



Universidade Federal de Pernambuco

Centro de Informática

Graduação em Ciência da Computação

ANÁLISE DE PRÉ-PROCESSAMENTO NO DESEMPENHO DE PREVISÃO DE SÉRIES TEMPORAIS FINANCEIRAS

Vitor Teixeira Costa

TRABALHO DE GRADUAÇÃO

Recife

Junho de 2008

Universidade Federal de Pernambuco

Centro de Informática

Vitor Teixeira Costa

ANÁLISE DE PRÉ-PROCESSAMENTO NO DESEMPENHO DE PREVISÃO DE SÉRIES TEMPORAIS FINANCEIRAS

*Trabalho apresentado ao programa de Graduação em
Ciência da Computação do Centro de Informática da
Universidade Federal de Pernambuco como requisito parcial
para obtenção do grau de Bacharel em Ciência da
Computação.*

Orientador: Prof. Germano Crispim Vasconcelos

Recife

Junho de 2008

ASSINATURAS

Este Trabalho de Graduação é resultado dos esforços do aluno Vitor Teixeira Costa, sob a orientação do professor Germano Crispim Vasconcelos, sob o título “ANÁLISE DE PRÉ-PROCESSAMENTO NO DESEMPENHO DE PREVISÃO DE SÉRIES TEMPORAIS FINANCEIRAS”. Todos abaixo estão de acordo com o conteúdo deste documento e os resultados deste Trabalho de Graduação.

Vitor Teixeira Costa – Aluno

Prof. Germano Crispim Vasconcelos – Orientador

AGRADECIMENTOS

Aos meus pais, familiares, amigos, colegas, professores e a Deus.

RESUMO

Nas últimas décadas o estudo do uso de redes neurais artificiais para a previsão de séries temporais financeiras tem crescido bastante no meio científico. A grande capacidade de generalização das redes neurais e o reconhecimento de padrões em sistemas complexos, não-lineares e com quantidade considerável de ruído explicam o atual interesse nesse modelo.

Paralelamente, existe uma escola de pensamento no âmbito financeiro que estuda as variações de mercado, tentando prever preços futuros baseando-se em dados passados da série. Essa escola, a escola de análise técnica, utiliza diferentes métodos para maximizar a acurácia de suas previsões. Entre eles está o uso de indicadores técnicos e métodos de suavização da série, identificando tendências e reversões no mercado. Diversos estudos foram feitos utilizando essas técnicas como método de pré-processamento de séries temporais para redes neurais.

Este trabalho tem como objetivo analisar o desempenho de uma rede *multi-layer perceptron* para previsão de séries temporais utilizando métodos de pré-processamento baseados nos indicadores desenvolvidos pela escola de análise técnica.

Palavras-chave: Séries Temporais, Redes Neurais Artificiais, Mercado Financeiro, Análise Técnica, Indicadores Técnicos.

SUMÁRIO

Introdução	1
1.1 Contexto.....	1
1.2 Objetivos.....	2
1.3 Estrutura do Documento	3
Redes Neurais e a Previsão de Séries Temporais.....	5
2.1 Redes Neurais Artificiais	5
2.1.1 O Problema da Previsão	7
2.2 Projeto da Rede	9
2.3 Normalização dos Dados	10
2.4 Sistemas Híbridos.....	11
2.4.1 Algoritmos Genéticos	11
2.4.2 Enxame de Partículas	13
Mercado Financeiro.....	15
3.1 Teoria do Mercado Eficiente.....	15
3.2 Análise Fundamentalista.....	16
3.3 Análise Técnica.....	17
3.3.1 Médias Móveis	17
3.3.2 Moving Average Convergence Divergence.....	19
3.3.3 Momentum.....	19
3.3.4 Rate of Change.....	20
3.3.5 Índice de Força Relativa	20
3.3.6 Estocástico	21

Séries Utilizadas	22
4.1 Índice Dow Jones Industrial Average.....	22
4.2 Índice Nasdaq Composite.....	23
4.3 Índice S&P 500.....	24
4.4 Ativo PETR3	24
Experimentos	26
5.1 Metodologia	26
5.2 Medidas de Desempenho	27
5.3 Experimentos com o índice Dow Jones Industrial Average	29
5.4 Experimentos com o índice Nasdaq Composite	31
5.5 Experimentos com o índice S&P 500	33
5.6 Experimentos com o ativo PETR3	34
5.7 Análise dos Resultados.....	36
Considerações Finais	37
6.1 Conclusões	37
6.2 Trabalhos Futuros.....	38
Referências Bibliográficas	39

LISTA DE FIGURAS

Figura 2.1: Processamento dos neurônios da rede.....	6
Figura 2.2: Rede <i>multi-layer perceptron</i>	6
Figura 4.1: Gráfico da série do índice Dow Jones Industrial Average.....	23
Figura 4.2: Gráfico da série do Índice Nasdaq Composite.	24
Figura 4.3: Gráfico da série do Índice S&P 500.	25
Figura 4.4: Gráfico da série do ativo PETR3.	25
Figura 5.1: Série DJIA e a previsão para a configuração 01.....	30
Figura 5.2: Série DJIA e a previsão para a configuração 02.....	30
Figura 5.3: Série DJIA e a previsão para a configuração 03.....	31
Figura 5.4: Série Nasdaq e a previsão para a configuração 01.	32
Figura 5.5: Série Nasdaq e a previsão para a configuração 02.	32
Figura 5.6: Série Nasdaq e a previsão para a configuração 03.	32
Figura 5.7: Série S&P 500 e a previsão para a configuração 01.....	33
Figura 5.8: Série S&P 500 e a previsão para as configurações 02 e 03.....	34
Figura 5.9: Série PETR3 e a previsão para a configuração 01.....	35
Figura 5.10: Série PETR3 e a previsão para a configuração 02.....	35
Figura 5.11: Série PETR3 e a previsão para a configuração 03.....	35

LISTA DE TABELAS

Tabela 5.1: Resultados obtidos para o índice Dow Jones Industrial Average.....	30
Tabela 5.2: Resultados obtidos para o índice Nasdaq Composite.....	31
Tabela 5.3: Resultados obtidos para o índice S&P 500.....	33
Tabela 5.4: Resultados obtidos para o ativo PETR3.....	34

INTRODUÇÃO

Este capítulo faz uma introdução inicial ao tema discutindo durante o resto do documento. Inicialmente é mostrado o contexto do problema aqui abordado. Em seguida, são mostrados os resultados esperados após a conclusão deste trabalho. Por fim, a estrutura deste documento é mostrada, dando um breve resumo do conteúdo dos capítulos seguintes.

1.1 CONTEXTO

Redes neurais artificiais têm sido amplamente utilizadas nas últimas décadas na previsão de séries temporais financeiras, eliminando riscos gerados por incerteza e auxiliando o planejamento e a tomada de decisões. Uma provável resposta para seu uso nesta área reside no fato de que as redes neurais têm a capacidade de reconhecer padrões em sistemas complexos, não-lineares e com quantidade razoável de ruído. Capacidade essa não encontrada nos métodos estatísticos convencionais. Outra importante característica das redes neurais é sua capacidade de generalização, tornando-o o modelo ideal para problemas onde a quantidade de dados históricos é de certa forma limitada.

O projeto da rede neural é de fundamental importância para o resultado obtido na previsão. Diferentes parâmetros, tais como os retardos temporais utilizados, o número de camadas, o número de nós em cada camada, a função de ativação e o algoritmo de treinamento devem ser considerados. Em muitas situações, a metodologia de tentativa e erro deve ser utilizada para procurar a melhor configuração da rede para um problema específico. Diversos modelos foram propostos no meio científico, identificando seus pontos fortes e suas deficiências [13]. O uso de sistemas híbridos com redes neurais e outros algoritmos de otimização também podem ser encontrados na literatura, obtendo a melhor configuração da rede através de uma busca evolutiva.

No mercado financeiro, diversas técnicas são utilizadas por analistas para melhor entender o seu comportamento futuro. Essas técnicas estão divididas em duas principais escolas de pensamento: análise fundamentalista e análise técnica. Estratégias de negociação, regras e conceitos baseados nessas duas escolas têm assistido os investidores no seu processo de tomada de decisão [16]. A primeira utiliza dados financeiros da empresa e a análise do cenário econômico atual na tentativa de prever movimentos futuros do mercado. Já a escola de análise técnica assume que as variações nos preços são baseadas em tendências do mercado, e tais tendências podem ser identificadas e utilizadas para previsão de preços futuros [1]. A análise técnica baseia-se na premissa de que a direção futura do mercado pode ser determinada examinando seu passado. Existe ainda uma terceira escola de pensamento, a *random walk*, que diz que os preços de mercado sofrem variações de maneira randômica e imprevisível [23].

Unindo o poder das redes neurais na previsão de séries temporais e técnicas de pré-processamento utilizando a análise técnica, há a possibilidade de se obter uma melhor taxa de acerto na previsão de preços futuros do mercado. Diversos estudos demonstram o uso de indicadores técnicos no problema da previsão de séries temporais financeiras [1, 6, 7, 9, 10, 20]. Esses indicadores são calculados a partir de dados da série e são geralmente utilizados para identificar tendências ou para descobrir reversões no mercado, gerando sinais de compra ou de venda. O uso de médias móveis no pré-processamento das séries também é discutido nesses estudos.

