.66	-4.15	-3.44
P-valor Teste Welch	3.93e-39	1.78e-08	3.75e-05	6.25e-04

4.2.2 Experimentos com o módulo de decisão do AN2

Os estimadores dos parâmetros da WiSARD foram definidos comparando-se a acurácia da rede ao variar o tamanho do termômetro, o número de *bits* e o fator de esquecimento exponencial do cálculo do RSI, em um algoritmo *grid search*. Para esse procedimento, treinou-se a rede como os diferentes percentuais: 60%, 70% and 80%, realizando a validação do modelo nas sequenciais de dados subjacentes. O valor do indicador RSI varia de 0 a 100 e o termômetro é definido por $(max - min)/parts$, onde $parts$ representa o incremento dos valores no termômetro e max e min representam , respectivamente, os valores máximo e mínimo desse indicador. Posto isso, optou-se por avaliar os valores do tamanho do termômetro usando o parâmetro $parts$ como 1 e 10.

O número de *bits*, no algoritmo de *grid search*, variou de 2, 4, 8, 16 e 32, uma vez que não é possível identificar, *a priori*, quantos *bits* serão necessários para o endereçamento das RAMs. Vale lembrar que, quanto maior o número de *bits*, maior deverá ser a quantidade de memória requerida para o armazenamento desses valores, o que pode gerar perda considerável no poder de generalização da rede. Por outro lado, quanto menor a quantidade de *bits*, maior é a possibilidade de saturação do modelo. Por fim, o fator de esquecimento exponencial do indicador RSI, no algoritmo de *grid search*, variou de 0.7, 0.8, 0.9, 0.99. Este foi o parâmetro que mais influenciou o desempenho da rede, o que permite observar uma certa robustez no modelo WiSARD, visto que os seus parâmetros de configuração não alteraram o seu desempenho. Os melhores parâmetros para o modelo foram: 70%, 10, 2 e 0.9, para o percentual de treino, o tamanho do termômetro, o número de *bits* e o fator de esquecimento, respectivamente.

O experimentos para avaliar o AN2 dividiram-se em duas partes. O objetivo, da primeira parte, foi testar os parâmetros: $z = 1, 2$ e 3, usado no cálculo dos desvios que compõem os pontos de *stop-loss* e *stop-gain*; a granularidade de 1, 5, 10 e 15 minutos; a previsão dos instantes de tempo: $t+1$, $t+2$ e $t+3$. Para validar as melhores estimativas, simulou-se um modelo de previsão com 100% de acurácia, denominado *oráculo*. Esse modelo de previsão foi construído utilizando-se os preços reais negociados no mercado em vez de preços fornecidos pelos modelos de previsão. A Tabela 15 resume o desempenho do AN2, para os parâmetros em teste, utilizando a estratégia *oráculo*. Definiu-se que AN2 será considerado lucrativo se atingir uma taxa de acerto acima de 50%, assim como a estratégia de avaliação adotada em (GIACOMEL; GALANTE; PEREIRA, 2015). Observa-se que o AN2 atinge as maiores taxas de acerto, em todas as granularidades, para a previsão no período de tempo $t+3$ com z igual a 1. Isto significa que o AN2 atinge seu desempenho máximo quando os pontos de encerramento (*stop-gain* e *stop-loss*) da posição atual, para cada transação, formam bandas com variações menores.

Na segunda etapa do experimento, avaliou-se o AN2 usando a previsão de regressão *ridge* para os melhores parâmetros observados na Tabela 15, $t+3$ e $z = 1$. Na Tabela 16, estão listadas as negociações globais realizadas pelo AN2, o número de compras e vendas lucrativas e não lucrativas, a taxa de acertos e a acurácia da WiSARD. Esses experimentos foram executados 100 vezes com o objetivo de avaliar o desvio padrão da acurácia da rede. Na Tabela 15, nota-se que a WiSARD apresentou uma acurácia maior que 97,80% para todas as granularidades de janela de tempo com um desvio padrão zero. Além disso, foram apurados os de processamento da WiSARD, considerando apenas o tempo necessário para a tomada de decisão. Em cada ponto do conjunto de dados os tempos médios de treinamento e classificação foram, respectivamente, 0,08 e 0,20 milissegundos. Como se pode ver, o AN2 não atingiu uma taxa de acerto superior a 50% na granularidade de 1 minuto. Contudo, é esperado que em granularidades menores, embora o número de oportunidades de negociação seja maior, os riscos em cada transação sejam também grandes. Isso pode ser explicado pelo fato de que em menores granularidades as tendências das séries de preços são menos definidas, o que provoca sinais errados de compras e vendas gerados pelas regra do indicador RSI.

4.3 DISCUSSÃO

A avaliação da primeira etapa do trabalho comparou a acurácia média e o tempo de processamento dos três classificadores: WiSARD, KNN e SVM. Os resultados desses experimentos, apresentados na Seção 4.1.1, retornaram a acurácia desses classificadores na tarefa de previsão das fases dos preços das ações PETR4, VALE5 e BBDC4

Tabela 15 – Sumário das negociações com *oráculo* para o próximo instante de tempo.

Granularidade	tempo	z	Total de Negociações	Taxa de Acerto	ACC
1 min	$t+1$	1	2682	67.74 %	100.0 %
1 min	$t+1$	2	2682	61.18 %	100.0 %
1 min	$t+1$	3	2682	56.48 %	100.0 %
1 min	$t+2$	1	2675	71.66 %	99.55 %
1 min	$t+2$	2	2675	63.92 %	99.55 %
1 min	$t+2$	3	2675	58.39 %	99.55 %
1 min	**t+3**	**1**	2673	**73.39** %	99.48 %
1 min	$t+3$	2	2673	65.61 %	99.48 %
1 min	$t+3$	3	2673	60.11 %	99.48 %
5 min	$t+1$	1	529	67.29 %	98.14 %
5 min	$t+1$	2	529	58.22 %	98.14 %
5 min	$t+1$	3	529	50.66 %	98.14 %
5 min	$t+2$	1	531	72.69 %	98.89 %
5 min	$t+2$	2	531	64.40 %	98.89 %
5 min	$t+2$	3	531	52.73 %	98.89 %
5 min	**t+3**	**1**	531	**76.08** %	100.0 %
5 min	$t+3$	2	531	66.85 %	100.0 %
5 min	$t+3$	3	531	55.93 %	100.0 %
10 min	$t+1$	1	261	68.96 %	95.26 %
10 min	$t+1$	2	261	52.49 %	95.26 %
10 min	$t+1$	3	261	44.82 %	95.26 %
10 min	$t+2$	1	270	71.48 %	98.53 %
10 min	$t+2$	2	270	56.66 %	98.53 %
10 min	$t+2$	3	270	45.55 %	98.53 %
10 min	**t+3**	**1**	266	**75.18** %	97.80 %
10 min	$t+3$	2	266	59.77 %	97.80 %
10 min	$t+3$	3	266	50.75 %	97.80 %
15 min	$t+1$	1	167	62.87 %	92.66 %
15 min	$t+1$	2	167	47.90 %	92.66 %
15 min	$t+1$	3	167	43.71 %	92.66 %
15 min	$t+2$	1	169	71.59 %	100.0 %
15 min	$t+2$	2	169	53.84 %	100.0 %
15 min	$t+2$	3	169	50.29 %	100.0 %
15 min	**t+3**	**1**	173	**71.67** %	98.31 %
15 min	$t+3$	2	173	56.06 %	98.31 %
15 min	$t+3$	3	173	48.55 %	98.31 %

Tabela 16 – Sumário das negociações usando regressão *ridge*.

Estatística	1 min	5 min	10 min	15 min
Quantidade de Treino	6272	1255	636	410
Quantidade Validação	2688	538	273	177
ACC	100.0%	99.44%	97.80%	100.0%
Total Negociado	2687	534	270	168
Compra Lucrativa	488	90	38	15
Compra Não Lucrativa	701	112	47	37
Venda Lucrativa	790	214	121	84
Venda Não Lucrativa	708	118	64	32
Taxa de Acerto	47.56%	56.92%	58.89%	58.93%

com base na estratégia de médias móveis utilizada no mercado financeiro (NEOLOGICA,). A WiSARD apresentou alta acurácia, para todas as séries em estudo, e menor tempo de processamento dentre os classificadores comparados. Esse último resultado destaca a importância do estudo desse modelo na classificação em mercados financeiros, posto que este é um requisito importante dos algoritmos que atuam nesse cenário.

