

UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

LEONEL ALEJANDRO LABOISSIERE

**ESTIMAÇÃO DO PREÇO DE AÇÕES DE
CONCESSIONÁRIAS DE ENERGIA ELÉTRICA
BRASILEIRAS POR MEIO DE REDES NEURAIAS
ARTIFICIAIS**

São Carlos
2013

LEONEL ALEJANDRO LABOISSIERE

**ESTIMAÇÃO DO PREÇO DE AÇÕES DE
CONCESSIONÁRIAS DE ENERGIA ELÉTRICA
BRASILEIRAS POR MEIO DE REDES NEURAIAS
ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado à
Escola de Engenharia de São Carlos da
Universidade de São Paulo.

Curso de Engenharia Elétrica com Ênfase em
Sistemas de Energia e Automação

ORIENTADOR: Prof. Dr. Ricardo A. S. Fernandes

São Carlos
2013

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

L122e Laboissiere, Leonel
Estimação do preço de ações de concessionárias de energia elétrica brasileiras por meio de redes neurais artificiais / Leonel Laboissiere; orientador Ricardo Fernandes. São Carlos, 2013.

Monografia (Graduação em Engenharia Elétrica com ênfase em Sistemas de Energia e Automação) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2013.

1. estimação de séries temporais. 2. mercado de ações. 3. redes neurais artificiais. I. Título.

FOLHA DE APROVAÇÃO

Nome: Leonel Alejandro Laboissiere

Título: “Estimação de ações de concessionárias de energia elétrica brasileiras por meio de redes artificiais neurais”

Trabalho de Conclusão de Curso defendido e aprovado
em 26/11/2013,

com NOTA 8,5 (oito, cinco), pela Comissão Julgadora:

Prof. Dr. Ricardo Augusto Souza Fernandes - (Orientador - UFSCar)

Dr. Guilherme Guimarães Lage - (Pós-Doutorando - SEL/EESC/USP)

Mestre Marcel Ayres de Araujo - (Doutorando - SEL/EESC/USP)

Coordenador da CoC-Engenharia Elétrica - EESC/USP:
Prof. Associado Homero Schiabel

Resumo

LABOISSIERE, L. A. (2013). *Estimação de Ações de Concessionárias de Energia Elétrica Brasileiras por meio de Redes Neurais Artificiais*. Trabalho de Conclusão de Curso – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2013.

Séries temporais têm sido vastamente estudadas e empregadas como ferramentas para modelagem de sistemas. Entretanto, a previsão de uma série temporal não é uma tarefa trivial e demanda uma análise aprofundada da mesma. Especificamente, no mercado financeiro, a análise e modelagem de séries temporais são tarefas de extremamente úteis visto que a previsibilidade, principalmente, de ações é de fundamental importância para auxiliar as tomadas de decisão que visam a compra e/ou venda destas ações. Conforme esperado num ambiente versátil, como é o caso do mercado de ações, a não linearidade é uma característica marcante. Neste sentido, este trabalho de conclusão de curso tem como objetivo principal a determinação de uma metodologia que apresente bons resultados à previsão de ações de algumas concessionárias de energia elétrica brasileiras, as quais participam da BM&FBovespa. Foram selecionadas 5 concessionárias, a saber: CPFL, COELBA, COSERN, CELESC, CEB. Esta seleção foi realizada de forma aleatória, com o intuito de validar a metodologia proposta.

Palavras Chave: Estimação de séries temporais, mercado de ações, redes neurais artificiais.

Abstract

LABOISSIERE, L. A. (2013). *Stock Forecast for Brazilian Power Utilities Using Artificial Neural Networks*. Major Thesis – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2013.

Time series forecasting have been widely studied and used as modeling tools. However, the prediction a time series is not a trivial task and requires a deeply analysis. Specifically, analysing and modeling of time series in finances is an important task to assist in the decesion-making process. As expected in a dynamic environment such as the stock market, the non-linearity is a pronounced characteristic. Thus, this major thesis aims at determining a methodology results to predict stocks of brazilian electric utilities, which participate in the BM&FBovespa. Finally, it is worth mentioning that five power distribution utilities were selected, namely: CPFL, COELBA, COSERN, CELESC, CEB. This selection was performed randomly, in order to validate the proposed methodology.