1.2 OBJETIVOS

Dado o contexto apresentado na seção anterior, esse trabalho realiza um estudo sobre o impacto do pré-processamento da série no desempenho das redes neurais artificiais na previsão de séries temporais financeiras. A metodologia de pré-processamento dos dados será baseada nos fundamentos da escola de análise técnica, utilizando as médias móveis sobre os valores da série, e os vários indicadores técnicos desta escola. Um estudo detalhado sobre cada um dos possíveis indicadores utilizados neste trabalho será feito, mostrando a equação utilizada para o cálculo do indicador e sua interpretação no âmbito financeiro.

O modelo de rede neural a ser utilizado nesse trabalho será baseado no modelo *multi-layer perceptron*. Utilizando os dados pré-processados juntamente com os valores dos retardos temporais como padrões de entrada para a rede, o modelo tentará fazer a previsão do valor do dia seguinte.

As séries temporais utilizadas neste estudo são os três principais índices do mercado de ações norte-americano – *Dow Jones Industrial Average*, *Nasdaq Composite* e *S&P 500* – e os dados históricos do ativo PETR3, relativo à empresa Petrobras e negociado na Bolsa de Valores de São Paulo.

Uma vez concluídos experimentos, os resultados obtidos serão analisados através das medidas de desempenho utilizadas e a partir dos gráficos comparativos contendo a previsão gerada e a série utilizada. Por fim, possíveis trabalhos futuros com o objetivo de estender o conhecimento obtido durante este trabalho serão identificados.

1.3 ESTRUTURA DO DOCUMENTO

A organização deste documento é apresentada a seguir.

Capítulo 1 – Introdução: neste primeiro capítulo é realizada uma breve introdução ao tema abordado neste documento, identificando o contexto atual do problema e mostrando os objetivos deste trabalho.

Capítulo 2 – Redes Neurais e a Previsão de Séries Temporais: neste capítulo é descrito o funcionamento das redes neurais artificiais e como elas podem ser utilizadas no problema da previsão de séries temporais. Os vários aspectos relacionados ao projeto da rede e como eles podem afetar seu desempenho também são abordados. Por fim, duas abordagens da área de inteligência artificial para busca da melhor arquitetura da rede serão brevemente analisadas.

Capítulo 3 – Mercado Financeiro: neste capítulo são descritos os métodos utilizados por analistas e investidores para tentar prever movimentos futuros de mercado com objeto de maximizar os lucros obtidos em investimentos no mercado acionário. Dentre estes métodos, são expostos neste trabalho os utilizados pela análise

fundamentalista e pela análise técnica. Além disso, é mostrada uma teoria que diz ser impossível a previsão de preços futuros de mercado.

Capítulo 4 – Séries Utilizadas: neste capítulo são descritas as séries utilizadas nos experimentos. Para cada uma das séries é mostrado de modo breve um pouco de sua história e é indicado o período no qual os dados históricos foram extraídos, incluindo um gráfico do mesmo.

Capítulo 5 – Experimentos: neste capítulo é mostrado como os experimentos foram conduzidos. As medidas de desempenho utilizadas são descritas, identificando suas características e significados. Por fim, os resultados experimentais são demonstrados e analisados.

Capítulo 6 – Considerações Finais: neste capítulo são apresentadas as conclusões obtidas a partir dos estudos e experimentos realizados durante o trabalho. Propostas de trabalhos futuros baseados nos resultados obtidos também serão discutidas.

REDES NEURAIS E A PREVISÃO DE SÉRIES TEMPORAIS

Neste capítulo é descrito o funcionamento das redes neurais artificiais e como elas podem ser utilizadas no problema da previsão de séries temporais. Os vários aspectos relacionados ao projeto da rede e como eles podem afetar seu desempenho também são abordados. Por fim, duas abordagens da área de inteligência artificial para busca da melhor arquitetura da rede serão brevemente analisadas.

2.1 REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais fazem parte de um modelo computacional baseado nos sistemas neurais biológicos, em outros termos, o cérebro. Ela consiste de um grupo de unidades de processamento completamente ou parcialmente interconectado, chamados de neurônios. Em alguns modelos, tais unidades são agrupadas em camadas, tendo sempre uma camada de entrada e uma camada de saída e podendo ter zero ou mais camadas escondidas.

Cada conexão entre neurônios possui um peso indicando a intensidade da mesma. São esses pesos os responsáveis por armazenar o conhecimento adquirido pela rede, e, como será visto mais adiante, fazem parte do processamento dos neurônios. No processo de aprendizagem, esses pesos mudam de valor, de modo a obter uma maior generalização das informações apresentadas à rede.

Os neurônios da rede são unidades de processamento simples. Eles possuem uma ou mais conexões de entrada, cada uma com um peso atribuído. Sua função é computar a soma ponderada dos valores de suas conexões de entrada e utilizar este valor como entrada para uma função de ativação. A saída desta função é a saída do

próprio neurônio [12], e é passada adiante por suas conexões de saída. A Figura 2.1 mostra o fluxo de processamento dentro dos neurônios.




Figura 2.1: Processamento dos neurônios da rede.

O modo como as camadas estão dispostas e como os neurônios estão interligados permite uma grande variedade de modelos de redes neurais. Muitos modelos podem ser encontrados na literatura, dentre os quais os mais populares são [27]:

- Redes *multi-layer perceptron*;
- Redes Recorrentes;
- Redes de Kohonen;
- Redes de Hopfield;
- Redes ART.

Dentre esses modelos, as mais usadas tanto em problemas gerais como no problema específico de previsão de séries temporais financeiras são as redes *multi-layer perceptron*. Esse modelo tem seus neurônios agrupados em camadas. Existem apenas uma camada de entrada, onde os padrões de entrada são alimentados na rede, e uma camada de saída, onde o resultado do processamento da rede é exposto. Além dessas duas camadas, esse modelo pode ter uma ou mais camadas intermediárias, chamadas de camadas escondidas. A Figura 2.2 mostra o arranjo das camadas, onde é possível ver que camadas vizinhas possuem os neurônios completamente interconectados.




Figura 2.2: Rede *multi-layer perceptron*.

Seu funcionamento é baseado no paradigma *feed-forward*, e inicia quando dados de entrada são apresentados à camada de entrada. Os valores são processados pelos neurônios e a saída dos mesmos é apresentada para a camada seguinte. Este último passo se repete até que se obtenha um resultado da última camada.

Durante o treinamento da rede, a saída da rede é comparada com a saída desejada para o padrão apresentado, gerando uma medida de erro global. O algoritmo de treinamento é então utilizado para ajustar os pesos de modo a minimizar este erro [11]. O modelo mais popular de treinamento para redes *multi-layer perceptron* é o *backpropagation*. Como o próprio nome diz, ele propaga o erro encontrado começando pela camada de saída e indo até a camada de entrada. À medida que itera pelas camadas, ele ajusta os pesos das conexões de acordo com o erro global da rede.

Os padrões utilizados durante o processo de treinamento da rede podem ser divididos em dois ou três conjuntos, descritos a seguir:

- Conjunto de treinamento: utilizado para o treinamento da rede, momento os pesos da rede ajustados de maneira a diminuir seu erro global;
- Conjunto de validação: utilizado durante o treinamento para a validação do mesmo, determinando o melhor momento para seu término;
- Conjunto de testes: utilizado após o término do treinamento, verificando o desempenho do modelo obtido.

Quando divididos em dois conjuntos, utilizam-se apenas os conjuntos de treinamento e de testes. Neste caso, 70% a 90% dos padrões fazem parte do conjunto de treinamento, sendo o restante parte dos testes. Já para o outro caso, todos os três conjuntos são utilizados, sendo os padrões particionados em 50% para treinamento, 25% para validação e 25% para testes. Em ambos os casos, não existem regras para o particionamento dos dados, sendo os valores aqui expostos um consenso entre os vários trabalhos encontrados na literatura.

2.1.1 O Problema da Previsão

A previsão de séries temporais é um método específico de previsão que utiliza um conjunto de valores históricos para prever um valor futuro. Este conjunto de valores

históricos, também referenciado como a própria série temporal, são observações igualmente espaçadas ao longo do tempo e podem representar dados como vendas mensais de uma empresa ou consumo diário de eletricidade de uma casa. Neste trabalho, estudaremos em especial os dados que compõem históricos de índices de mercado e preços de negociação de ativos em bolsas de valores.

Na tentativa da previsão baseada em dados históricos, é feita uma análise de uma janela de tempo, contendo dados passados e presentes, para determinar pontos futuros. Tal janela é formada por um conjunto de pontos da série, chamados de retardos temporais, que devem trazer, juntamente com os dados pré-processados, informações suficientes para a determinação dos acontecimentos futuros. Dessa forma, a escolha dos retardos temporais utilizados é de fundamental importância para uma melhor caracterização da série.

Diversos modelos estatísticos têm sido propostos para resolver o problema da previsão de séries temporais. Modelos tradicionais, como Box-Jenkins e modelos auto-regressivos, assumem que as séries temporais em estudo são geradas através de um processo linear [13]. Tais modelos lineares podem ser compreendidos e analisados em maiores detalhes e são fáceis de explicar e implementar. Entretanto, seu uso é inadequado em casos onde a série possui característica não-linear. Estudos afirmam que séries financeiras possuem ruídos e são não-lineares [10], inviabilizando o uso de tais modelos para este problema específico.