Apoiado nestas conclusões, a segunda parte do trabalho implementou um AN1 capaz de operar no mercado de transações diárias, no qual o módulo de previsão adotou as mesmas características da primeira etapa. Neste AN1, o mercado financeiro de negociações diárias foi modelado por meio de um processo de decisão de Markov via programação dinâmica. A avaliação desta etapa comparou o o capital final obtido pela estratégia de negociação traçada pelas políticas do MPD e uma estratégia simples que observa o preço da ação no próximo dia para tomar a decisão de compra ou venda no dia atual. Nos resultados, apresentados na Seção 4.1.2, foi mostrado que as estratégias de compra e venda de ações com base nas políticas do MDP obtiveram ganho médio maior e menor volatilidade comparado aos lucros obtidos pela estratégia simples. Um segundo resultado importante que cabe ressaltar foi o *trade-off* criado entre as representações dos tamanhos das médias móveis ideais para as definições das fases nas estratégias.

O método baseado na estratégia da Tabela 2, apresentada na Seção 3.2, funciona melhor em mercados com médias móveis mais longas pois as tendências das séries dos preços são mais bem definidas e, consequentemente, as fases são mais representativas. Por isso, os classificadores apresentaram acurácia maior para valores de médias móveis maiores. Por sua vez, médias móveis mais curtas possibilitam maior número de cruzamentos entre as curvas MMA_L e MMA_S, o que gera mais pontos de topos e fundos nas séries de preços. Portanto, as políticas do MDP enviaram números maiores de ordens de compra e de venda ao mercado, resultando, assim, em maiores lucros para o AN1. Em resumo, os classificadores no módulo de previsão do AN1 funcionaram melhor com

estratégias definidas por médias móveis mais longas, enquanto que o módulo de decisão apresentou lucros maiores em estratégias com médias móveis mais curtas.

Além disso, como o AN1 conseguiu definir boas políticas de negociações no mercado de posse da informação da fase correta do próximo dia, julgou-se importante avaliar o desempenho na próxima etapa de um módulo de previsão com base em um modelo de regressão. Nesse contexto, a terceira etapa, optou por estudar o modelo de regressão *ridge*, para este módulo de previsão, e o comportamento da WiSARD no módulo de decisão. O objetivo de fazer uso desse modelo foi explorar o seu rápido aprendizado e simples implementação, uma vez que essas são características fundamentais requeridas nos algoritmos que atuam no cenário de alta frequência (LOVELESS; STOIKOV; WAEBER, 2013). Sendo assim, no AN2, elegeu-se essa rede para atuar no seu módulo de decisão incorporando as regras estáticas de um dos indicadores mais bem sucedidos no intuito de sinalizar os pontos de compra e venda da série. Nos experimentos, apresentados na Seção 4.2.2, foi possível constatar que a codificação das regras na WiSARD foi bem sucedida em tempo compatível com a média de tempo entre as negociações no mercado.

Outro ponto expressivo desta etapa foi a decisão da melhor granularidade para o monitoramento do mercado, visto que o AN2 conseguiu realizar mais negociações em granularidades menores, mas obteve uma taxa maior de ordens de compra e venda lucrativas em granularidades maiores, como pode ser visto na Tabela 16. É esperado que em granularidades menores o número de ordens emitidas pelo AN2 seja maior pois o monitoramento mais frequente permite ao AN2 encontrar mais oportunidades de negociação. Contudo a tendência das séries é mais incerta em intervalos menores, o que reduz o desempenho do módulo de previsão e o sinais gerados pelas regras do indicador técnico.

5 CONCLUSÃO

Em cenários de aprendizado *online*, novos dados de entrada são divulgados sequencialmente, significando que o algoritmo deve adaptar-se sempre que estes dados são observados. Posto isso, o presente trabalho analisa o desempenho da rede neural sem peso WiSARD aplicada às ações mais representativas negociadas na bolsa brasileira, BM&FBovespa, em três etapas. Na primeira etapa, a WiSARD foi adotada para a previsão dos preços das fases das ações baseadas em uma estratégia com médias móveis. Essa etapa resultou no artigo aceito e apresentado no 12° Congresso Brasileiro de Inteligência Computacional (CBIC) (ALVES et al., 2015), em outubro de 2015. Na segunda etapa, o AN1 era composto pelos módulos de previsão e decisão. No módulo de previsão a WiSARD tinha como objetivo a previsão das tendências das ações com base na mesma estratégia estudada na primeira etapa. No módulo de decisão políticas de compra e venda foram modeladas por meio de processos de decisão de Markov (MDP) via programação dinâmica. Na terceira etapa, o módulo de previsão é composto pela regressão *ridge* e o módulo de decisão pela WiSARD.

Algoritmos que negociam dados de alta frequência necessitam de uma capacidade de reação muito rápida em decorrência das atualizações frequentes do mercado. Por isso, na terceira etapa foi proposta uma arquitetura composta por dois módulos adaptáveis a essas necessidades. O primeiro módulo foi empregado com o objetivo de prever o comportamento futuro da ação e alimentar o segundo módulo com essa informação. De posse da previsão do preço futuro, o segundo módulo foi encarregado de tomar as decisões de compra e venda no mercado de ações da ação em análise.

Com base na exigência de velocidade e na natureza *online* dos problemas de negociações de alta frequência, a classe de algoritmos de um passo é especialmente adequada para aplicações nesse cenário (LOVELESS; STOIKOV; WAEBER, 2013). Desta forma, no AN2, o modelo de regressão *ridge* foi utilizado no módulo de previsão, tendo em vista que este pode ser adaptado para uma forma recursiva (VAN WATERSCHOOT; ROMBOUTS; MOONEN, 2005). O segundo módulo, por sua vez, foi composto pela rede neural sem peso WiSARD, em função de duas vantagens desse modelo: (i) rápido treinamento e classificação; (ii) implementação simples. A variável de entrada da rede neural foi escolhida com o propósito de capturar a oscilação dos preços no curto prazo. Essa variável é o indicador de índice de força relativa (RSI). O presente trabalho adota os mesmos parâmetros propostos por (WILDER, 1978), determinando assim regras estáticas

de compra e venda das ações.

Para a avaliação da primeira etapa, a acurácia média na previsão das tendências dos papéis e do tempo de processamento da WiSARD são comparados aos desempenhos dos classificadores SVM e KNN. Nos resultados, a WiSARD apresentou boa acurácia e o baixo tempo de processamento dentre todos os classificadores, sendo este um requisito para classificação em mercados de frequências mais altas. Já na avaliação da segunda etapa, o capital final obtido pela estratégia de negociação traçada pelas políticas do MDP é comparado ao atingido por uma estratégia simples, a qual observa o preço da ação no próximo dia para tomar a decisão de compra ou venda no dia atual. Os resultados experimentais mostraram que utilizar a estratégia do MDP permitem que o agente tenha ganho médio maior e menor volatilidade se comparados aos lucros obtidos pela estratégia simples.

Na terceira etapa, os experimentos em um conjunto de dados reais do mercado de alta frequência revelaram ser possível codificar as regras do indicador RSI na WiSARD de forma compatível com o tempo de reação exigido pelas atualizações neste tipo de mercado. Além disso, os experimentos do módulo de previsão compararam o modelo de regressão *ridge* ao modelo proposto em (LOVELESS; STOIKOV; WAEBER, 2013), modelo de mínimos quadrados recursivos com decaimento exponencial (RLS). O modelo *ridge* retornou resultados gerais mais promissores que os da segunda abordagem. Em termos gerais, foi possível verificar também que o AN2 obteve piores resultados na taxa de acerto com as menores granularidades. Este resultado permitiu confirmar que a previsão do comportamento de tendência da série em intervalos de tempo pequenos é uma tarefa mais complexa, aumentando o risco da estratégia de decisão a ser tomada.

5.1 TRABALHOS FUTUROS

Os resultados do módulo de decisão mostraram que as regras do RSI foram implementadas com sucesso para a WiSARD poder reagir às atualizações do mercado em tempo compatível. O passo seguinte, que constitui trabalho ainda em curso, procurará adaptar a rentabilidade real observada dos dados históricos, melhorando assim a diretriz dada pelo RSI. Sendo assim, o AN2 será dotado de capacidade de acompanhar mudanças de tendência. Apesar do desempenho bastante satisfatório, avaliações mais conclusivas do sistema de negociação somente poderão ser feitas após a metodologia ser testada em períodos de verificação de duração ainda mais longa, abrangendo outras ações da própria bolsa brasileira; outros indicadores técnicos; e outras bolsas do mercado financeiro. Outra ideia a ser explorada é utilizar um algoritmo genético no período de treinamento, para otimizar os parâmetros da arquitetura, a saber: tamanho das janelas móveis e

das amostras de treinamento, validação e teste. Estudos futuros devem investigar a possibilidade de desenvolver uma arquitetura composta por multiagentes designados em tarefas diferentes um um sistema de negociação no mercado de alta frequência, tal qual a arquitetura proposta em (FREITAS; FREITAS; SOUZA, 2016).