Keywords: Time series forecasting, stock exchange, artificial neural networks.

Lista de Figuras

FIGURA 3.1 – COMPARAÇÃO ENTRE NEURÔNIO BIOLÓGICO E NEURÔNIO ARTIFICIAL.....	16
FIGURA 3.2 – FUNÇÃO DE ATIVAÇÃO DO TIPO DEGRAU BIPOLAR.....	18
FIGURA 3.3 – FUNÇÃO DE ATIVAÇÃO DO TIPO DEGRAU.....	18
FIGURA 3.4 – FUNÇÃO DE ATIVAÇÃO DO TIPO LINEAR.....	18
FIGURA 3.5 – FUNÇÃO DE ATIVAÇÃO DO TIPO TANGENTE HIPERBÓLICA.....	19
FIGURA 3.6 – FUNÇÃO DE ATIVAÇÃO DO TIPO LOGÍSTICA (SIGMÓIDE).....	19
FIGURA 3.7 – FUNÇÃO DE ATIVAÇÃO DO TIPO RAMPA.....	20
FIGURA 3.8 – FUNÇÃO DE ATIVAÇÃO DE BASE RADIAL (GAUSSIANA).....	20
FIGURA 4.1 – FLUXOGRAMA DA METODOLOGIA PROPOSTA PARA A PREVISÃO DAS AÇÕES DE CONCESIONÁRIAS DE ENERGIA ELÉTRICA BRASILEIRAS.....	23
FIGURA 4.2 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÁXIMO DA AÇÃO DA CPFL E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	33
FIGURA 4.3 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÍNIMO DA AÇÃO DA CPFL E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	34
FIGURA 4.4 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÁXIMO DA AÇÃO DA COELBA E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	37
FIGURA 4.5 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÍNIMO DA AÇÃO DA COELBA E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	38
FIGURA 4.6 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÁXIMO DA AÇÃO DA COSERN E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	42
FIGURA 4.7 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÍNIMO DA AÇÃO DA COSERN E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	43
FIGURA 4.8 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÁXIMO DA AÇÃO DA CELESC E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	46
FIGURA 4.9 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÍNIMO DA AÇÃO DA CELESC E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	47
FIGURA 4.10 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÁXIMO DA AÇÃO DA CEB E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.....	51

FIGURA 4.11 – COMPARAÇÃO ENTRE O VALOR DESEJADO DO PREÇO MÍNIMO DA AÇÃO DA CEB E OS VALORES ESTIMADOS PELAS RNAs CONSIDERANDO OS DADOS COM E SEM A SELEÇÃO DOS ATRIBUTOS.	52
FIGURA 5.1 – HISTÓRICO DE COTAÇÕES DAS AÇÕES DAS CONCESSIONÁRIAS ANALISADAS NESTE TRABALHO PARA O HORIZONTE DE AGOSTO/2012 A SETEMBRO/2013.....	53