Nos últimos anos, um crescente número de estudos tem aparecido sobre o uso de redes neurais em previsões de séries temporais financeiras. Algumas características das redes neurais artificiais explicam seu uso nesta área [13]. Primeiro, são modelos auto-adaptativos, de modo que aprendem a partir de exemplos e capturam relações estruturais dos dados mesmo que essas sejam desconhecidas ou difíceis de descrever. Esses modelos são conhecidos por serem aproximadores universais de funções, sendo capaz de aproximar qualquer função contínua a qualquer precisão desejada. Outro fator importante é sua habilidade em reconhecer padrões não lineares nos dados das séries temporais. Característica essa encontrada nos movimentos do mercado financeiro. Além disso, redes neurais podem inferir dados não apresentados no processo de treinamento

mesmo se os padrões apresentarem ruído devido à sua grande capacidade de generalização.

No âmbito financeiro, exemplos de uso de redes neurais não só se limitam ao problema da previsão, mas são utilizadas também no reconhecimento de padrões em gráficos financeiros, estimação do preço de opções e indicações de compra ou venda de uma determinada ação.

2.2 PROJETO DA REDE

O projeto de uma rede neural é uma atividade delicada devido à grande quantidade de parâmetros a serem ajustados. A correta configuração destes parâmetros pode resultar em grandes diferenças no desempenho obtido pela rede. Sendo assim, eles serão apresentados de modo resumido nesta seção.

Um dos principais problemas encontrados no projeto da rede é a definição de sua topologia. A topologia da rede define a organização dos neurônios e os tipos de conexão permitidos [4]. Para o problema específico da previsão de séries temporais, a quantidade de entradas, ou retardos temporais, é fundamental para uma melhor caracterização da série em estudo. A seleção deste parâmetro depende do problema em estudo, sendo necessária inclusive uma análise da série temporal em questão. Métodos de tentativa e erro também podem ser utilizados a fim de achar os retardos relevantes.

Outro problema encontrado na definição da topologia é a determinação do número de camadas escondidas e a quantidade neurônios em cada uma destas camadas. O mais comum neste caso é o uso de apenas uma ou no máximo duas camadas intermediárias, sendo essa escolha dependente do problema. Esses valores são suficientes pois redes com apenas uma camada escondida são capazes de aproximar qualquer função não-linear contínua. A adição de novas camadas só traria complexidade para a rede, inibindo sua capacidade de generalização. A definição do número de neurônios em cada camada também é dependente do problema em questão. Um número grande de neurônios pode causar *overfitting*, ou seja, o modelo se ajusta demais às características do conjunto de treinamento e perde a sua capacidade generalização [8]. Em contrapartida, um número pequeno pode fazer com que a rede não aprenda de

maneira correta. Diferentes estudos utilizam valores baseado no número de neurônios na camada de entrada [14], mas em geral utilizam-se processos de tentativa e erro.

Em geral, as redes *multi-layer perceptron* possuem os neurônios completamente conectados, ou seja, os neurônios de uma camada possuem conexões com todos os neurônios das camadas adjacentes. Outras possíveis configurações são as redes parcialmente conectadas ou redes com conexões diretas da camada de entrada para a camada de saída.

Além dos problemas relativos à topologia da rede, outros parâmetros devem ser configurados. A função de ativação dos neurônios é um deles, e define a saída do neurônio a partir dos valores de suas entradas. As funções de ativação mais encontradas na literatura são as funções sigmóide logística, tangente hiperbólica e linear [25]. Em redes *multi-layer perceptron*, é comum utilizar a função linear para os neurônios de entrada e a função sigmóide logística para os demais neurônios, tanto das camadas escondidas quanto das camadas intermediárias.

Por fim, mas não menos importante, tem-se a escolha do algoritmo de treinamento. Esses algoritmos são responsáveis por minimizar o erro global obtido pela rede. Para isso, eles devem ajustar os pesos das conexões dos neurônios em cada iteração do processo de treinamento. A maioria dos algoritmos utilizados para isso emprega alguma forma de gradiente descendente. Dentre os mais populares está o *backpropagation* [17]. Sua escolha é uma tarefa difícil, podendo ser novamente utilizado o método de tentativa e erro.

2.3 NORMALIZAÇÃO DOS DADOS

Para serem mais eficientes, os neurônios devem receber valores dentro de uma faixa limitante. Valores que podem variar em uma ordem de magnitude muito grande farão com que a rede não consiga aprender os padrões apresentados. Isso ocorre por causa da função de ativação dos neurônios, que nos casos não-lineares têm os valores de saída em um intervalo baixo (de 0 a 1 para o caso da função sigmóide logística).

Existem várias maneiras de se normalizar um conjunto de dados. Dentre eles, o mais simples faz uma transformação linear para um determinado intervalo. Tal normalização pode ser feita da seguinte maneira para o intervalo $[a, b]$:

$$X' = (b - a) \frac{X - X_{min}}{X_{max} - X_{min}} + a \quad (2.1)$$

onde X' é o valor normalizado, X é o valor original, X_{min} é o valor mínimo do conjunto de dados e X_{max} é o valor máximo do conjunto de dados.

Como as saídas desejadas utilizadas durante o treinamento também foram normalizadas, a denormalização das saídas da rede deve ser feita. Esse procedimento faz parte do pós-processamento, e permite a obtenção do valor real previsto. Para que a denormalização seja possível, os valores X_{min} e X_{max} utilizados durante o pré-processamento devem ser armazenados e utilizados posteriormente no período de pós-processamento.

2.4 SISTEMAS HÍBRIDOS

Sistemas híbridos utilizando redes neurais artificiais e outras técnicas de inteligência artificial podem ser utilizadas para otimizar o poder das redes neurais. Seu principal papel neste caso é encontrar as melhores configurações descritas anteriormente para um problema específico. Desde modo, eles automatizam o processo de tentativa e erro, que em geral costuma ser muito tedioso. Entre essas técnicas estão os algoritmos genéticos e o enxame de partículas, detalhados a seguir.

2.4.1 Algoritmos Genéticos

Algoritmos genéticos são métodos de busca e otimização utilizados para encontrar soluções exatas ou aproximadas. Eles são algoritmos evolutivos, e utilizam técnicas inspiradas na teoria da evolução, como herança genética, mutação, seleção e *crossover*¹.

¹ *Crossover* é o processo no qual dois cromossomos são emparelhados e são selecionados seções dos genes de cada cromossomo.

A busca ocorre não a partir de apenas um indivíduo, mas sim de uma população, contendo as várias soluções para o problema. Cada indivíduo da população é representado por um cromossomo, que por sua vez é composto por vários genes. Cada gene representa um parâmetro a ser ajustado. As operações aplicadas pelo algoritmo nos cromossomos permitem a geração de novos indivíduos com características únicas.

Uma das atividades dos algoritmos genéticos é ranquear os indivíduos utilizando uma função de *fitness*, de modo a identificar aqueles que representam a melhor solução. Ela é aplicada a cada um dos indivíduos, resultando em maiores valores para as melhores soluções. No caso das redes neurais, essa função é geralmente baseada no erro médio quadrático ou em um conjunto de outras medidas de desempenho.

Durante cada iteração do algoritmo, uma nova população é gerada através da adição de novos indivíduos filhos, mutação de indivíduos da população atual e remoção daqueles que possuem *fitness* muito baixo. Para a adição e mutação dos indivíduos é necessário fazer uma seleção das melhores soluções encontradas. Existem várias maneiras de se escolher os indivíduos que sofrerão operações genéticas. Uma delas é o método de seleção por roleta [27], onde ocorre uma amostragem estocástica da população, sendo a probabilidade de escolha de um indivíduo diretamente proporcional ao seu valor de *fitness*.

Duas operações podem ocorrer durante a geração da nova população: *crossover*, também chamada de recombinação, e mutação. A primeira é responsável por gerar cromossomos filhos a partir da combinação de dois cromossomos pais. Essa combinação permite que o cromossomo gerado possua as melhores características dos cromossomos pais. Já a mutação altera um cromossomo de maneira randômica, possibilitando a diversificação da população.

Existem diferentes formas de se implementar um algoritmos genético, mas todos eles seguem um modelo básico. Tal modelo é apresentado a seguir:

1. A população é criada, resultando em um conjunto de cromossomos randomicamente inicializados;
2. Cada membro da população é avaliado, utilizando a função de *fitness*;
3. Os indivíduos que sofrerão operações genéticas são selecionados;

4. Uma nova geração é criada a partir das operações genéticas sofridas pelos indivíduos selecionados e da remoção das piores soluções;
5. Os novos indivíduos são avaliados através da função de *fitness*;
6. O algoritmo volta para o passo 3.

O processo descrito acima é repetido até que uma determinada condição de parada ocorra. A decisão de parada pode ocorrer quando uma solução satisfizer um critério mínimo, o número máximo de iterações ser alcançado ou quando sucessivas gerações não conseguem resultar em uma melhor solução.

O problema de mínimo local enfrentado pelas redes neurais não possui muito impacto nos algoritmos genéticos [26]. Isso ocorre devido ao fato de as operações de mutação e *crossover* permitirem uma grande diversificação da população. Além disso, o algoritmo procura sempre melhorar o indivíduo com melhor função de *fitness*, mantendo-o sempre na população, enquanto procura por indivíduos melhores que ele.

No caso específico de redes neurais, dois métodos podem ser utilizados em conjunto com os algoritmos genético. O primeiro permite o ajuste de todos os parâmetros, inclusive o valor dos pesos. Desse modo, o algoritmo genético se torna responsável pelo treinamento da rede neural. No segundo caso, só ocorrem ajustes nos parâmetros da topologia da rede.