REFERÊNCIAS

AKAIKE, H. Factor analysis and aic. *Psychometrika*, Springer, v. 52, n. 3, p. 317–332, 1987. Citado 2 vezes nas páginas 13 e 46.

ALDRIDGE, I. *High-frequency trading: a practical guide to algorithmic strategies and trading systems*. [S.l.]: John Wiley and Sons, 2009. v. 459. Citado 6 vezes nas páginas 5, 13, 25, 30, 33 e 35.

ALEKSANDER, I. From wisard to magnus: a family of weightless virtual neural machines. *RAM-Based Neural Networks*, Singapore: World Scientific, v. 9, 1998. Citado na página 21.

ALEKSANDER, I.; MORTON, H. *An introduction to neural computing*. [S.l.]: Chapman and Hall London, 1990. v. 240. Citado na página 21.

ALEKSANDER, I.; THOMAS, W.; BOWDEN, P. Wisard a radical step forward in image recognition. *Sensor review*, MCB UP Ltd, v. 4, n. 3, p. 120–124, 1984. Citado 2 vezes nas páginas 3 e 20.

ALVES, S. A. et al. Análise de séries temporais financeiras utilizando wisard. In: *Congresso Brasileiro de Inteligência Computacional-Volume 01*. [S.l.: s.n.], 2015. Citado 3 vezes nas páginas 26, 53 e 61.

ANGEL, J. J.; HARRIS, L. E.; SPATT, C. S. Equity trading in the 21st century. *The Quarterly Journal of Finance*, World Scientific, v. 1, n. 01, p. 1–53, 2011. Citado na página 2.

APPEL, G. *The moving average convergence-divergence trading method: advanced version*. [S.l.]: Scientific Investment Systems, 1985. Citado na página 5.

BUENO, R. D. L. da S. *Econometria de séries temporais*. [S.l.]: Cengage Learning, 2008. Citado na página 12.

CARDOSO, D. O. et al. Financial credit analysis via a clustering weightless neural classifier. *Neurocomputing*, Elsevier, v. 183, p. 70–78, 2016. Citado na página 21.

CARNEIRO, H. C.; FRANÇA, F. M.; LIMA, P. M. Multilingual part-of-speech tagging with weightless neural networks. *Neural Networks*, Elsevier, v. 66, p. 11–21, 2015. Citado na página 21.

CAVALCANTE, R. C.; OLIVEIRA, A. L. An autonomous trader agent for the stock market based on online sequential extreme learning machine ensemble. In: IEEE. *Neural Networks (IJCNN), 2014 International Joint Conference on*. [S.l.], 2014. p. 1424–1431. Citado na página 5.

CHEUNG, Y.-W.; LAI, K. S. Lag order and critical values of the augmented dickey–fuller test. *Journal of Business & Economic Statistics*, Taylor & Francis Group, v. 13, n. 3, p. 277–280, 1995. Citado na página 44.

CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995. Citado na página 20.

CUNNINGHAM, P.; DELANY, S. J. k-nearest neighbour classifiers. *Mult Classif Syst*, p. 1–17, 2007. Citado na página 19.

DACOROGNA, M. et al. *An introduction to high-frequency finance*. [S.l.]: San Diego: Academic press, 2001. Citado na página 25.

DICKEY, D. A.; FULLER, W. A. Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, Taylor & Francis, v. 74, n. 366a, p. 427–431, 1979. Citado 2 vezes nas páginas 12 e 33.

EVERITT, B. S. et al. Miscellaneous clustering methods. *Cluster Analysis, 5th Edition*, Wiley Online Library, p. 215–255, 2011. Citado na página 19.

FAMA, E. F. The behavior of stock-market prices. *The journal of Business*, JSTOR, v. 38, n. 1, p. 34–105, 1965. Citado na página 11.

FAMA, E. F. Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, JSTOR, v. 25, n. 2, p. 383–417, 1970. Citado na página 11.

FAMA, E. F. Random walks in stock market prices. *Financial analysts journal*, CFA Institute, v. 51, n. 1, p. 75–80, 1995. Citado 2 vezes nas páginas 11 e 33.

FONTENLA-ROMERO, Ó. et al. Online machine learning. *Efficiency and Scalability Methods for Computational Intellect*, IGI Global, p. 27, 2013. Citado na página 26.

FREITAS, F. D.; FREITAS, C. D.; SOUZA, A. F. Intelligent trading architecture. *Concurrency and Computation: Practice and Experience*, Wiley Online Library, v. 28, n. 3, p. 929–943, 2016. Citado 2 vezes nas páginas 7 e 55.

FUKUNAGA, K.; NARENDRA, P. M. A branch and bound algorithm for computing k-nearest neighbors. *IEEE transactions on computers*, IEEE, v. 100, n. 7, p. 750–753, 1975. Citado na página 19.

GIACOMEL, F.; GALANTE, R.; PEREIRA, A. An algorithmic trading agent based on a neural network ensemble: a case of study in north american and brazilian stock markets. In: IEEE. *Web Intelligence and Intelligent Agent Technology (WI-IAT), 2015 IEEE/WIC/ACM International Conference on*. [S.l.], 2015. v. 2, p. 230–233. Citado 4 vezes nas páginas 5, 30, 36 e 49.

GRIECO, B. P. et al. Producing pattern examples from "mental" images. *Neurocomputing*, Elsevier, v. 73, n. 7, p. 1057–1064, 2010. Citado 2 vezes nas páginas 21 e 23.

HASBROUCK, J. Order characteristics and stock price evolution an application to program trading. *Journal of Financial Economics*, Elsevier, v. 41, n. 1, p. 129–149, 1996. Citado na página 9.

HOREWICZ, M. C.; JR, C. L. N.; SILVA, T. M. Técnicas de redes neurais para o problema de reconhecimento de caracteres: um estudo comparativo. *VIII Simpósio de Guerra Eletrônica (SIGE 2006)*, p. 1–5, 2006. Citado 2 vezes nas páginas 9 e 20.

HORN, R.; JOHNSON, C. Norms for vectors and matrices. *Matrix analysis*, p. 313–386, 1990. Citado na página 15.

HUANG, W.; NAKAMORI, Y.; WANG, S.-Y. Forecasting stock market movement direction with support vector machine. *Computers & Operations Research*, Elsevier, v. 32, n. 10, p. 2513–2522, 2005. Citado na página 4.

JABBUR, E. et al. Design and evaluation of automatic agents for stock market intraday trading. In: IEEE COMPUTER SOCIETY. *Proceedings of the 2014 IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT)-Volume 03*. [S.l.], 2014. p. 396–403. Citado 2 vezes nas páginas 5 e 30.

KUMAR, D. A.; MURUGAN, S. Performance analysis of indian stock market index using neural network time series model. In: IEEE. *Pattern Recognition, Informatics and Mobile Engineering (PRIME), 2013 International Conference on*. [S.l.], 2013. p. 72–78. Citado na página 5.

LOVELESS, J.; STOIKOV, S.; WAEBER, R. Online algorithms in high-frequency trading. *Communications of the ACM*, ACM, v. 56, n. 10, p. 50–56, 2013. Citado 6 vezes nas páginas 3, 35, 45, 52, 53 e 54.

MADDALA, G. S.; LAHIRI, K. *Introduction to econometrics*. [S.l.]: Macmillan New York, 1992. v. 2. Citado na página 11.

MALLOWS, C. L. Some comments on c p. *Technometrics*, Taylor & Francis Group, v. 15, n. 4, p. 661–675, 1973. Citado na página 34.

MONTEMERLO, M.; ROY, N.; THRUN, S. Perspectives on standardization in mobile robot programming: The carnegie mellon navigation (carmen) toolkit. In: IEEE. *Intelligent Robots and Systems, 2003.(IROS 2003). Proceedings. 2003 IEEE/RSJ International Conference on*. [S.l.], 2003. v. 3, p. 2436–2441. Citado na página 7.

MURPHY, J. J. *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. [S.l.]: Penguin, 1999. Citado 2 vezes nas páginas 11 e 13.

NEOLOGICA. *Diamante - Uma Estratégia Simples Utilizando Médias Móveis*. <http://www.nelogica.com.br/conhecimento/artigos/indicadores-estudo/estrategia-diamante>. Citado 2 vezes nas páginas 26 e 51.