Lista de Tabelas

TABELA 4.1 – ORGANIZAÇÃO DOS DADOS (ATRIBUTOS CONTIDOS NA BASE DE DADOS).	25
TABELA 4.2 – RESULTADOS DA SELEÇÃO DE ATRIBUTOS PARA A CPFL.....	26
TABELA 4.3 – RESULTADOS DA SELEÇÃO DE ATRIBUTOS PARA A COELBA.	26
TABELA 4.4 – RESULTADOS DA SELEÇÃO DE ATRIBUTOS PARA A COSERN.	26
TABELA 4.5 – RESULTADOS DA SELEÇÃO DE ATRIBUTOS PARA A CELESC.	27
TABELA 4.6 – RESULTADOS DA SELEÇÃO DE ATRIBUTOS PARA A CEB.	27
TABELA 4.7 – QUANTIDADE DE NEURÔNIOS PARA RNAs COM 1 CAMADA NEURAL INTERMEDIÁRIA.	28
TABELA 4.8 – QUANTIDADE DE NEURÔNIOS PARA RNAs COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	28
TABELA 4.9 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CPFL: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	30
TABELA 4.10 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CPFL: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	30
TABELA 4.11 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CPFL: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	31
TABELA 4.12 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CPFL: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	31
TABELA 4.13 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CPFL: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÁXIMO.	32
TABELA 4.14 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CPFL: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÍNIMO.	33
TABELA 4.15 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COELBA: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	34
TABELA 4.16 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COELBA: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	35
TABELA 4.17 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COELBA: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	35
TABELA 4.18 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COELBA: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	36
TABELA 4.19 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COELBA: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÁXIMO.	37
TABELA 4.20 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COELBA: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÍNIMO.	38
TABELA 4.21 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COSERN: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	39
TABELA 4.22 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COSERN: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.....	39

TABELA 4.23 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COSERN: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	40
TABELA 4.24 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COSERN: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.....	41
TABELA 4.25 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COSERN: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÁXIMO.	41
TABELA 4.26 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COSERN: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÍNIMO.	42
TABELA 4.27 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CELESC: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	43
TABELA 4.28 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CELESC: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	44
TABELA 4.29 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CELESC: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	44
TABELA 4.30 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CELESC: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	45
TABELA 4.31 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CELESC: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÁXIMO.	46
TABELA 4.32 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CELESC: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÍNIMO.	47
TABELA 4.33 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CEB: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	48
TABELA 4.34 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CEB: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 1 CAMADA NEURAL INTERMEDIÁRIA.	48
TABELA 4.35 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CEB: DADOS SEM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	49
TABELA 4.36 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CEB: DADOS COM SELEÇÃO DE ATRIBUTOS E RNA COM 2 CAMADAS NEURAI INTERMEDIÁRIAS.	50
TABELA 4.37 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CEB: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÁXIMO.	50
TABELA 4.38 – RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CEB: 10 TREINAMENTOS PARA PREVISÃO DO PREÇO MÍNIMO.	51

Sumário

RESUMO	I
ABSTRACT	III
LISTA DE FIGURAS	V
LISTA DE TABELAS	VII
CAPÍTULO 1 INTRODUÇÃO AO TRABALHO DE CONCLUSÃO DE CURSO	1
1.1 MOTIVAÇÃO E JUSTIFICATIVA AO TEMA DO TRABALHO	1
1.2 OBJETIVOS	2
1.3 ORGANIZAÇÃO	3
CAPÍTULO 2 FUNDAMENTOS DE PREVISÃO DE SÉRIES TEMPORAIS	5
2.1 SÉRIES TEMPORAIS	5
2.2 FERRAMENTAS EMPREGADAS À PREVISÃO DE SÉRIES TEMPORAIS	5
2.2.1 MODELOS AUTOREGRESSIVOS E DE MÉDIAS MÓVEIS	6
2.2.2 MODELOS BASEADOS EM REDES NEURAIS ARTIFICIAIS	7
2.3 BOLSA DE VALORES.....	8
2.3.1 BOVESPA.....	9
2.3.2 AÇÕES E ESPECIFICAÇÕES DE OPERAÇÃO	10
2.3.3 ÍNDICES DE AÇÕES	10
CAPÍTULO 3 MINERAÇÃO DE DADOS APLICADA À PREVISÃO DE SÉRIES TEMPORAIS 13	
3.1 FUNDAMENTOS DE MINERAÇÃO DE DADOS	13
3.1.1 SELEÇÃO DE ATRIBUTOS.....	14
3.2 INTRODUÇÃO ÀS REDES NEURAIS ARTIFICIAIS.....	14
3.2.1 ESTRUTURA DO CÉREBRO.....	14
3.2.2 NEURÔNIO ARTIFICIAL	15
3.2.3 FUNÇÕES DE ATIVAÇÃO	17
3.2.4 ARQUITETURAS DE REDES NEURAIS ARTIFICIAIS	20
3.3 REDE NEURAL PROPOSTA PARA PREVISÃO DAS AÇÕES	21
CAPÍTULO 4 PREVISÃO DE AÇÕES DE CONCESSIONÁRIAS DE ENERGIA ELÉTRICA BRASILEIRAS	23
4.1 METODOLOGIA PROPOSTA PARA PREVISÃO DAS AÇÕES	23
4.2 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CPFL.....	29
4.3 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COELBA.....	34
4.4 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COSERN	38
4.5 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CELESC.....	43
4.6 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CEB	47
CAPÍTULO 5 DISCUSSÕES	53