2.4.2 Enxame de Partículas

Enxame de partículas – do inglês *Particle Swarm Optimization* (PSO) [22] – é uma técnica de otimização estocástica baseada no comportamento social de aves e peixes. Assim como os algoritmos genéticos, o PSO também é iniciado a partir uma população randômica de soluções e busca a melhor solução através de novas gerações. Apesar desta semelhança, esta nova técnica não utiliza operadores genéticos, como *crossover* e mutação. As partículas do enxame andam pelo espaço do problema seguindo sua própria melhor solução encontrada até o momento e a melhor solução global descoberta pelo enxame. Desta maneira, se alguma partícula encontrar uma melhor solução, o enxame é de certa forma direcionado a este novo ponto.

Cada partícula mantém as informações sobre sua posição atual e sua melhor posição encontrada até o momento. O algoritmo armazena também as informações sobre a melhor posição encontrada por todo o enxame. A cada iteração, a velocidade das partículas é atualizada e sua posição é recalculada. De modo simplificado, o cálculo da velocidade ocorre da seguinte maneira [15]:

$$v(t + 1) = wv(t) + c_1r_1 \cdot \alpha(t) + c_2r_2 \cdot \gamma(t) \quad (2.2)$$

onde $v(t)$ é a velocidade da partícula no tempo t , $\alpha(t)$ é a distância entre a posição atual da partícula e posição da melhor solução encontrada por ela, $\gamma(t)$ é a distância entre a posição atual da partícula e a posição da melhor solução encontrada pelo enxame, c_1 e c_2 representam coeficientes de aceleração e controlam a variação máxima da velocidade em uma única iteração, r_1 e r_2 são variáveis randômicas no intervalo $[0, 1]$. A variável w representa a inércia, e varia linearmente de 1 até 0 durante o algoritmo. Como o espaço de busca pode ser multidimensional, tal velocidade deve ser calculada para cada um dos parâmetros a ser otimizado [22].

Assim como os algoritmos genéticos, o PSO utiliza uma função de *fitness* para ranquear as partículas do enxame. Uma vez calculada a nova posição da partícula, a mesma é comparada com a melhor solução própria da partícula e com a melhor solução encontrada pelo enxame. Caso o *fitness* da posição atual seja melhor que a da melhor solução própria atual, a partícula guarda sua nova posição como a melhor própria. De modo análogo, quando o *fitness* da posição atual for melhor que a da melhor solução atual do enxame, o algoritmo guarda esta posição como sendo a melhor posição encontrada pelo enxame.

As iterações prosseguem até que uma determinada condição de parada ocorra. A decisão de parada pode ocorrer quando uma solução satisfizer um critério mínimo, o número máximo de iterações ser alcançado ou quando sucessivas iterações não conseguirem resultar em uma melhor solução.

MERCADO FINANCEIRO

Neste capítulo são mostrados os métodos utilizados por analistas de mercado na tentativa de prever movimentos futuros do mercado. Entre esses métodos estão os estudos das análises fundamentalista e técnica. A primeira se baseia em fundamentos da empresa e da economia na qual ela está inserida. Já a segunda utiliza somente os dados passados da série, utilizando análise grafistas e de indicadores técnicos na busca de melhores retornos em investimentos no mercado de capitais. São estes indicadores técnicos aqui estudados que servirão de base para os métodos de pré-processamento utilizados neste trabalho. Este capítulo mostra também, de modo breve, uma teoria que diz não ser possível tal previsão.

3.1 TEORIA DO MERCADO EFICIENTE

A teoria do mercado eficiente afirma que o preço atual de mercado de uma determinada ação reflete a assimilação de todas as informações disponíveis [23]. Isso significa que, dadas as informações de mercado, não é possível prever variações de preços futuros.

Um mercado eficiente pode ser definido como um mercado onde um grande número de investidores racionais age no sentido de maximizar seus lucros. Baseando-se na disponibilidade das informações, ou seja, considerando que estão disponíveis publicamente a todos, tais informações estarão inclusas no preço da ação. À medida que novas informações se tornam disponíveis, o estado desbalanceado do mercado é rapidamente descoberto e um movimento corretivo ocorre para ajustá-lo. Dependendo do tipo de informação utilizada, três diferentes formas de mercado eficiente podem ser observadas:

- Forma Fraca – Somente o histórico de preços é considerado;
- Forma Semi-Forte – As informações disponíveis publicamente são consideradas;

- Forma Forte – Informações tanto públicas quanto privadas são consideradas.

Essa teoria em sua forma fraca pode ser vista como base para aqueles que acreditam que as variações nos valores de ações e de índices de mercado seguem um modelo *Random Walk*. De acordo com este modelo, variações de preços são serialmente independentes e o histórico de preços não é capaz de se tornar um indicador para previsão de direções futuras de mercado, ou seja, a variação do mercado é randômica e imprevisível [24]. Além disso, este modelo prega que a melhor estratégia de mercado seria o de comprar uma ação e mantê-la – *buy and hold* – ao invés de tentar ter rendimentos maiores que o mercado.

3.2 ANÁLISE FUNDAMENTALISTA

Investidores que se baseiam na análise fundamentalista utilizam os resultados dos relatórios financeiros das empresas para determinar seu valor intrínseco, ou valor justo. Ela tenta identificar casos onde o valor acionário de uma determinada empresa está subvalorizada, gerando possíveis lucros em movimentos de preços futuros. Em geral, esse tipo de análise é utilizado para investimentos em longo prazo [3].

Além disso, segundo essa escola deste pensamento, é possível fazer uma análise mais ampla, no nível industrial ou de mercado, através não só dos dados de relatórios financeiros, mas também da análise do cenário micro e macroeconômico, do setor industrial no qual a empresa está inserida e da oferta e/ou demanda dos produtos produzidos por ela, além de outros indicadores econômicos [10].

Caso o valor justo não seja igual ao preço atual das ações, a análise fundamentalista indica que a ação está sobre ou subvalorizada, e que o seu valor de mercado irá caminhar gradativamente até o preço justo. Ao contrário daqueles que crêem na teoria do mercado eficiente, os fundamentalistas acreditam que os preços de mercado não refletem precisamente toda informação disponível.

3.3 ANÁLISE TÉCNICA

Resumidamente falando, a análise técnica é um método utilizado para tentar prever movimentos futuros nos preços de ações baseando-se única e exclusivamente na observação de movimentos passados. Esse tipo de análise assume que a história sempre se repete, e que a direção futura do mercado pode ser determinada examinando padrões ocorridos no passado [28]. A análise técnica não resulta em previsões precisas, mas tenta antecipar o que é mais provável de acontecer ao longo do tempo. Em suas observações, essa análise pode utilizar os seguintes dados de um determinado período de tempo:

- Preço de abertura;
- Maior preço negociado;
- Menor preço negociado;
- Preço de fechamento;
- Volume de negócios.

Esse período pode ser baseado no *intraday* (1-minuto, 5-minutos, 30-minutos, 1-hora) ou nas variações nos preços diários, semanais, mensais ou até anuais.

A análise técnica pode ainda ser subdividida em análises grafistas e de indicadores técnicos. Como o próprio nome já diz, os grafistas utilizam diferentes tipos de gráficos contendo o histórico de preços para traçar linhas de tendência, canais de congestão, resistências, suportes e identificar padrões gráficos, como topo duplo, fundo duplo, ombro-cabeça-ombro, triângulo simétrico, triângulo ascendente etc. Os tipos de gráficos mais comumente utilizados são os de linha, de barra e o *candlestick*. Por fim, temos também o uso dos indicadores técnicos, cujos valores são calculados utilizando dados passados da série. Os mais populares no meio financeiro são apresentados a seguir.

3.3.1 Médias Móveis

As médias móveis estão entre as ferramentas mais simples e populares utilizadas na análise técnica [19]. Sua principal função é suavizar os dados da série, tornando mais

fácil a identificação de tendências. Além disso, as médias móveis servem como base de cálculo para vários outros indicadores técnicos.

Em sua essência, as médias móveis são calculadas utilizando os valores da série em um período de tempo determinado. Há atualmente diferentes tipos de médias móveis, mas neste documento iremos falar somente sobre as duas mais populares na área financeira. Das variadas médias móveis existentes, a que possui o cálculo mais fácil é a média móvel simples (MMS). Ela pode ser obtida efetuando uma simples média aritmética dos valores da série no período observado, e é dada por:

$$MMS_x = \frac{\sum_{i=0}^n V_{x-i}}{n} \quad (3.1)$$

onde V_x é o valor de fechamento no dia x , e n é o tamanho da janela utilizada.

Um dos problemas encontrados no uso das MMS é o fato de todos os valores do período observado possuírem o mesmo peso. Para contornar esse problema, muitos analistas utilizam a média móvel exponencial (MME). Este tipo de média móvel dá um peso maior às observações mais recentes do período observado. A MME é dada por:

$$MME_x = V_x \cdot k + MME_{x-1} \cdot (1 - k) \quad (3.2)$$

$$k = \frac{2}{1 + n} \quad (3.3)$$

onde V_x é o valor de fechamento no dia x , MME_{x-1} é a média móvel exponencial do dia anterior, e k é um multiplicador calculado a partir da janela de tempo utilizada n . Para exemplificar, utilizando um período de cinco dias, obtemos k igual a 33%. Como pode ser observado, a utilização de médias móveis exponenciais dá um peso bem maior às observações mais recentes, comparadas com o peso de 20% quando se utiliza médias móveis simples.