NETTLES, J. et al. Forecasting intraday volume distributions. In: IEEE. *Systems and Information Engineering Design Symposium (SIEDS), 2015*. [S.l.], 2015. p. 97–102. Citado 2 vezes nas páginas 30 e 37.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Citado 2 vezes nas páginas 41 e 45.

PELLEGRINI, J.; WAINER, J. Processos de decisão de markov: um tutorial. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 133–179, 2007. Citado 2 vezes nas páginas 9 e 18.

PERLIN, M.; RAMOS, H. Gethfdata: Ar package for downloading and aggregating high frequency trading data from bovespa. 2016. Citado na página 25.

PUTERMAN, M. L. *Markov decision processes: discrete stochastic dynamic programming*. [S.l.]: John Wiley & Sons, 2014. Citado na página 18.

RAPOSO, R. de C. T. *Uma ferramenta para análise fundamentalista de investimentos em empresas utilizando sistemas neuro-nebulosos*. Dissertação (Mestrado) — Universidade Federal do Rio de Janeiro, Instituto de Matemática, Programa de Pós de Graduação em Informática, Rio de Janeiro, 2001. Citado na página 11.

RODRÍGUEZ-GONZÁLEZ, A. et al. Cast: Using neural networks to improve trading systems based on technical analysis by means of the rsi financial indicator. *Expert systems with Applications*, Elsevier, v. 38, n. 9, p. 11489–11500, 2011. Citado na página 17.

SCHWARZ, G. et al. Estimating the dimension of a model. *The annals of statistics*, Institute of Mathematical Statistics, v. 6, n. 2, p. 461–464, 1978. Citado na página 34.

SILVA, E. et al. A neural network based approach to support the market making strategies in high-frequency trading. In: IEEE. *Neural Networks (IJCNN), 2014 International Joint Conference on*. [S.l.], 2014. p. 845–852. Citado 2 vezes nas páginas 6 e 30.

SINGH, S.; COHN, D. et al. How to dynamically merge markov decision processes. *Advances in neural information processing systems*, MORGAN KAUFMANN PUBLISHERS, n. 10, p. 1057–1063, 1998. Citado na página 18.

SOTIROPOULOS, D. N. et al. What drives social sentiment? an entropic measure-based clustering approach towards identifying factors that influence social sentiment polarity. In: IEEE. *Information, Intelligence, Systems and Applications, IISA 2014, The 5th International Conference on*. [S.l.], 2014. p. 361–373. Citado na página 20.

SOUZA, A. F.; FREITAS, F. D.; ALMEIDA, A. G. C. de. High performance prediction of stock returns with vg-ram weightless neural networks. In: IEEE. *High Performance Computational Finance (WHPCF), 2010 IEEE Workshop on*. [S.l.], 2010. p. 1–8. Citado na página 6.

SOUZA, A. F.; FREITAS, F. D.; ALMEIDA, A. G. Coelho de. Fast learning and predicting of stock returns with virtual generalized random access memory weightless neural networks. *Concurrency and Computation: Practice and Experience*, Wiley Online Library, v. 24, n. 8, p. 921–933, 2012. Citado na página 7.

TEIXEIRA, L. A.; OLIVEIRA, A. L. I. D. A method for automatic stock trading combining technical analysis and nearest neighbor classification. *Expert systems with applications*, Elsevier, v. 37, n. 10, p. 6885–6890, 2010. Citado na página 4.

VAN WATERSCHOOT, T.; ROMBOUTS, G.; MOONEN, M. Optimally regularized recursive least squares for acoustic echo cancellation. In: *Proceedings of The second annual IEEE BENELUX/DSP Valley Processing Symposium (SPS-DARTS 2006), Antwerp, Belgium*. [S.l.: s.n.], 2005. p. 28–29. Citado 2 vezes nas páginas 16 e 53.

VAPNIK, V. *The nature of statical learning theory*. [S.l.]: Springer-Verlang, New York, 1995. Citado na página 19.

VAPNIK, V. N.; KOTZ, S. *Estimation of dependences based on empirical data*. [S.l.]: Springer-Verlag New York, 1982. v. 41. Citado na página 19.

VELLA, V.; NG, W. L. Enhancing risk-adjusted performance of stock market intraday trading with neuro-fuzzy systems. *Neurocomputing*, Elsevier, v. 141, p. 170–187, 2014. Citado 2 vezes nas páginas 13 e 27.

WILDER, J. W. *New concepts in technical trading systems*. [S.l.]: Trend Research, 1978. Citado 4 vezes nas páginas 4, 5, 16 e 53.

YOO, P. D.; KIM, M. H.; JAN, T. Machine learning techniques and use of event information for stock market prediction: A survey and evaluation. In: IEEE. *Computational Intelligence for Modelling, Control and Automation, 2005 and International Conference on Intelligent Agents, Web Technologies and Internet Commerce, International Conference on*. [S.l.], 2005. v. 2, p. 835–841. Citado na página 4.

ANEXO A – CBIC

Neste anexo é apresentado o artigo aceito e apresentado no 12° Congresso Brasileiro de Inteligência Computacional (CBIC) (ALVES et al., 2015), em outubro de 2015.

Análise de Séries Temporais Financeiras Utilizando WiSARD

Samara Alves, Fabrício Firmino, Fabio Rangel, Priscila Machado Vieira Lima
Programa de Pós-Graduação em Informática (PPGI)
Universidade Federal do Rio de Janeiro
{samara.alvarez, firminodefaria, fabiorangel}@ufrj.br, priscila.lima@nce.ufrj.br

***Resumo*—Séries temporais financeiras são amplamente estudadas por suas aplicações no mercado financeiro. Por meio da aplicação de aprendizado de máquina, é possível prever o valor de uma ação em um determinado momento da série temporal. Na análise técnica, os intervalos dessas séries são categorizados em fases. Este trabalho propõe apresentar uma aplicação do classificador WiSARD na tarefa de predição da fase de um determinado intervalo baseado nos intervalos anteriores da série temporal. Devido a característica da WiSARD é permitido o aprendizado de forma *on-line*. Utilizou-se SVM e K-NN como classificadores de comparação da acurácia e do tempo de processamento. Dentre os resultados obtidos, a WiSARD apresentou boa acurácia e menor tempo de processamento dentro todos os classificadores, sendo este um requisito para classificação *on-line*.**

***Palavras-chave*—WiSARD, SVM, K-NN, Séries Temporais, Previsão de Ações, Mercado Financeiro Brasileiro**

I. Introdução

Técnicas de predição em séries temporais para o mercado financeiro são amplamente estudadas devido a aplicabilidade na previsão do comportamento do mercado de ações. Dentre as abordagens mais utilizadas para prever o comportamento no mercado de ações, destacam-se a análise fundamentalista e a análise técnica. A análise fundamentalista estuda as causas dos movimentos do mercado financeiro, ao passo que a análise técnica estuda as consequências desses movimentos [1]. Sendo assim, a análise técnica utiliza o comportamento histórico da ação como uma série temporal. Aplicando-se esta abordagem acredita-se que o histórico de variação do preço de uma determinada ação tende a se repetir ao longo do tempo.

Previsão de séries temporais financeiras podem ser consideradas um dos principais desafios que envolvem séries temporais e aprendizados de máquina [2]. Nos últimos anos, diversas abordagens foram propostas com o objetivo de fornecer previsões e oferecer sistemas de suporte para tomada de decisões [3]. Tradicionalmente, modelos estatísticos vem sendo utilizados na predição de séries temporais [4] [5]. Contudo, a aplicação de modelos de redes neurais artificiais vem demonstrando bons resultados nessa área. Além disso apresentam como característica a capacidade de criar um modelo flexível e não linear, baseado nos dados fornecidos, sem a necessidade de conhecimento a priori dos relacionamentos entre as entradas e saídas de dados [6]. Outras técnicas de aprendizado baseado em exemplos, como o *Support Vector Machines* (SVM) e *K-Nearest Neighbors* (K-NN), também apresentam essas características, sendo amplamente aplicadas na tarefa de predição em diversos cenários, incluindo o cenário do mercado de ações [7] [8] [9]. Ainda mais recentemente, redes neurais artificiais sem peso obtiveram bons resultados na previsão de ações do mercado financeiro [10] [11].