5.1 COMPORTAMENTO DAS AÇÕES DAS CONCESSIONÁRIAS SELECIONADAS DEVIDO À MEDIDA PROVISÓRIA 579 DE 2013.....	53
5.2 RESULTADOS OBTIDOS POR MEIO DAS PREVISÕES	54
CAPÍTULO 6 CONCLUSÕES	55
REFERÊNCIAS BIBLIOGRÁFICAS.....	57

Capítulo 1

Introdução ao Trabalho de Conclusão de Curso

1.1 MOTIVAÇÃO E JUSTIFICATIVA AO TEMA DO TRABALHO

A previsão de séries temporais corresponde a um tema de pesquisa que destina-se a resolver diversos problemas, principalmente, nas áreas de meteorologia, previsão de carga em redes de computadores e análise de mercado. Destaca-se que tais aplicações sempre têm como objetivo a minimização de riscos por meio de ferramentas que auxiliem o planejamento e as tomadas de decisão dos profissionais que encontram-se envolvidos a estes problemas (Amorim, 2008).

Desta forma, pode-se destacar que o objetivo supracitado torna-se óbvio ao se idealizar ferramentas voltadas à análise de mercados. Assim, faz-se necessário garantir uma boa precisão na previsão deste tipo de série temporal. Portanto, o aperfeiçoamento dos modelos de previsão são de extrema importância, conforme comentado em em Coakley e Brown (2000). Neste sentido, pode-se destacar os estudos e publicados em 1978, conforme é comentado em Box, Jenkins e Rensils (2008), que resultaram na criação do modelo ARIMA (Modelo Auto-Regressivo Integrado de Média Móvel), o qual tornou-se um método bastante empregado para previsão.

No entanto, ao considerar a análise do comportamento de processos ou sistemas representados por séries temporais, é comum verificar que os dados apresentam um comportamento não linear. Neste contexto, as Redes Neurais Artificiais (RNA) são consideradas como um conjunto de ferramentas muito úteis para abordar problema de previsão/estimação de séries temporais.

Em Ceretta, Brutti e Schlender (2010) é feita uma comparação entre os modelos ARIMA e de RNAs, onde os autores afirmam que ambas as ferramentas são confiáveis para a previsão de séries temporais relacionadas ao preço da soja num horizonte de tempo pré-definido. Além disso, no trabalho de Zhang (2003), as RNAs e o ARIMA são combinados a fim de utilizar suas características para prever séries temporais referentes a modelagens de problemas financeiros.

A previsão de preços de ativos é uma tarefa bastante estudada para estratégia de negócios. No contexto do agronegócio, Ferreira (2011) emprega RNAs como uma estratégia de precificação de *commodities* agrícolas em mercados de futuros.

Em relação ao mercado de futuros pode ser verificado o trabalho de Hu, Hu et Lin. (2012), onde os autores comparam redes neurais do tipo MLP (*Multilayer Perceptron*), redes recorrentes de Elman e sistemas neuro-fuzzy recorrentes para a previsão de mercados de futuro relacionados ao petróleo. Neste caso, as redes neurais do tipo MLP foram as que apresentaram o pior resultado. Em contrapartida, o sistema neuro-fuzzy foi o mais eficiente.