O uso de médias móveis no âmbito financeiro serve essencialmente para identificar tendências e descobrir áreas para iniciar operações [5]. Elas possuem o propósito de acompanhar o progresso de uma tendência, e não de prever ações do mercado. Isso se dá pelo simples fato de serem utilizados os valores de um período passado, ou seja, é um indicador atrasado. Elas só acompanham o mercado e indicam se uma nova tendência foi iniciada, mas somente após esse fato já ter acontecido.

3.3.2 Moving Average Convergence Divergence

O Moving Average Convergence Divergence (MACD) é um dos mais simples e mais confiáveis indicadores disponíveis e utiliza duas linhas, uma rápida e outra lenta, para indicar sinais de compra e de venda. A linha rápida, chamada de linha MACD, é a diferença entre duas médias móveis, uma mais longa e outra mais curta. Já a linha lenta, chamada de linha de sinal, é calculada pela média móvel da própria linha MACD. O uso mais popular do MACD é baseado nas médias móveis exponenciais de 26 – longa – e 12 – curta – dias. Já para a linha de sinal, o mais usado é a média móvel exponencial de nove dias da linha MACD. Ambas as linhas oscilam em torno do eixo 0, sem limites inferiores ou superiores. Tal indicador é dado por:

$$MACD = MME_{12} - MME_{26} \quad (3.4)$$

$$Signal = MME_9^{MACD} \quad (3.5)$$

onde MME_{12} é a média móvel exponencial de 12 dias do valor de fechamento, MME_{26} é a média móvel exponencial de 26 dias do valor de fechamento e MME_9^{MACD} é a média móvel exponencial de 9 dias da linha MACD.

É importante notar que o MACD mede a diferença entre as duas médias móveis, e que valores positivos indicam que a linha da MME de 12 dias está acima da linha da MME de 26 dias. Analogamente, valores negativos indicam que a linha da MME de 12 dias está abaixo da linha da MME de 26 dias. Os sinais de compra e venda mais comuns gerados por este indicador ocorrem quando a linha MACD cruza a linha de sinal e quando a linha MACD passa a ser positiva após estar no campo negativo.

3.3.3 Momentum

O conceito de *momentum* é a mais básica aplicação de análise de osciladores. Este indicador mensura a velocidade da variação dos preços, analisando continuamente a diferença de preços em um intervalo de tempo determinado. O *momentum* é dado por:

$$M = V - V_x \quad (3.6)$$

onde V é o último preço de fechamento e V_x é o preço de fechamento de x dias atrás. Apesar de qualquer período de tempo poder ser utilizado, janelas de cinco ou dez dias

são mais comumente utilizadas. Valores positivos indicam altas nos preços, enquanto que valores negativos indicam quedas.

3.3.4 Rate of Change

O Rate of Change (ROC) é bem semelhante ao *momentum*, baseando-se também no último preço de fechamento e no preço de fechamento de alguns dias atrás. A fórmula do ROC é dada por:

$$ROC = 100 \cdot \frac{V - V_x}{V_x} \quad (3.7)$$

onde V é o último preço de fechamento e V_x é o preço de fechamento de x dias atrás. Em geral, o cálculo deste indicador utiliza janelas de dez ou doze dias.

Diferentemente do *momentum*, o gráfico ROC mostra a variação dos preços em percentagem oscilando em torno de uma linha de equilíbrio, a linha zero. Valores acima da linha de equilíbrio indicam que os últimos preços estão maiores que os preços passados. Analogamente, valores abaixo da linha de equilíbrio indicam que os últimos preços estão menores que os preços passados.

3.3.5 Índice de Força Relativa

O Índice de Força Relativa (IFR) foi desenvolvido para contornar dois problemas encontrados no uso de técnicas baseadas no *momentum* [21]. Uma alta ou queda brusca nos preços de uma série há 10 dias (para o caso de uma janela de tempo de 10 dias) pode causar uma forte distorção na linha de *momentum*, mesmo que os preços atuais mostrem pequena variação. Algum tipo de suavização se mostra então necessário para minimizar tais distorções. O segundo problema é a necessidade em se ter uma faixa constante de variação. O IFR não só provê uma série mais suavizada como também cria uma faixa limitante, podendo ter seu valor variando somente entre 0 e 100. O valor deste indicador é dado por:

$$IFR = 100 - \frac{100}{1 + \frac{\sum \varphi}{\sum \omega}} \quad (3.8)$$

onde φ são as variações de preço de fechamento em alta e ω são as variações de preço de fechamento em baixa. Em geral, o cálculo deste indicador utiliza uma janela de tempo de nove ou catorze dias. Quanto menor o tamanho da janela, mais sensível será o oscilador e mais larga será sua amplitude [24].

Movimentos abaixo de 30 são considerados como sobrevendidos e um sinal de compra é gerado quando o indicador cruza novamente a linha dos 30 para cima. Analogamente, movimentos acima de 70 são considerados como sobrecomprados e um sinal de venda é gerado quando o indicador cruza novamente a linha dos 70 para baixo.

3.3.6 Estocástico

O estocástico é um oscilador que indica o estado atual do preço de fechamento em relação à faixa da menor baixa até a maior alta de um determinado período de dias. Duas linhas são utilizadas para este indicador: a primeira, $\%K$, é calculado a partir da faixa descrita anteriormente; e a segunda, $\%D$, é a média móvel simples de três dias de $\%K$. Esses dois valores formam o estocástico rápido. É comum também o uso das médias móveis desses dois valores, gerando uma versão mais suave chamada estocástico lento. Os valores do estocástico rápido são dados por:

$$\%K = 100 \cdot \frac{C - L_x}{H_x - L_x} \quad (3.9)$$

$$\%D = MMS_3^{\%K} \quad (3.10)$$

onde C é o último preço de fechamento, L_x é a menor baixa no período de x dias atrás e H_x é a maior alta para os mesmos x períodos.

Em geral, janelas de tempo de catorze dias são utilizadas. Ambas as fórmulas resultam em valores em uma escala de 0 a 100. Da mesma maneira que o IFR, o estocástico identifica reversões no mercado quando $\%D$ cruza as áreas de sobrevenda e sobrecompra. Mas ao contrário do IFR, melhores resultados foram encontrados quando utilizada a faixa de 20 a 80, e não de 30 a 70. Os sinais de compra e venda gerados por esse indicador ocorrem quando o estocástico está na situação de reversão de mercado descrita acima e as linhas $\%K$ e $\%D$ se cruzam.

SÉRIES UTILIZADAS

Neste capítulo são descritas as séries utilizadas nos experimentos realizados durante este trabalho. Os três principais índices do mercado financeiro norte-americano foram utilizados. Além desses, a série contendo os preços do ativo PETR3, relativo à empresa Petrobras e negociada na Bolsa de Valores de São Paulo, também foi estudada.

4.1 ÍNDICE DOW JONES INDUSTRIAL AVERAGE

O índice Dow Jones Industrial Average, também chamado de DJIA, Dow 30, ou mais informalmente como Dow Jones, é um dos vários indicadores de mercado acionário criados por Charles Dow, editor do *Wall Street Journal* do século XIX e co-fundador da *Dow Jones & Company*. Dow criou o índice como uma forma de medir o desempenho da parte industrial do mercado acionário norte-americano. Ele é o segundo mais antigo indicador de mercado norte-americano, ficando atrás apenas do Dow Jones Transportation Average, também criado por Dow.

Hoje, o índice é composto por 30 das maiores empresas relativas ao parque industrial dos Estados Unidos. Ele é calculado através de uma média ponderada dos preços das ações dessas empresas. Para compensar os efeitos de *splits*² das ações e outros possíveis ajustes, ele é atualmente uma média redimensionada, e não a média real dos preços de suas ações participantes. A soma dos preços das ações é dividida por um divisor, que muda sempre que uma das empresas participantes do índice tem um *split* em suas ações ou distribuição de dividendos para os acionistas, para gerar o valor do índice. Uma vez que o divisor atualmente é inferior a um, o valor do índice é maior do que a soma dos preços das ações participantes.

² Um *split* de um ativo aumenta o número de ações no mercado e ajusta o preço de modo que o capital de mercado da empresa continue o mesmo.

A série do índice Dow Jones Industrial Average utilizada é composta por 1420 pontos referentes às observações diárias do índice de janeiro de 1998 a agosto de 2003. A Figura 4.1 mostra o gráfico para a série utilizada.




Figura 4.1: Gráfico da série do índice Dow Jones Industrial Average.

4.2 ÍNDICE NASDAQ COMPOSITE

Criado em 1971, o índice Nasdaq Composite faz parte do primeiro e maior mercado de ações eletrônico do mundo, a Nasdaq (*National Association of Securities Dealers Automated Quotation System*). Com aproximadamente 3.200 empresas, ela lista mais ativos e possui o maior volume de negociações por dia do que qualquer outra bolsa de valores no mundo. Ela é altamente acompanhada nos Estados Unidos e no mundo como indicador do desempenho das ações de empresas tecnológicas e de alto crescimento. Uma vez que ambas as empresas norte-americanas e empresas não norte-americanas estão listadas neste índice, ele não é exclusivo do mercado dos Estados Unidos.

A série do índice Nasdaq Composite utilizada é composta por 1626 pontos referentes às observações diárias do índice de janeiro de 1998 a junho de 2004. A Figura 4.2 mostra o gráfico para a série utilizada.