Como exemplo de trabalho de predição em séries temporais por meio de aprendizado baseado em exemplos, em [12] é proposto um modelo de evolução das redes neurais parcialmente conectados (EPCNNs) usando indicadores técnicos como entradas. Outro trabalho na mesma linha propõe combinar séries exógenas: IBOV, SP500, DAX, NYSE:PBR, Dollar, Euro, BRENT com os modelos de redes neurais MLP (*Multilayer Perceptron*) [13]. No trabalho [14] é apresentado uma metodologia baseada em informações obtidas a partir da série exógena AUAU para o índice PETR4, e das séries exógenas Dollar e IBOV para o índice VALE5, em combinação com redes neurais para prever série de ações. Por fim, existe a proposta de um agente negociador autônomo capaz de comprar e vender ações na bolsa de valores brasileira. Esse agente é baseado na rede neural que combina *Single Hidden Layer Feedforward* (SLFN) treinado com *On-line Sequential Extreme Learning Machine* (OS-ELM) [15].

Um grande percentual dos trabalhos aplicados na tarefa de predição no mercado financeiro tem como objetivo determinar o preço futuro de uma ação. Porém, as estratégias de análise técnica fazem uso de outras informações, além da predição do preço, para determinar o momento de compra ou venda de um ativo. Uma abordagem amplamente utilizada pela análise técnica é o uso de médias móveis como indicador de tendência de variação de preço [1]. A estratégia de médias móveis utilizada no presente trabalho categoriza os dias em fases que representam o momento em que a série se encontra. Por meio da tarefa de classificação baseado em exemplos, é possível prever a próxima fase da série utilizando as fases anteriores, possibilitando determinar se o momento é propício para comprar ou vender um ativo. Sendo assim, este trabalho apresenta um problema de classificação e não de regressão.

A rede neural sem peso WiSARD (Wilkie, Stonham & Aleksander's Recognition Device) [16] foi escolhida para a tarefa de classificação. A justificativa desta escolha provém das características do cenário, onde a aprendizagem acontece de forma *on-line*, ou seja, os dados são obtidos de forma contínua [17]. Nessa rede é permitido adicinar um novo exemplo previamente anotado sem a necessidade de treinar toda a base novamente. Além disso, um mecanismo de *feedback* apresenta as correlações que deram origem a uma determinada

classificação [18]. Essa informação pode ser utilizada pelos analistas financeiros para entender e validar a corretude de uma predição.

O presente trabalho propõe empregar a WiSARD na tarefa de classificação de fases em três séries temporais: os índices PETR4, VALE5 e BBDC4 do mercado financeiro brasileiro BM&FBovespa. Para modelar essas séries de forma a definir categorias para a classificação automática da tendência optou-se pela abordagem de estratégias do campo da análise técnica, baseada na análise das curvas das médias móveis, comumente adotada na avaliação de compra e venda de ações. Para avaliar a classificação as métricas trabalhadas foram a acurácia e o tempo da validação (tempo de treinamento da Base de Treino e tempo de reconhecimento e treinamento da Base de Teste). Para comparar o funcionamento do classificador WiSARD, decidiu-se utilizar como classificadores de comparação o SVM e o K-NN. O SVM foi escolhido devido ao seu amplo uso em diversos cenários, onde este apresenta boas performances; e o K-NN foi escolhido por ser um classificador cujo aprendizado pode ocorrer de forma *on-line* por não possuir tempo de treinamento. A WiSARD apresentou acurácia próxima a do SVM em duas séries e foi inferior aos outros classificadores na terceira. Contudo, na análise de tempo de processamento a WiSARD foi superior aos outros classificadores.

O trabalho está divido em: Conceitos Básicos, no qual é apresentado o classificador WiSARD, os classificadores de comparação e as estratégias financeiras utilizadas; Metodologia, onde é feito uma descrição das bases de dados, dos parâmetros dos classificadores K-NN e SVM, do processamento sobre as mesmas e do experimento; Experimentos e Análises, no qual são apresentados os resultados e as discurssões relevantes; e Conclusão e Trabalhos Futuros.

II. Conceitos Básicos

A. Rede sem peso WiSARD

A WiSARD é uma arquitetura de Rede Neural sem Peso baseada em memória RAM [19]. O formato de entrada dessa rede é uma cadeia de *bits* a qual deu-se o nome de retina. Ela foi projetada para reconhecer imagens em preto-e-branco, sendo assim, é necessário que a entrada seja binarizada [20].

As memórias são agrupadas em discriminadores, que representam as categorias deste mecanismo de classificação [21]. O treinamento, representado na Figura 1, é supervisionado, tornando necessário informar a qual classe um determinado padrão pertence. Sendo assim, na etapa de treinamento é associado um discriminador para cada classe específica. De início, o conteúdo das posições das RAMs é inicializado com zero e durante o treinamento eles são atualizados.

Na etapa de reconhecimento a rede analisa a resposta de todos os discriminadores e escolhe o que ativou o maior número de neurônios [21]. Esses neurônios produzem saídas binárias: ”1” se a posição que foi indicada pelo endereço que a RAM recebe estava marcado; ”0”, caso contrário [18]. O placar de um discriminador é a soma das respostas de todas as RAMs desse discriminador [21]. Na Figura 2, o discriminador apresentado classifica a imagem presente na retina com 3 memórias respondendo positivamente e uma negativamente.

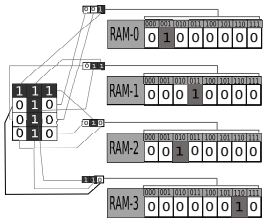

Figura 1. Treino da WiSARD com um exemplo da letra T [22].

Nesse caso, o placar desse discriminador é 3. A Figura 3 apresenta o placar dos discriminadores após o processo de reconhecimento do que se encontra na retina.

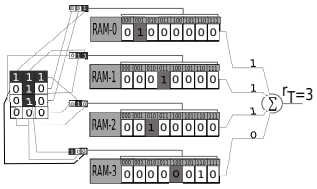

Figura 2. Modelo do Classificador WiSARD [22].

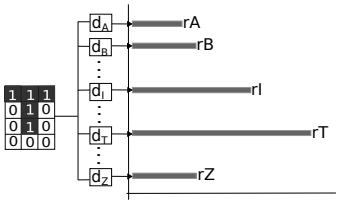

Figura 3. Reconhecimento WiSARD [22]

B. Mecanismo de Bleaching

Um problema apresentado pela WiSARD é a saturação da rede: perda da capacidade de reconhecimento quando os discriminadores recebem treinamento em excesso. Essa saturação pode ser reconhecida quando todos os discriminadores respondem positivamente a um determinado exemplo, podendo haver empates no placar ou os mesmos apresentando valores muito próximos que não permitam uma classificação com confiança. Uma maneira encontrada para contornar esse problema foi o mecanismo de *Bleaching*, representado na Figura 4. Esse mecanismo faz uso, durante a etapa de classificação, de posições de memórias endereçadas com valores associados maiores que o valor de *Bleaching* predefinido.

Para utilizar esse mecanismo, a fase de treinamento deve ser alterada no seguinte aspecto: ao invés de armazenar ”1” na memória responsável, incrementa-se ”1” ao conteúdo da mesma. Sendo assim, terminada a fase de treinamento os valores do conteúdo de cada memória variam de 0 a X, onde X é o número de padrões de treinamento [18]. A Figura 3 ilustra a classificação dos discriminadores com o emprego do mecanismo de *Bleaching*.

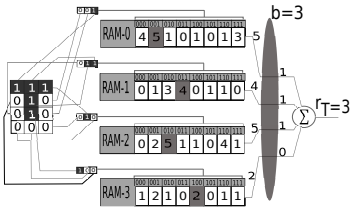

Figura 4. WiSARD com *Bleaching* [22]

C. Classificadores de Comparação

De maneira a avaliar a acurácia do classificador WiSARD, faz-se necessário compará-la a acurácia de outros classificadores. Os classificadores de comparação escolhidos foram o *K-Nearest Neighbors* (K-NN) e o *Support Vector Machines* (SVM).

K-NN é um classificador que categoriza um dado exemplo baseado em k (um número definido) exemplos mais próximos do corpus de treinote [23]. Sendo assim, determina-se a classe de um determinado exemplo baseado na classe dos exemplos cujas distâncias sejam menores. Definiu-se a distância de Hamming como métrica, embora a distância Euclidiana pudesse ser utilizada obtendo os mesmos resultados por conta do modelo adotado. A Distância de Hamming compara cada *bit* e aumenta em 1 caso os *bits* sejam diferentes. No presente trabalho, o problema foi modelado como um vetor de *bits*, tornando confortável a escolha da Distância de Hamming como métrica para o K-NN.

