

# 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 adicionar 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 optouse 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 dividido em: Conceitos Básicos, no qual é apresentado o classificador WiSARD, os classificadores de comparação e as estratégias financeiras utilizadas; Metodologia, onde é feita 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 discussões 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).

O K-NN é um classificador que categoriza um dado exemplo baseado em  $k$  (um número definido) exemplos mais próximos do corpus de treino [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 aritméticas 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
$PF > MMA_{50}$	$PF > MMA_{50}$
$PF < MMA_{100}$	$PF > MMA_{100}$
$MMA_{50} < MMA_{100}$	$MMA_{50} < MMA_{100}$
Altísta	Aviso
$PF > MMA_{50}$	$PF < MMA_{50}$
$PF > MMA_{100}$	$PF > MMA_{100}$
$MMA_{50} > MMA_{100}$	$MMA_{50} > MMA_{100}$
Distribuição	Baixista
$PF < MMA_{50}$	$PF < MMA_{50}$
$PF < MMA_{100}$	$PF < MMA_{100}$
$MMA_{50} > MMA_{100}$	$MMA_{50} < MMA_{100}$

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 prever 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 previsão 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 aquele 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  $\gamma$  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  $\gamma$  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.

Base Inicial de Treino

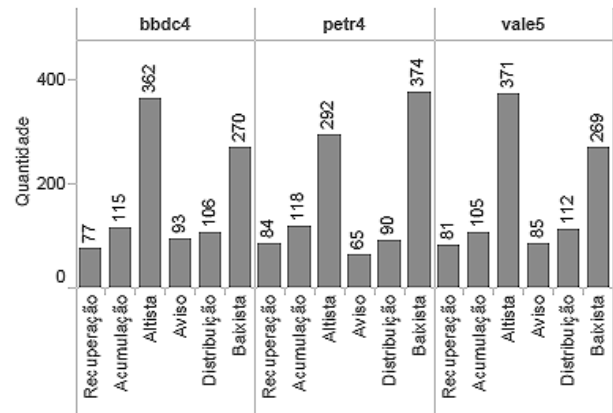


Figura 5. Quantidade de Exemplos para cada Fase na Base de Treino Inicial.

Base de Teste




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 demonstrou 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.

Acurácia dos Classificadores por Série

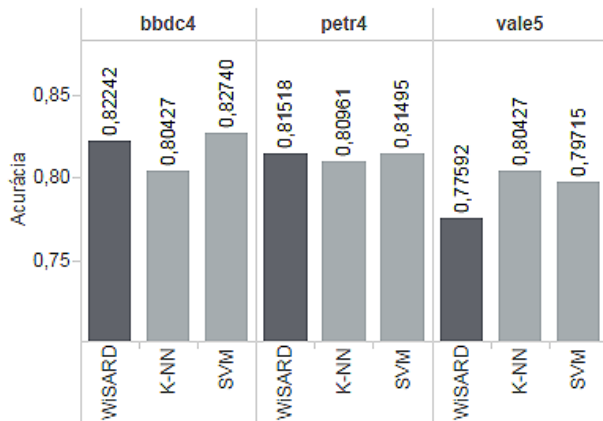


Figura 7. Acurácia dos Classificadores para cada Série Temporal.

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<sup>1</sup>. 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.

<sup>1</sup><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 inferior 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. Martínez-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 statistical 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.neologica.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.