Figura 4.2: Gráfico da série do Índice Nasdaq Composite.

4.3 ÍNDICE S&P 500

O índice S&P 500 (*Standard & Poor 500*) trata-se de um índice composto por 500 grandes empresas qualificadas devido ao seu tamanho de mercado, sua liquidez e sua representação de grupo industrial, das quais as maiorias são norte-americanas. Todos os ativos do índice são empresas de grande visibilidade e são negociadas nos dois maiores mercados acionários norte-americanos, tanto na *New York Stock Exchange* (NYSE) quanto na Nasdaq. Depois do *Dow Jones Industrial Average*, o S&P 500 é o indicador mais amplamente utilizado para análise das maiores empresas acionárias norte-americanas. Ele é considerado um dos mais importantes indicadores da economia dos Estados Unidos.

A série do índice S&P 500 utilizada é composta por 2021 pontos referentes às observações diárias do índice de janeiro de 1995 a dezembro de 2002. A Figura 4.3 mostra o gráfico da série utilizada.

4.4 ATIVO PETR3

O ativo PETR3 – ações ordinárias da Petrobras – é um dos dois ativos relativos à Petrobras em ações negociadas na Bolsa de Valores de São Paulo (Bovespa). A Petrobras é uma empresa brasileira que opera no segmento de prospecção, exploração, produção, refino, comercialização e transporte de petróleo, principalmente em tecnologias de extração em água de alta profundidade, e seus derivados no Brasil e no exterior.

Atualmente, a Petrobras é a 3ª maior empresa das Américas, 6ª maior do mundo, ultrapassando empresas de grande porte como a Microsoft, AT&T e Wal-Mart. Suas ações, PETR3 e PETR4, representam cerca de 16% do Índice Bovespa, o principal indicador do mercado financeiro brasileiro.




Figura 4.3: Gráfico da série do Índice S&P 500.

A série do ativo PETR3 utilizada é composta por 2079 pontos referentes às observações diárias do ativo de janeiro de 1995 a julho de 2003. A Figura 4.4 mostra o gráfico da série utilizada.




Figura 4.4: Gráfico da série do ativo PETR3.

EXPERIMENTOS

Este capítulo mostra como os experimentos foram conduzidos, identificando os indicadores técnicos utilizados como método de pré-processamento e as configurações da rede utilizada. As medidas de desempenho utilizadas são descritas, analisando suas características e significados. Por fim, os resultados experimentais são demonstrados e analisados.

5.1 METODOLOGIA

Para se ter um comparativo do uso dos indicadores técnicos como método de pré-processamento, três diferentes configurações foram utilizadas durante a execução dos experimentos, sendo as mesmas descritas abaixo.

Configuração 01: nenhum pré-processamento foi realizado, utilizando apenas os retardos temporais da série.

Configuração 02: foram utilizados os retardos temporais e os indicadores técnicos para o retardo mais recente, e.g., caso sejam escolhidos os retardos 2, 4, 5 e 6, o pré-processamento utilizando indicadores técnicos será feito apenas para o retardo 2.

Configuração 03: o pré-processamento foi aplicado em todos os retardos utilizados como entrada para a rede.

Nem todos os indicadores técnicos estudados neste trabalho foram utilizados nos experimentos. Apenas alguns foram selecionados, sendo eles:

- Índice de Força Relativa de 9 períodos;
- Estocástico %K de 14 períodos;
- Estocástico %D de 3 períodos;
- Linha Moving Average Convergence Divergence;

- Linha de sinal do Moving Average Convergence Divergence;
- Rate of Change (ROC) de 5 períodos.

A normalização dos dados ocorreu de duas formas diferentes dependendo da natureza do valor apresentado. Para os dados que são sempre positivos, houve a normalização para o intervalo [0.1 0.9]. Já para os dados que oscilam em torno do eixo 0, como o MACD e o ROC, a normalização foi feita para o intervalo [-0.9 0.9].

Os dados das séries foram divididos em três partes: 50% para o treinamento da rede; 25% para a validação do treinamento; e o 25% restantes para geração de testes e avaliação da rede obtida.

Os parâmetros da rede, tais como retardos temporais relevantes, número de neurônios na camada escondida e algoritmo de treinamento, serão os mesmos do trabalho que apresenta o método TAEF (*Time-lag Added Evolutionary Forecasting Method*) [2], já que as séries financeiras estudadas são as mesmas. Esse modelo utiliza diferentes técnicas de inteligência artificial para a previsão de séries temporais, combinando redes neurais artificiais, um algoritmo genético modificado, um mecanismo de busca evolutiva pela dimensionalidade mínima necessária para a reconstrução do espaço de fase gerador da série e um procedimento de pós-processamento para a determinação da fase da previsão gerada.

5.2 MEDIDAS DE DESEMPENHO

A maioria dos trabalhos encontrados na literatura sobre previsão de séries temporais utiliza apenas um critério como método de avaliação de desempenho do modelo predictor. A medida mais popular utilizada para tal é o erro médio quadrático. Seu valor é formulado como a diferença entre o valor desejado e o valor previsto pelo modelo, e é dado por:

$$MSE = \frac{1}{N} \sum_{t=1}^N (target_t - output_t)^2 \quad (5.1)$$

onde N é o número de padrões, $target_t$ é a saída desejada para o modelo no instante t e $output_t$ é o valor previsto pela rede no instante t . Vale notar que os valores obtidos para

o MSE no domínio financeiro são muito mais elevados do que em outros problemas devido à dificuldade inerente de se prever esse tipo de série com exatidão [18].

Apesar de a medida MSE ser utilizada para guiar a rede durante seu treinamento, ela sozinha não pode ser considerada como medida absoluta para a comparação de diferentes modelos de redes neurais [2]. Por este motivo, outras medidas de desempenho serão utilizadas nos experimentos, proporcionando desta maneira uma análise mais conclusiva a respeito do desempenho obtido.

A primeira medida auxiliar de desempenho utilizada é o erro médio percentual absoluto, MAPE, e é dada por:

$$MAPE = \frac{100}{N} \sum_{t=1}^N \left| \frac{target_t - output_t}{X_t} \right| \quad (5.2)$$

onde N é o número de padrões, $target_t$ é a saída desejada para o modelo no instante t , $output_t$ é o valor previsto pela rede no instante t e X_t é o ponto da série no instante t .

A segunda medida utilizada é a estatística U de Theil. Ela associa o desempenho do modelo predictor com um modelo *random walk*. Caso U de Theil seja igual a 1, o modelo de rede utilizado possui o mesmo desempenho que o modelo *random walk*. Sendo maior que 1, o desempenho da rede é considerado inferior ao de um modelo do tipo *random walk*. Caso contrário, com U de Theil menor que 1, o modelo utilizado possui desempenho superior do que o modelo *random walk*. Os modelos de melhor desempenho têm essa medida tendendo a 0. Seu cálculo é dado por:

$$Theil = \frac{\sum_{t=1}^N (target_t - output_t)^2}{\sum_{t=1}^N (output_t - output_{t+1})^2} \quad (5.3)$$

onde N é o número de padrões, $target_t$ é a saída desejada para o modelo no instante t e $output_t$ é o valor previsto pela rede no instante t .

Outra medida de desempenho importante, principalmente para séries financeiras, é a previsão de mudança de direção. Ela mede o percentual de vezes em que a direção do valor previsto pelo modelo estava correta, ou seja, se o modelo predictor acertou se a variação seria positiva ou negativa. A medida POCID – Prediction of Change in Direction – é dada por:

$$POCID = \frac{100}{N} \sum_{t=1}^N D_t \quad (5.4)$$

$$D_t = \begin{cases} 1 & \text{se } (target_t - target_{t-1}) (output_t - output_{t-1}) > 0 \\ 0 & \text{caso contrário} \end{cases} \quad (5.5)$$

onde N é o número de padrões, $target_t$ é a saída desejada para o modelo no instante t e $output_t$ é o valor previsto pela rede no instante t .

Por último, utilizaremos a medida de variância relativa média (ARV). Ela associa o desempenho do modelo predictor com a média da série utilizada. Caso ARV seja igual a 1, o desempenho do modelo seria igual ao de um modelo que sempre retorna a média da série como valor previsto. Sendo maior que 1, o desempenho da rede é considerado inferior à previsão realizada utilizando a média da série. Caso contrário, com ARV menor que 1, o modelo utilizado possui desempenho superior do que a média da série. Assim como o U de Theil, a medida ARV tende a 0 para modelos ideais. Esta medida é dada por:

$$ARV = \frac{\sum_{t=1}^N (output_t - target_t)^2}{\sum_{t=1}^N (output_t - \overline{output})^2} \quad (5.6)$$

onde N é o número de padrões, $target_t$ é a saída desejada para o modelo no instante t , $output_t$ é o valor previsto pela rede no instante t e $\overline{output}$ é a média da série temporal.

5.3 EXPERIMENTOS COM O ÍNDICE DOW JONES INDUSTRIAL AVERAGE

Para a série do índice Dow Jones Industrial Average foram selecionados os retardos 2, 4, 5, 6, 9 e 10. Para a camada escondida, 10 neurônios foram utilizados. O algoritmo de treinamento foi o Levenberg-Marquart. A Tabela 5.1 mostra os valores das medidas de desempenho para as três configurações testadas.