O SVM [24] é um modelo de forte suporte teórico e expressivo sucesso empírico, formulado inicIalmente por Vapnik [25] como um classificador não linear que opera em um espaço de dimensão maior do que o espaço original do conjunto de *features* da base de dados [26]. É possível encontrar na literatura a aplicação do SVM em diversos diferentes cenários. No mercado financeiro, por exemplo, o SVM foi utilizado para fazer previsões das direções do movimentos do índice NIKKEI225 [27].

D. Média Móvel Aritmética (MMA)

O indicador média móvel é um dos mais utilizados devido a forma como é construído e pelo fato de ser facilmente quantificado e testado [1]. Quando MMA é utilizada, todos os preços no intervalo de tempo escolhido possuem os mesmos pesos. Várias versões desse indicador foram criadas, contudo a média móvel simples ou média móvel aritmética é a versão mais utilizada na maioria das abordagens das análise técnica.

E. Estratégia com Médias Móveis

Na análise técnica do mercado financeiro a estratégia de médias móveis é voltada para operações de médio e longo prazo, baseadas em médias móveis aritiméticas e fases. As médias móveis utilizadas neste trabalho, que foram obtidas empiricamente, são: uma de 50 (MMA_{50}) períodos (média curta) e a outra de 100 (MMA_{100}) períodos (média longa). O conjunto de fases comumente utilizadas quando adotada essa estratégia são: fase de recuperação, fase de acumulação, fase altísta, fase de aviso, fase de distribuição e fase baixista [28]. As definições dessas fases requerem a comparação entre os preços de fechamento (PF) e as médias móveis aritméticas dos dois períodos [29], como apresentado na Tabela I.

Tabela I
FASES DA ESTRATÉGIA DE MÉDIAS MÓVEIS ARITMÉTICA

Recuperação	Acumulação
$PF > MMA_{50}$ $PF < MMA_{100}$ $MMA_{50} < MMA_{100}$	$PF > MMA_{50}$ $PF > MMA_{100}$ $MMA_{50} < MMA_{100}$
Altísta	Aviso
$PF > MMA_{50}$ $PF > MMA_{100}$ $MMA_{50} > MMA_{100}$	$PF < MMA_{50}$ $PF > MMA_{100}$ $MMA_{50} > MMA_{100}$
Distribuição	Baixista
$PF < MMA_{50}$ $PF < MMA_{100}$ $MMA_{50} > MMA_{100}$	$PF < MMA_{50}$ $PF < MMA_{100}$ $MMA_{50} < MMA_{100}$

Nesse trabalho, as fases da estratégia de médias móveis correspondem às classes do problema de classificação. Neste caso, a Tabela I apresenta as possíveis classes para cada um dos dias em uma determinada série temporal. Adotando essa estratégia, os analistas financeiros definem momentos de compra e venda conforme a fase que uma série se apresenta e de acordo com o preço da ação e o volume de ações negociados.

III. METODOLOGIA

Com objetivo de comparar a performance do classificador WiSARD a dos classificadores: SVM e K-NN, utilizou-se a acurácia média e o tempo de validação como métricas de avaliação na realização de uma anotação automática. Para calcular a acurácia foi utilizada uma validação específica para dados na forma de *streaming* (dados sequenciais), sobre dados de três séries temporais presentes no mercado de ações brasileiro.

Na estratégia de análise técnica adotada, estabelece-se uma classe (fase) que qualifica cada dia da série temporal. Adotando um intervalo específico de dias anteriores utiliza-se a sequência de classes para predizer a do próximo dia. Sendo assim, este trabalho apresenta uma classificação automática. O histórico recente das ações tem maior influência sobre o seu preço futuro que seus valores mais antigos. Sendo assim, após uma série de experimentos com intervalos de: 5; 10; 20; e 30 dias, observou-se que o intervalo de cinco dias, classificando cada dia em uma fase, obteve a maior acurácia na predição da classe do próximo dia da série temporal, para todos os classificadores.

A. Bases de Teste e Modelagem

A base utilizada nos experimentos foi composta por dados de séries temporais que possuem participação no mercado de ações brasileiro: Petrobras PN (PETR4), Vale PNA (VALE5) e Bradesco PN (BBDC4). As três séries pertencem a segmentos de mercados diferentes, tais quais: companhia de petróleo, companhia de mineração e banco, respectivamente. Os dados são diários correspondendo ao período de 02 de fevereiro de 2009 a 30 de junho de 2015.

Cada dia de cada série foi classificada em uma das seis possíveis fases seguindo as regras da Tabela I. Desta forma, a série de preços é transformada em uma sequência de fases. Um intervalo de cinco fases (cinco dias) em sequência é utilizado como entrada para classificação da fase do próximo dia.

Para modelar a sequência de cinco dias no formato de um vetor de *features* (ou retina no caso do classificador WiSARD), adotou-se um modelo no qual cada dia é representado por um vetor com 6 *bits*. Cada um desses 6 *bits* representa uma classe da estratégia de médias móveis. Apenas um *bit* pode assumir o valor 1, sendo este o responsável por representar a classe ao qual àquele dia pertence. O vetor de *features* será a concatenação de 5 dias consecutivos que antecedem ao dia da previsão, possuindo ao final 30 *bits* em sua estrutura.

B. Validação

Visando adotar uma validação adequada à estrutura de uma série temporal, optou-se por utilizar uma validação própria para o cenário, onde o aprendizado ocorre de forma *on-line*. Primeiro treinou-se com os 1023 primeiros exemplos, que correspondem a 64,54% da base de cada série. Em seguida, para cada dia subsequente, tenta-se prever a classe daquele dia e, independentemente do acerto, adiciona-se aquele exemplo com sua classificação correta à base de treino. O fato de adicionar o exemplo à base de treino, independentemente do acerto, é uma estratégia que pode ser adotada no cenário de uma classificação real, visto que é possível saber a real classe de um determinado intervalo após o mesmo já ter ocorrido.

C. Escolhas dos parâmetros

Para ambos os classificadores de comparação (SVM e K-NN), os parâmetros foram obtidos de forma empírica, utilizando o processo de validação descrito na Seção III-B e a série temporal BBDC4. No caso do K-NN, o valor de k foi obtido iterativamente até que a acurácia fosse menor que 50%. O valor de k igual a 7 foi o que apresentou a melhor acurácia.

Para operar em uma dimensão maior que a do espaço de *features* original, o SVM depende de uma função de *Kernel* que normalmente é escolhida empiricamente. Comparou-se as funções de *Kernel*: *Radial Basis Function*, *Polynomial*, Linear e *Sigmoid*; e aplicou-se essas funções de *Kernel* no processo de validação, variando o valor de γ em uma taxa de 0.1 em cada uma delas, buscando a que resultasse em uma melhor acurácia. A função de que apresentou os melhores resultados foi a *Radial Basis Function* (1), com a constante γ inicializada em $0,5$. Após esse processo, refinou-se a busca na vizinhança desse parâmetro, porém não se obteve melhor acurácia.

$$K(x_i, x_j) = e^{-\gamma||(x_i - x_j)||^2} \quad (1)$$

IV. Experimentos e Análises

O objetivo dos experimentos é avaliar e comparar a acurácia e o tempo de processamento do treinamento e reconhecimento/treinamento para cada classificador (tempo da validação), em cada uma das séries utilizadas. Para o corpus de treino inicial na classificação de cada série, utilizou-se os 1023 primeiros exemplos, correspondentes ao intervalo de 02 de fevereiro de 2009 a 26 de março de 2013. A Figura 5 apresenta a quantidade de exemplos para cada fase na base de inicial de treino (Base de Treino). Chamou-se Base de Teste a base com os exemplos a partir do dia 27 de março de 2013 a 30 de junho de 2015. Essa base foi utilizada para aplicar a classificação e, após cada exemplo ser automaticamente anotado, ele é adicionado como treino para o classificador, porém com sua anotação correta (independente da anotação do classificador). A Figura 6 apresenta a quantidade de exemplos por classe na Base de Teste.

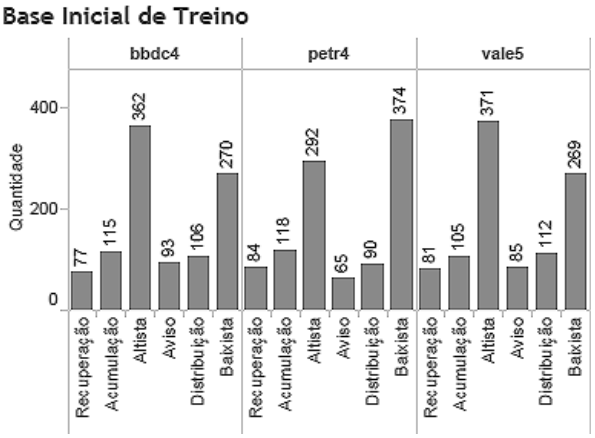

Figura 5. Quantidade de Exemplos para cada Fase na Base de Treino Inicial.