Conforme relatado em Kaastra e Boyd (1996), apesar de as RNAs se mostrarem como ferramentas a serem empregadas para a previsão de séries temporais financeiras, estas também podem se tornar complexas do ponto de vista de sua parametrização e projeto.

No caso específico de previsão de séries temporais relacionadas ao mercado acionário, é importante prever com maior precisão a tendência do movimento (subida ou descida) da série, visto que tais características podem auxiliar na estratégia de compra e venda das mesmas. De acordo com o trabalho de Amorim (2008), ao se ter uma estimativa suficientemente boa destas tendências, o investidor passa a ter maior segurança na escolha das ações que lhe oferecem melhor relação risco-retorno.

Seguindo as afirmações feitas em Amorim (2008), o trabalho de Kimoto, Asakama, Yoda e Takeoka (1990) ainda complementa as recomendações supracitadas mostrando que também é importante conhecer ou estimar o melhor momento para a compra e/ou venda de ações.

Tendo-se como base os trabalhos previamente apresentados, nota-se que as RNAs são ferramentas que podem ser empregadas à estimativa do preço de ações e, desta forma, estas podem auxiliar as tomadas de decisão do investidor. Entretanto, este trabalho encontra-se focado na estimação do preço ações de concessionárias de energia elétrica brasileiras.

1.2 OBJETIVOS

O presente trabalho visa a obtenção de uma metodologia baseada em Redes Neurais que possibilite uma boa estimação do preço das ações de concessionárias de energia elétrica brasileiras. Ademais, este trabalho também propõe a definição das

variáveis que são mais relevantes ao processo de estimação de cada uma das concessionárias. Desta forma, elencou-se as seguintes variáveis:

- Preço de abertura;
- Preço máximo
- Preço mínimo
- Preço do último negócio;
- Melhor oferta de compra;
- Melhor oferta de venda;
- Índice de Energia Elétrica (IEE);
- Índice da Bovespa (Ibovespa);
- Cotação do dólar americano.

Deste modo, realizou-se uma análise da influência destas variáveis nas ações por meio de correlação.

Por fim, este trabalho ainda busca realizar as estimações para concessionárias de distintas regiões. Ademais, as concessionárias selecionadas apresentam distintas participações no mercado acionário. Por este motivo, foram selecionadas as seguintes concessionárias: CPFL, COELBA, COSERN, CELESC, CEB.

Cabe destacar que foram selecionadas somente concessionárias de distribuição de energia elétrica.

1.3 ORGANIZAÇÃO

O trabalho de conclusão de curso está organizado da seguinte forma.

No Capítulo 2 são tratados os conceitos e fundamentos referentes às séries temporais, incluindo modelos de previsão. Além disso, é dada uma descrição básica do mercado acionário da bolsa de valores.

No Capítulo 3 os conceitos fundamentais das técnicas para seleção de atributos e das RNAs são apresentados.

O Capítulo 4 é destinado a mostrar os aspectos da metodologia proposta para a devida previsão das ações das concessionárias de energia elétrica brasileiras.

No Capítulo 5, discute-se a metodologia empregada e os resultados para a previsão das ações analisadas neste trabalho.

Por fim, no Capítulo 6 são dadas as conclusões gerais e os possíveis trabalhos que podem ser desenvolvidos no futuro.

Capítulo 2

Fundamentos de Previsão de Séries Temporais

Neste capítulo serão apresentados os fundamentos da previsão de séries temporais, bem como do mercado de ações. Neste sentido, Box, Jenkins e Rensils (2008) definem previsão como uma expressão relativa a resultados desconhecidos em um futuro determinado.

A previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma conseqüente tomada de decisão, a qual visa atingir determinados objetivos. Desta forma, Box, Jenkins e Rensils (2008) afirmam que a análise de séries temporais foca na obtenção de relações de dependência entre as observações adjacentes (dados históricos) da série temporal.