Como pode ser observado, nenhuma configuração obteve desempenho satisfatório. Todas elas se comportaram pior que um modelo *random walk* de acordo com a estatística U de Theil. O POCID pouco abaixo de 50% encontrado em todas as configurações constata que o modelo é equivalente a um experimento do tipo cara ou coroa. Pode-se também observar que a inserção dos indicadores técnicos para o retardo

mais recente teve uma pequena influência negativa no desempenho da rede. Já a configuração 03 mostrou-se bastante inferior quando comparada à primeira configuração.

	Config. 01	Config. 02	Config. 03
MSE	2.08e-3	2.83e-3	2.73e-3
MAPE (%)	9.0598	10.0406	10.6685
Theil	2.1104	1.9628	3.2306
POCID (%)	47.3988	49.7109	46.2427
ARV	0.0740	0.1013	0.0987

Tabela 5.1: Resultados obtidos para o índice Dow Jones Industrial Average.

Os gráficos comparativos para os últimos 100 pontos do conjunto de teste entre os valores da série do índice Dow Jones Industrial Average, em linha sólida, e os valores previstos pela rede neural, em linha tracejada, são exibidos para cada uma das configurações utilizadas nas figuras 5.1, 5.2 e 5.3.




Figura 5.1: Série DJIA e a previsão para a configuração 01.




Figura 5.2: Série DJIA e a previsão para a configuração 02.

A análise dos gráficos mostra um deslocamento temporal de um passo para a previsão em todas as configurações. Tal característica é apresentada por modelos *random walk*, confirmando os resultados obtidos com a estatística U de Theil. Pode-se

verificar também um leve descolamento vertical da previsão para a configuração 03, confirmando novamente o alto valor do U de Theil obtido por esta configuração.




Figura 5.3: Série DJIA e a previsão para a configuração 03.

5.4 EXPERIMENTOS COM O ÍNDICE NASDAQ COMPOSITE

Para a série do índice Nasdaq Composite foram selecionados os retardos 3, 4, 6 e 8. Para a camada escondida, 11 neurônios foram utilizados. O algoritmo de treinamento foi o Levenberg-Marquart. A Tabela 5.2 mostra os valores das medidas de desempenho para as três configurações testadas.

	Config. 01	Config. 02	Config. 03
MSE	1.15e-3	2.19e-3	3.29e-3
MAPE (%)	7.2117	8.8945	11.3694
Theil	3.3922	2.7314	5.2220
POCID (%)	53.5353	52.5252	49.7474
ARV	0.0206	0.0401	0.0639

Tabela 5.2: Resultados obtidos para o índice Nasdaq Composite.

Novamente os resultados obtidos em todos os experimentos não foram satisfatórios. O alto valor obtido pela estatística U de Theil mostra que os modelos tiveram desempenho pior que o modelo *random walk*. Todos os experimentos obtiveram o POCID em torno de 50%, caracterizando os modelos estudados como experimentos do tipo cara ou coroa. Pela análise da tabela de resultados é possível observar uma leve degradação dos modelos na medida em que são inseridos os indicadores técnicos. A medida ARV apresentou bons resultados, em especial para a configuração 01.

Os gráficos comparativos para os últimos 100 pontos do conjunto de teste entre os valores da série do índice Nasdaq Composite, em linha sólida, e os valores previstos pela rede neural, em linha tracejada, são exibidos para cada uma das configurações utilizadas nas figuras 5.4, 5.5 e 5.6.




Figura 5.4: Série Nasdaq e a previsão para a configuração 01.




Figura 5.5: Série Nasdaq e a previsão para a configuração 02.




Figura 5.6: Série Nasdaq e a previsão para a configuração 03.

Assim como os resultados da série DJIA, a análise dos gráficos para os experimentos com a série Nasdaq apresentam um deslocamento temporal de um passo para a previsão em todas as configurações, caracterizando este modelo como um modelo *random walk*. Nestes experimentos, o descolamento vertical da previsão em relação à série é bastante visível ao inserir os dados da análise técnica, em especial para configuração 03, onde se tem o uso de indicadores técnicos para cada um dos retardos utilizados.

5.5 EXPERIMENTOS COM O ÍNDICE S&P 500

Para a série do índice S&P 500 foi selecionado apenas o primeiro retardo temporal. Para a camada escondida, 3 neurônios foram utilizados. O algoritmo de treinamento foi novamente o Levenberg-Marquart. A Tabela 5.3 mostra os valores das medidas de desempenho para as três configurações testadas.

	Config. 01	Config. 02	Config. 03
MSE	4.18e-4	4.26e-8	4.26e-8
MAPE (%)	4.0430	4.1065	4.1065
Theil	1.0183	1.0986	1.0986
POCID (%)	45.4545	45.8585	45.8585
ARV	0.0119	0.0123	0.0123

Tabela 5.3: Resultados obtidos para o índice S&P 500.

Pelo fato de ter sido utilizado apenas o primeiro retardo temporal, os experimentos para as configurações 02 e 03 são os mesmos. Para estes experimentos, a estatística U de Theil mostra que os resultados obtidos são equivalentes ao de um modelo *random walk*. Os valores abaixo de 50% para o POCID indicam uma taxa maior de erro na previsão da direção da variação do índice. As medidas MAPE e ARV mostraram bons resultados para todas as configurações quando comparados com os experimentos das outras séries financeiras. Por fim, não foram constatadas variações significativas no desempenho da rede após a utilização dos indicadores técnicos.

Os gráficos comparativos para os últimos 100 pontos do conjunto de teste entre os valores da série, em linha sólida, e os valores previstos pela rede neural, em linha tracejada, são exibidos para cada uma das configurações utilizadas nas figuras 5.7 e 5.8.




Figura 5.7: Série S&P 500 e a previsão para a configuração 01.




Figura 5.8: Série S&P 500 e a previsão para as configurações 02 e 03.

Neste experimento, é possível observar o deslocamento temporal exato de um passo para a previsão. Isso confirma os resultados obtidos com a estatística U de Theil, que mostrou o modelo experimental idêntico ao modelo *random walk*. Diferentemente das séries analisadas anteriormente, a introdução de indicadores técnicos nos padrões de entrada não causou um efeito de descolamento vertical entre a linha da previsão e a linha da série.

5.6 EXPERIMENTOS COM O ATIVO PETR3

Para a série do ativo PETR3 foram selecionados os retardos 3, 4 e 7. Para a camada escondida, 17 neurônios foram utilizados. O algoritmo de treinamento foi o Levenberg-Marquart. A Tabela 5.4 mostra os valores das medidas de desempenho para as três configurações testadas.

	Config. 01	Config. 02	Config. 03
MSE	4.86e-3	5.11e-3	5.21e-3
MAPE (%)	12.2718	12.6695	12.7092
Theil	2.6408	3.0485	4.3575
POCID (%)	48.6381	48.2490	49.0272
ARV	0.2001	0.2222	0.2238

Tabela 5.4: Resultados obtidos para o ativo PETR3.

Analisando a tabela de resultados é possível concluir que a inserção de indicadores técnicos não trouxe melhor desempenho para a série PETR3. Todas elas se comportaram pior que um modelo *random walk* de acordo com a estatística U de Theil e nem sequer obtiveram uma boa previsão da direção da variação do índice de acordo com o POCID, mostrando-se semelhante a um experimento do tipo cara ou coroa. Os

experimentos com a série PETR3 obtiveram os piores resultados para as medidas MAPE e ARV dentre as séries examinadas. Comparando as três configurações para esta série, é possível observar que todas as medidas de desempenho, exceto pela estatística U de Theil, permaneceram estáveis.

Os gráficos comparativos para os últimos 100 pontos do conjunto de teste entre os valores da série, em linha sólida, e os valores previstos pela rede neural, em linha tracejada, são exibidos para cada uma das configurações utilizadas nas figuras 5.9, 5.10 e 5.11.




Figura 5.9: Série PETR3 e a previsão para a configuração 01.




Figura 5.10: Série PETR3 e a previsão para a configuração 02.




Figura 5.11: Série PETR3 e a previsão para a configuração 03.

Assim como os experimentos com as outras séries, a análise gráfica dos resultados mostra um certo deslocamento temporal de um passo para a previsão em todas as configurações, confirmando o resultado obtido com a estatística U de Theil de

que o modelo utilizado se aproxima do modelo *random walk*. Percebe-se também nesta série, um pequeno descolamento vertical em alguns locais entre a linha da previsão e a linha da série quando os indicadores técnicos são utilizados.

5.7 ANÁLISE DOS RESULTADOS

Em geral todos os experimentos realizados não obtiveram resultados satisfatórios. Todos eles apresentaram a medida de desempenho U de Theil acima de um, indicando que os modelos experimentados possuem desempenho inferior do que um modelo *random walk*. Já para a medida POCID, todos os experimentos obtiveram valores em torno de 50%. Baseando-se neste resultado, pode-se constatar que os modelos utilizados são equivalentes a um experimento do tipo cara ou coroa.

Pela análise dos gráficos, pôde-se observar o deslocamento temporal de um passo para a previsão. Isso apenas confirmou os resultados obtidos com a estatística U de Theil. Foi possível notar também, que após a inserção valores pré-processados nos padrões de entrada, três das quatro séries utilizadas apresentaram um descolamento vertical da linha de previsão em relação à série, especialmente quando foram utilizados indicadores técnicos para todos os retardos temporais.