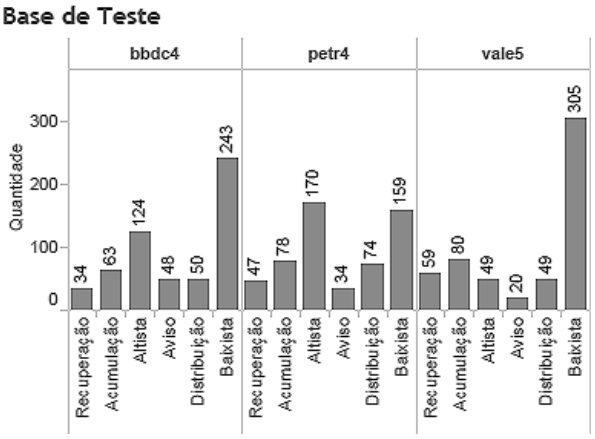

Figura 6. Quantidade de Exemplos para cada Fase na Base de Teste.

A fim de comparar a acurácia dos classificadores, utilizou-se o processo de validação apresentado na Seção III-B. Faz-se importante perceber que, ao repetir essa validação, o resultado obtido é o mesmo para ambos os classificadores: SVM e K-NN. No caso da WiSARD, por haver um mapeamento aleatório da retina nas memórias, a acurácia resultante pode variar. Para contornar esse problema foi calculado o desvio padrão da acurácia resultante de 30 processos de validação, de maneira que a distribuição de médias amostrais se aproxime de modo satisfatório a uma distribuição normal, pelo Teorema Central do Limite. Foram realizados diversos testes com a WiSARD, com e sem a mecânica de *Bleaching*, utilizando

Tabela II
DESVIO PADRÃO DA WISARD COM 4 BITS UTILIZANDO O MECANISMO DE BLEACHING, PARA CADA ÍNDICE.

	BBDC4	PETR4	VALE5
WiSARD	0,82%	0,90%	1,09%

diferentes quantidades de *bits*. A WiSARD que demostrou a melhor acurácia foi utilizando 4 *bits* com *Bleaching*, e obteve desvio padrão baixo o que confirma a boa precisão da classificação, como ser visto na Tabela II. A Figura 7 apresenta a acurácia dos classificadores em cada uma das séries. É possível perceber que a WiSARD apresentou acurácia muito próxima a do SVM nos índices PETR4 e BBDC4, embora tenha obtido uma acurácia inferior no índice VALE5. Para este índice, o K-NN apresentou melhor acurácia, embora próximo da acurácia do SVM.

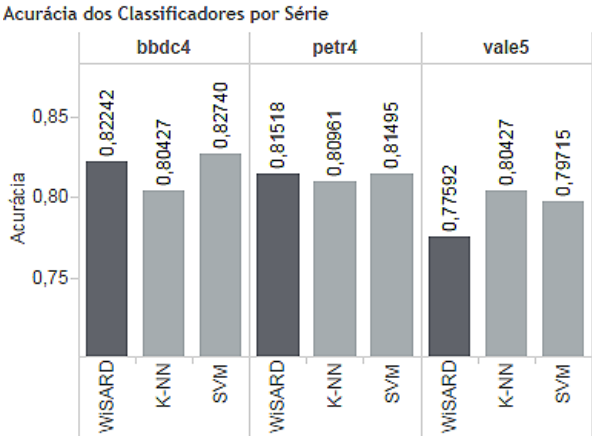

Figura 7. Acurácia dos Classificadores para cada Série Temporal.

Para entender melhor o comportamento da WiSARD em cada uma das séries é importante avaliar a acurácia para cada classe de exemplo. Essa análise também é motivada pela necessidade de saber o quão correta pode estar uma classificação dado que se encontra em uma determinada classe. Importante perceber, também, que existem classes específicas para compra e venda de ativos e que avaliar a acurácia dado um resultado pode ser importante para o analista. Visando essa análise, construiu-se uma matriz de confusão para a classificação da WiSARD em cada série temporal. As Tabelas III IV V apresentam as Matrizes de Confusão do classificador WiSARD com 4 *bits* utilizando *Bleaching* nas séries BBDC4, PETR4 e VALE5, respectivamente.

Tabela III
MATRIZ DE CONFUSÃO WISARD NO ÍNDICE BBDC4.

	Rec.	Ac.	Alt.	Av.	Dis.	Baix.
Recuperação	42,5%	7,4%	2,9%	0,0%	0,0%	47,3%
Acumulação	5,1%	80,9%	2,7%	0,4%	0,1%	10,8%
Altista	0,0%	3,2%	87,5%	6,3%	2,8%	0,1%
Aviso	0,0%	0,0%	29,0%	56,9%	14,0%	0,1%
Distribuição	0,0%	0,0%	3,2%	16,3%	80,5%	0,0%
Baixista	4,5%	2,8%	0,2%	0,1%	1,6%	90,8%

Tabela IV
MATRIZ DE CONFUSÃO WISARD NO ÍNDICE PETR4.

	Rec.	Ac.	Alt.	Av.	Dis.	Baix.
Recuperação	52,3%	14,8%	0,1%	0,0%	0,0%	32,8%
Acumulação	12,6%	85,5%	0,0%	0,0%	0,0%	1,9%
Altista	0,0%	4,7%	87,9%	6,1%	1,0%	0,2%
Aviso	0,0%	0,0%	63,8%	31,1%	5,1%	0,0%
Distribuição	0,0%	0,0%	5,5%	7,5%	86,9%	0,2%
Baixista	6,6%	0,0%	0,0%	0,0%	3,8%	89,6%

Tabela V
MATRIZ DE CONFUSÃO WISARD NO ÍNDICE VALE5.

	Rec.	Ac.	Alt.	Av.	Dis.	Baix.
Recuperação	48,1%	9,5%	0,0%	0,0%	0,0%	42,4%
Acumulação	11,7%	75,7%	0,4%	0,0%	0,0%	12,2%
Altista	0,2%	8,0%	68,8%	20,1%	2,9%	0,0%
Aviso	0,0%	0,0%	50,7%	40,3%	9,0%	0,0%
Distribuição	0,6%	3,7%	8,7%	13,5%	67,1%	6,4%
Baixista	6,8%	2,6%	0,0%	0,0%	1,3%	89,3%

Comparando a matriz de confusão do índice VALE5 (Tabela V) com os outros dois (Tabelas IV e III) é possível perceber que o erro nas classes Distribuição e Altista da VALE5 é maior do que nos outros índices. Provavelmente, um dos motivos que gerou essa diferença foi a mudança no comportamento da série, considerando que a Base Treino (Figura 5) possuía uma elevada proporção de Altistas enquanto a Base de Teste (Figura 6) possui uma baixa proporção dessa classe.

Outra análise efetuada foi o cálculo do tempo de processamento para as duas etapas da validação: (i)Treinamento com a Base de Treino e (ii)Reconhecimento e Treinamento com a Base de Teste. Todos os testes foram executados 30 vezes em um ambiente Windows 7 64 bits rodando em um computador Intel Core i5-2400 3.10 GHz com 4GB de RAM. Foi calculado a média e o desvio padrão do tempo para a série BBDC4, pois todas as séries retornavam um tempo próximo para o mesmo classificador. O desvio padrão apresentado por todos os classificadores foi menor do que 0,01%, não sendo apresentado na Tabela VI, onde as médias dos tempos de processamento das etapas são apresentadas.

Tabela VI
MÉDIA DO TEMPO DE PROCESSAMENTO PARA OS CLASSIFICADORES NO ÍNDICE BBDC4.

Classificador	(i) Treinamento Base de Treino	(ii) Reconhecimento e Treinamento Base de Teste
WiSARD	0,054	0,25
SVM	0,03	29,7
K-NN	0	4,5

O SVM e o K-NN usaram a biblioteca sklearn[1]. Vale destacar que essa implementação é otimizada, diferentemente da sequencial utilizada na WiSARD, apesar dela ser altamente paralelizável. Mesmo assim percebe-se pela Tabela VI que ela possui o menor tempo para a etapa de Reconhecimento e Treinamento (ii). Essa vantagem permite que a WiSARD seja usada na tarefa de aprendizado *on-line* com intervalos menores que os outros classificadores.