2.1 SÉRIES TEMPORAIS

Uma série temporal, também denominada série histórica, representa uma sequência de dados obtidos em intervalos regulares de tempo durante um período específico. Este conjunto de dados pode ser obtido por meio de observações periódicas do evento de interesse (Latorre e Cardoso, 2001).

Conforme pode ser observado em Box, Jenkins e Rensils (2008), séries temporais abrangem vários campos do conhecimento, como: economia, medicina, engenharia, ciências naturais (especialmente geofísica e meteorologia). Ademais, em Amorim (2008) são apresentados alguns exemplos com os seguintes dados: preços diários de ações, taxa mensal de desemprego, produção industrial, número semanal de casos de uma determinada doença, precipitação pluviométrica, temperatura diária e velocidade do vento.

2.2 FERRAMENTAS EMPREGADAS À PREVISÃO DE SÉRIES TEMPORAIS

A análise de séries temporais consiste em determinar estruturas e padrões existentes em dados históricos e, a partir dessa análise, elaborar um modelo que preveja o comportamento futuro da série. Esses modelos de previsão objetivam a determinação de valores futuros e tendências das séries, os quais podem ser adequadamente modelados por ferramentas de regressão.

Atualmente, existem diversos modelos estatísticos que podem ser aplicados à previsão de séries temporais. Dentre estes modelos, pode-se destacar as abordagens baseadas em métodos Autoregressivos e de Médias Móveis (AR, MA e ARMA), bem como o modelo Autoregressivo Integrado de Médias Móveis (ARIMA). Estes modelos são explanados em maiores detalhes nas subseções que seguem.

2.2.1 MODELOS AUTOREGRESSIVOS E DE MÉDIAS MÓVEIS

É importante destacar que os modelos tratados nesta subseção são comumente empregados para a representar séries temporais estacionárias. Assim, cabe destacar que Gujarati (2006) define uma série temporal estacionária como um conjunto de dados que apresenta média e variância constantes ao longo do tempo. Na prática, diz-se que uma série temporal é estacionária quando as observações ocorrem aleatoriamente em torno de uma média constante, ou seja, não há tendência (baixo desvio).

Dentre os modelos utilizados para a previsão de séries temporais estacionárias, o modelo Autoregressivo (AR) destaca-se por ser extremamente útil para tratar modelos estocásticos. O modelo AR pode ser representado por meio da Equação 2.1:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t \quad (2.1)$$

onde:

- X_t corresponde à observação da série temporal no tempo t ,
- ϕ_p corresponde ao parâmetro real do modelo da série temporal no tempo $t-p$; e
- e_t representa o erro de eventos aleatórios que não podem ser tratados pelo modelo, sendo que $E(e_t) = 0$ e $\text{Var}(e_t) = \sigma^2$.

Já o modelo de Média Móvel (MA) considera um processo linear $\{X_t, t \in Z\}$ e pode ser representado pela Equação 2.2:

$$X_t = -\theta_1 X_{t-1} - \theta_2 X_{t-2} - \dots - \theta_p X_{t-p} + e_t \quad (2.2)$$

onde:

- X_t corresponde à observação da série temporal no tempo t ,
- θ_q corresponde ao parâmetro real do modelo MA no tempo $t-p$; e
- e_t representa o erro de eventos aleatórios que não podem ser explicados pelo modelo, sendo que $E(e_t) = 0$ e $\text{Var}(e_t) = \sigma^2$.

Além dos modelos supracitados, existem os modelos mistos, ou seja, aqueles que fazem uso tanto da autoregressão como da média móvel. Desta forma, foi criado o modelo Autoregressivo de Média Móvel (ARMA), o qual é representado pela Equação 2.3.

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t - \theta_1 X_{t-1} - \theta_2 X_{t-2} - \dots - \theta_q X_{t-q} \quad (2.3)$$

Cabe comentar que os parâmetros deste modelos são os mesmos apresentados para as Equações 2.1 e 2.2. Desta forma, torna-se possível observar que os modelos ARMA relacionam osbervações passadas com valores futuros, assim como os erros de estimações passadas.