Das séries estudadas, apenas a série do índice S&P 500 não teve degradação do desempenho quando utilizados os dados pré-processados. Uma provável explicação para isto é a configuração utilizada para esta série, onde apenas o retardo temporal mais recente foi utilizado.

CONSIDERAÇÕES FINAIS

Este capítulo apresenta as conclusões obtidas a partir dos estudos e experimentos realizados durante o trabalho. Propostas de trabalhos futuros baseados nos resultados obtidos também serão discutidas.

6.1 CONCLUSÕES

Neste trabalho foram abordados os temas pertinentes à previsão de séries temporais financeiras. Primeiramente foram analisadas as redes neurais artificiais e o seu poder em solucionar problemas de previsão. O projeto da rede também foi abordado, explanando os diversos parâmetros necessários para configurar o modelo. Por fim, dois modelos de sistemas híbridos envolvendo redes neurais e técnicas de otimização inteligente foram discutidos, eliminando desta maneira o processo tedioso de tentativa e erro para a configuração dos parâmetros da rede.

Em seguida foi feito um estudo sobre o mercado financeiro, identificando os dados utilizados por analistas para prever movimentos futuros. Foram descritas as três vertentes existentes no âmbito financeiro: a teoria do mercado eficiente; a análise fundamentalista; e a análise técnica. Dentre estas, teve foco principal no trabalho a análise técnica por possuir os indicadores utilizados como método de pré-processamento da série. Os métodos utilizados para o pré-processamento dos dados foram analisados, explicando sua motivação e como utilizá-los para fazer análises do mercado.

Por fim, foram descritas as séries utilizadas nesse trabalho e a metodologia na qual os experimentos foram realizados. Os resultados obtidos foram mostrados através de diferentes medidas de desempenho e pelos gráficos contendo a série em questão e os valores previstos pelo modelo. Pôde-se observar, tanto pelas medidas de desempenho quanto pelos gráficos, que a inserção única e exclusiva de uma quantidade pequena de

indicadores técnicos não foi capaz de melhorar a performance da rede. Em alguns dos experimentos foi notável a degradação do desempenho quando foram utilizados indicadores técnicos para o mais recente retardo temporal, e pior ainda quando utilizados para todos os retardos selecionados.

6.2 TRABALHOS FUTUROS

Ainda utilizando os métodos utilizados por analistas de mercado, uma possível extensão para o método de pré-processamento aqui exposto é o uso de dados da análise fundamentalista, como resultados dos relatórios da empresa ou dados relativos à macroeconomia. Este novo modelo pode vir a ter melhores resultados, utilizando variáveis exógenas, e não só os dados passados da rede.

Na tentativa de previsão de movimentos futuros de mercado de uma determinada ação, outras séries temporais também podem ser utilizadas em conjunto na tentativa de agregar valores relevantes. Um exemplo disto são empresas produtoras de *commodities*³, e que possuem variações no mercado diretamente ligadas às variações de preços dos bens produzidos por ela.

Outro modelo interessante a ser trabalhado é a previsão da variação de preço do dia seguinte, ao invés de tentar prever o preço de fechamento. Este tipo de previsão permite uma maior tolerância a erros do que a previsão do preço exato, resultando em uma melhora significativa na habilidade de previsão das redes neurais. Estudos seguindo este modelo [9] mostram resultados acima de 70% para a medida POCID.

Por fim, um estudo pode ser realizado para a tentativa de previsão do valor exato em uma janela de vários dias à frente, e não só do dia seguinte como foi estudado neste trabalho. Isso porque a grande maioria dos indicadores utilizados não é utilizada para a previsão de preço do próximo dia, mas sim para antecipar o que é mais provável de acontecer ao longo de um certo espaço de tempo. Este tipo de previsão é tão valioso quanto o apresentado neste trabalho para investidores e analistas de mercado.

³ O termo *commodity* aplica-se àquelas mercadorias cujo preço é determinado em bolsas de mercadorias.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Jingtao Yao, Chew Lim Tan. **A case study on using neural networks to perform technical forecasting of forex.** *Neurocomputing*, 34:79-98, 2000.
- [2] Tiago A. E. Ferreira, Germano C. Vasconcelos, Paulo J. L. Adeodato. **A New Hybrid Approach for Enhanced Times Series Prediction.** *XXV Congresso da Sociedade Brasileira de Computação*, 831-840, 2005.
- [3] Bruce Vanstone, Clarence Tan. **Applications of Artificial Neural Networks in Investment and Financial Trading.** School of IT, Bond University.
- [4] Neeraj Mohan, Pankaj Jha, Arnab Kumar Laha, Goutam Dutta. **Artificial Neural Network Models for Forecasting Stock Price Index in Bombay Stock Exchange.** Indian Institute of Management, Ahmedabad, India.
- [5] Dr. Alexander Elder. **Come Into My Trading Room: A Complete Guide to Trading.** Wiley, 1st Edition, 2002.
- [6] Ieabeling Kaastra, Milton Boyd. **Designing a neural network for forecasting financial and economic time series.** *Neurocomputing*, 10:215-236, 1996.
- [7] Amaury Lendasse, John Lee, Éric de Bodt, Vincent Wertz and Michel Verleysen. **Dimension reduction of technical indicators for the prediction of financial time series – Application to the BEL20 Market Index.** *European Journal of Economic and Social Systems*, 15:31-48, 2001.
- [8] Z. Tang, P. A. Fishwick. **Feed-forward Neural Nets as Models for Time Series Forecasting.** TR91-008 Computer and Information Sciences, University of Florida.
- [9] CHAN Man-Chung, WONG Chi-Cheong, LAM Chi-Chung. **Financial Time Series Forecasting by Neural Network Using Conjugate Gradient Learning**

Algorithm and Multiple Linear Regression Weight Initialization. Department of Computing, The Hong Kong Polytechnic University.

- [10] Lóránt Bódis. **Financial Time Series Forecasting Using Artificial Neural Networks.** Master Thesis, Department of Computer Science, Babes-Bolyai University, 2004.
- [11] Ashok K. Nag, Amit Mitra. **Forecasting Daily Foreign Exchange Rates Using Genetically Optimized Neural Networks.** Department of Statistical Analysis & Computer Services, Reserve Bank of India, India. *Journal of Forecasting*, 21:501-511, 2002.
- [12] Jason E. Kutsurelis. **Forecasting Financial Markets Using Neural Networks: An Analysis of Methods and Accuracy.** Naval Postgraduate School, Monterey, California, 1998.
- [13] G. Zhang, B. E. Patuwo, M. Y. Hu. **Forecasting with artificial neural networks: The state of the art.** *International Journal of Forecasting*, 14:35-62, 1998.
- [14] Jingtao Yao, Chew Lim Tan. **Guidelines for Financial Forecasting with Neural Networks.**
- [15] Paulo S. G. de M. Neto, Ricardo de A. Araújo, Gustavo G. Petry, Tiago A. E. Ferreira, Germano C. Vasconcelos. **Hybrid Swarm System for Time Series Forecasting.** Center for Informatics (CIn) – Federal University of Pernambuco, Statistics and Computer Science Department – Catholic University of Pernambuco, Recife, Brazil.
- [16] Tong-Seng Quah, Bobby Srinivasan. **Improving Returns on Stock Investment through Neural Network Selection.** Nanyang Technological University, Singapore.
- [17] Roy Schwaerzel. **Improving the Prediction Accuracy of Financial Time Series.** Master Thesis, The University of Texas at San Antonio, 1996.

- [18] A. Lendasse, J. Lee, E. de Bodt, V. Wertz, M. Verleysen. **Input Data Reduction for the Prediction of Financial Time Series.** *ESANN'2001 proceedings - European Symposium on Artificial Neural Networks*, pp. 237-244, Bruges, 2001.
- [19] Myungsook Klassen. **Investigation of Some Technical Indexes in Stock Forecasting.** Computer Science Department, California Lutheran Oaks, California, 2005.
- [20] Dimitri Pissarenko. **Neural Networks for Financial Time Series Prediction: Overview Over Recent Research.** BSc (Hons) Computer Studies, 2001-2002.
- [21] J. Welles Wilder. **New Concepts in Technical Trading Systems.** Trend Research, 1978.
- [22] Kennedy, J. and Eberhart, R. C. **Particle swarm optimization.** *Proceedings of IEEE International Conference on Neural Networks*, Piscataway, NJ. pp. 1942-1948, 1995.
- [23] T. Hellström and K. Holmström. **Predicting the Stock Market.** Technical Report IMA-TOM-1997-07, Center of Mathematical Modeling, Department of Mathematics and Physics, Mälardalen University, Västerås, Sweden, 1998.
- [24] John J. Murphy. **Technical Analysis of The Financial Markets: A Comprehensive Guide to Trading Methods and Applications.** Prentice Hall Press, Subsequent Edition, 1999.
- [25] F.W. Op 't Landt. **Stock Price Prediction using Neural Networks.** Master Thesis, Leiden University, 1997.
- [26] David J. Montana, Lawrence Davis. **Training Feedforward Neural Networks Using Genetic Algorithms.** BBN Systems and Technologies Corp., Cambridge.
- [27] Tiago A. E. Ferreira. **Uma Nova Metodologia Híbrida Inteligente para a Previsão de Séries Temporais.** Tese de Doutorado, Centro de Informática, Universidade Federal de Pernambuco, Recife, 2006.

- [28] Ramon Lawrence. **Using Neural Networks to Forecast Stock Market Prices.**
Department of Computer Science, University of Manitoba, 1997.