[1]http://scikit-learn.org/stable/

V. Conclusões e Trabalhos Futuros

O presente trabalho apresentou a proposta de utilizar a rede WiSARD combinada com a estratégia de médias móveis aplicada no mercado financeiro pela análise técnica. Utilizou-se como métrica de comparação entre os classificadores a acurácia e o tempo de processamento em duas diferentes etapas da validação. Para comparar a WiSARD utilizou-se dois classificadores: K-NN e SVM. Optou-se por utilizar três séries financeiras com alto volume de negociação no mercado de ações brasileiro: BBDC4, PETR4 e VALE5.

Na avaliação de acurácia, a WiSARD apresentou resultados próximos ao do SVM em duas séries: BBDC4 e PETR4. Já para o índice VALE5, o K-NN obteve o melhor resultado, porém foi analisado que a série temporal da Base de Treino da VALE5 apresentou significativa diferença na distribuição de suas fases (classes) para a Base de Teste. Além disso, matrizes de confusão foram construídas a fim de avaliar a classificação da rede WiSARD em cada fase, para cada série. Embora a WiSARD com o mapeamento aleatório possa apresentar diferentes acurácias ao longo dos experimentos, pela análise apresentada do desvio padrão, menor que 1% para os índices BBDC4 e PETR4 e 1,09% para a VALE5, pode-se afirmar que a classificação possui boa precisão. Além da acurácia foi avaliado o tempo de processamento para as etapas da validação. É possível perceber que a WiSARD, embora implementada sequencialmente, apresenta tempo muito infeior ao dos outros classificadores, cuja implementação é otimizada.

No futuro, espera-se construir um agente autônomo capaz de negociar no mercado financeiro brasileiro com a modelagem aqui apresentada, juntamente com o volume negociado. Além disso, pretende-se implementar uma política de esquecimento na WiSARD para favorecer os exemplos mais próximos do intervalo de classificação, considerando que a série histórica mais recente influencia mais os preços do que o passado. Planeja-se avaliar, também, o percentual da base necessário para o treino da rede e estudar do efeito da discretização no desempenho da WiSARD.

Agradecimentos

CNPq, FAPERJ e CAPES.

Referências

[1] J. J. Murphy, *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. Penguin, 1999.

[2] F. E. Tay and L. Cao, "Application of support vector machines in financial time series forecasting," *Omega*, vol. 29, no. 4, pp. 309–317, 2001.

[3] L. A. Teixeira and A. L. I. De Oliveira, "A method for automatic stock trading combining technical analysis and nearest neighbor classification," *Expert systems with applications*, vol. 37, no. 10, pp. 6885–6890, 2010.

[4] G. E. Box, G. M. Jenkins, and G. C. Reinsel, *Time series analysis: forecasting and control*. John Wiley & Sons, 2011, vol. 734.

[5] P. J. Brockwell and R. A. Davis, *Introduction to time series and forecasting*. Springer Science & Business Media, 2006.

[6] G. Zhang, B. E. Patuwo, and M. Y. Hu, "Forecasting with artificial neural networks:: The state of the art," *International journal of forecasting*, vol. 14, no. 1, pp. 35–62, 1998.

[7] K. Alkhatib, H. Najadat, I. Hmeidi, and M. K. A. Shatnawi, "Stock price prediction using k-nearest neighbor (knn) algorithm," *International Journal of Business, Humanities and Technology*, vol. 3, no. 3, pp. 32–44, 2013.

[8] R. K. Nayak, D. Mishra, and A. K. Rath, "A naïve svm-knn based stock market trend reversal analysis for indian benchmark indices," *Applied Soft Computing*, no. 0, pp. –, 2015. [Online]. Available: http://www.sciencedirect.com/science/article/pii/S1568494615003920

[9] S. Choudhury, S. Ghosh, A. Bhattacharya, K. J. Fernandes, and M. K. Tiwari, "A real time clustering and {SVM} based price-volatility prediction for optimal trading strategy," *Neurocomputing*, vol. 131, no. 0, pp. 419 – 426, 2014. [Online]. Available: http://www.sciencedirect.com/science/article/pii/S0925231213009296

[10] A. F. De Souza, F. D. Freitas, and A. G. Coelho de Almeida, "Fast learning and predicting of stock returns with virtual generalized random access memory weightless neural networks," *Concurrency and Computation: Practice and Experience*, vol. 24, no. 8, pp. 921–933, 2012.

[11] J. Alhassan and S. Misra, "Using a weightless neural network to forecast stock prices: A case study of nigerian stock exchange," *Scientific Research and Essays*, vol. 6, no. 14, pp. 2934–2940, 2011.

[12] P.-C. Chang, D. di Wang, and C. le Zhou, "A novel model by evolving partially connected neural network for stock price trend forecasting," *Expert Systems with Applications*, vol. 39, no. 1, pp. 611 – 620, 2012. [Online]. Available: http://www.sciencedirect.com/science/article/pii/S095741741101013X

[13] M. C. A. Neto, G. D. Calvalcanti, and T. I. Ren, "Financial time series prediction using exogenous series and combined neural networks," in *Neural Networks, 2009. IJCNN 2009. International Joint Conference on*. IEEE, 2009, pp. 149–156.

[14] M. C. A. Neto, G. Tavares, V. M. Alves, G. D. Cavalcanti, and T. I. Ren, "Improving financial time series prediction using exogenous series and neural networks committees," in *Neural Networks (IJCNN), The 2010 International Joint Conference on*. IEEE, 2010, pp. 1–8.

[15] R. C. Cavalcante, A. L. Oliveira *et al.*, "An autonomous trader agent for the stock market based on online sequential extreme learning machine ensemble," in *Neural Networks (IJCNN), 2014 International Joint Conference on*. IEEE, 2014, pp. 1424–1431.

[16] I. Aleksander, W. Thomas, and P. Bowden, "Wisard a radical step forward in image recognition," *Sensor review*, vol. 4, no. 3, pp. 120–124, 1984.

[17] Ó. Fontenla-Romero, B. Guijarro-Berdiñas, D. Martinez-Rego, B. Pérez-Sánchez, and D. Peteiro-Barral, "Online machine learning," *Efficiency and Scalability Methods for Computational Intellect*, p. 27, 2013.

[18] B. P. Grieco, P. M. Lima, M. De Gregorio, and F. M. França, "Producing pattern examples from "mental" images," *Neurocomputing*, vol. 73, no. 7, pp. 1057–1064, 2010.

[19] I. Aleksander, M. De Gregorio, F. M. G. França, P. M. V. Lima, and H. Morton, "A brief introduction to weightless neural systems." in *ESANN*. Citeseer, 2009.

[20] D. de Oliveira Cardoso, "Uma arquitetura para agrupamento de dados em fluxo contínuo baseada em redes neurais sem pesos," Ph.D. dissertation, Universidade Federal do Rio de Janeiro, 2012.

[21] L. C. Bandeira and F. M. G. França, "Nc-wisard: Uma interpretação sem pesos do modelo neural neocognitron," Master's thesis, Universidade Federal do Rio de Janeiro (UFRJ), 2010.

[22] H. C. Carneiro, F. M. França, and P. M. Lima, "Multilingual part-of-speech tagging with weightless neural networks," *Neural Networks*, vol. 66, no. 0, pp. 11 – 21, 2015. [Online]. Available: http://www.sciencedirect.com/science/article/pii/S0893608015000465

[23] P. Cunningham and S. J. Delany, "k-nearest neighbour classifiers," *Mult Classif Syst*, pp. 1–17, 2007.

[24] V. N. Vapnik and S. Kotz, *Estimation of dependences based on empirical data*. Springer-Verlag New York, 1982, vol. 41.

[25] V. Vapnik, "The nature of statical learning theory," 1995.

[26] D. N. Sotiropoulos, C. D. Kounavis, P. Kourouthanassis, and G. M. Giaglis, "What drives social sentiment? an entropic measure-based clustering approach towards identifying factors that influence social sentiment polarity," in *Information, Intelligence, Systems and Applications, IISA 2014, The 5th International Conference on*. IEEE, 2014, pp. 361–373.

[27] W. Huang, Y. Nakamori, and S.-Y. Wang, "Forecasting stock market movement direction with support vector machine," *Computers & Operations Research*, vol. 32, no. 10, pp. 2513–2522, 2005.

[28] Neologica, "Diamante - uma estratégia simples utilizando médias móveis," http://www.nelogica.com.br/conhecimento/artigos/indicadores-estudo/estrategia-diamante, Accessed: 07 de junho de 2015.

[29] System Trader Success, "Market phase – going beyond the death cross," http://systemtradersuccess.com/market-phase-going-beyond-the-death-cross/, Accessed: 07 de junho de 2015.