Ressalta-se ainda que os modelos AR, MA e ARMA, são apropriados para descrever séries temporais estacionárias, isto é, séries que se desenvolvem no tempo ao redor de uma média constante.

Entretanto, nem todas as séries podem ser consideradas estacionárias, como é o caso de séries temporais encontradas na indústria, nos negócios e na economia (Box, Jenkins e Rensils, 2008). Com base nesta premissa, surgiu o modelo Autoregressivo Integrado de Média Móvel (ARIMA), o qual também é conhecido por modelo de Box-Jenkins.

O modelo ARIMA pode ser considerado como uma generalização do modelo ARMA, onde a principal consideração é feita ao se definir que o polinômio do modelo AR possui raiz unitária. Por meio desta consideração, foi observado que o modelo ARIMA poderia modelar de forma bastante razoável algumas séries temporais não estacionárias. Com o intuito de melhor representar o modelo ARIMA, o mesmo é descrito pela Equação 2.4.

$$W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \dots + \phi_p W_{t-p} + e_t - \theta_1 X_{t-1} - \theta_2 X_{t-2} - \dots - \theta_q X_{t-q} \quad (2.4)$$

2.2.2 MODELOS BASEADOS EM REDES NEURAIIS ARTIFICIAIS

Em Coakley e Brown (2000), os autores comentam que as Redes Neurais Artificiais são ferramentas que apresentam bons resultados quando aplicadas à modelagem estatística, pois, conforme será mostrado no Capítulo 3 deste trabalho, as RNAs apresentam habilidades de mapeamento de padrões, clusterização, identificação, aproximação funcional, predição e estimação. Assim, nota-se que as RNAs podem ser devidamente empregadas à predição/estimação de séries temporais, sejam estas estacionárias ou não.

Gately (1995), apresenta diversas aplicações de Redes Neurais na área de finanças. Algumas destas aplicações são mostradas na sequência:

- Predição do mercado acionário;
- Seleção de carteiras;
- Predição de valor de moedas;
- Seleção de fundos de investimentos;
- Mercado de opções;
- Predição de tendências em negociações;
- Predição de fluxo de caixa.

Devido às Redes Neurais Artificiais serem um dos enfoques deste trabalho, uma explanação mais detalhada sobre tal ferramenta será fornecida no Capítulo 3.

2.3 BOLSA DE VALORES

A bolsa de valores pode ser vista como uma instituição com ou sem fins lucrativos na qual se negociam títulos, ações e opções de acordo com um determinado índice. Estas negociações podem ser feitas a vista ou com prazo definido de vencimento. Ressalta-se que os negócios de compra e venda devem ser feitos em pregões, que atualmente costumam ser eletrônicos.

Visto que o mercado de capitais é um sistema de distribuição de valores mobiliários que visa proporcionar liquidez aos títulos de emissão de empresas e viabilizar seu processo de capitalização, os principais títulos negociados são os que representam o capital de empresas (as ações) ou empréstimos tomados, via mercado, pelas empresas. Portanto, o mercado de capitais permite a circulação de capital para custear o desenvolvimento econômico. Assim sendo, a Bolsa de Valores é um grande alicerce para o desenvolvimento econômico de um país, já que pode servir como fonte de renda de finanças pessoais, empresas e governos.

É importante destacar que o mercado acionário funciona também como reflexo do que ocorre no meio empresarial, além de servir como uma variável macroeconômica de um país.

Conforme Amorim (2008), outro aspecto importante da bolsa de valores é que esta permite o intercâmbio entre os países, o qual está realcionado à troca de moedas, aos investimentos no exterior e aos investimentos em *commodities*. Desta forma, as empresas podem operar por meio da bolsa de valores as transações de suas mercadorias com a

finalidade de buscar mecanismos que a protejam contra a oscilação dos preços de seus produtos.

2.3.1 BOVESPA

A Bovespa é o segmento de mercado acionário da BM&FBovespa (Bolsa de Valores, Mercadorias e Futuros de São Paulo), que abriu seu capital em 2008 tornando-se uma empresa com fins lucrativos. Além de disponibilizar um pregão para negociação de títulos (com destaque para ações) totalmente eletrônico (BM&FBovespa, 2013a).

Caso uma empresa deseje buscar recursos de financiamento no mercado acionário proporcionado pela Bovespa, é necessário fazer uma série de procedimentos. Em primeira instância, a empresa precisa obter registro de companhia aberta e da emissão dos valores junto à CVM (Comissão de Valores Mobiliários). Além disso, deve ser criado um conselho de administração e diretoria de relações com o investidor.

Posteriormente, a empresa precisa registrar-se na BM&FBovespa para as ações serem negociadas em sua plataforma de negócios. Ao finalizar esse processo, a empresa realiza sua Oferta Pública Inicial (IPO - do inglês *Inicial Public Offer* (BM&FBovespa, 2013a)). O IPO ocorre no chamado mercado primário que é o momento em que as empresas emitem e ofertam valores mobiliários para captar recursos diretamente de investidores para o financiamento de suas necessidades.

No mercado secundário são negociados pelos investidores os valores mobiliários (previamente adquiridos no mercado primário), ocorrendo apenas a troca de titularidade, isto é, a compra e a venda. Portanto, o objetivo do mercado secundário é o de gerar liquidez aos ativos da empresa (BM&FBovespa, 2013a).

Portanto, no mercado primário as empresas obtêm recursos necessários para investimento em novos equipamentos ou no desenvolvimento de pesquisas, o que melhora seu processo produtivo, tornando-o mais eficiente e beneficiando toda a comunidade.

O investidor de ações pode agir em ambos os momentos (primário e secundário) e beneficiar-se da produção de bens dos quais também é consumidor. No entanto, como este investidor passa a ser um acionista, o mesmo é tido como um dos sócios da empresa e participa diretamente de dividendos dos lucros da empresa.

Observa-se que a Bovespa é uma chave fundamental para o desenvolvimento econômico brasileiro, tanto pela aquisição de recursos para empresas como pelo aumento das finanças pessoais de quem opera no mercado secundário de ações.

Em se tratando de operações no mercado acionário da Bovespa, destaca-se que todo investidor deve estar cadastrado junto a uma corretora, mesmo que este deseje operar pelo *home broker* (serviço que permite que o investidor envie ordens de compra e venda via internet).

2.3.2 AÇÕES E ESPECIFICAÇÕES DE OPERAÇÃO

As ações e especificações de operação são títulos de renda variável emitidos por sociedades anônimas, que representam a menor fração do capital da empresa emissora. Estas ações podem ser escriturais ou representadas por cautelas ou certificados. Nestes casos, o investidor de ações é considerado como um co-proprietário da sociedade anônima da qual é acionista, participando dos seus lucros. Assim, os títulos mobiliários podem ser classificados como:

- Ordinários - proporcionam participação nos resultados da empresa e conferem ao acionista o direito de voto em assembleias gerais;
- Preferenciais - garantem ao acionista a prioridade no recebimento de dividendos (algumas vezes em percentual mais elevado que o atribuído às ações ordinárias) e no reembolso de capital (em caso de dissolução da sociedade).

A rentabilidade é variável ao aplicar no mercado acionário, onde uma parte é composta de dividendos ou participação nos resultados e benefícios concedidos pela empresa, parte advém da posse da ação e outra parte é proveniente do eventual ganho de capital na venda da ação.

2.3.3 ÍNDICES DE AÇÕES

Os índices das ações representam as oscilações de preços de uma ação ou de um conjunto de ações. Estes índices são obtidos com base nos negócios realizados na bolsa de valores. Portanto, cada índice segue uma metodologia de cálculo para representar a variação média de preços no mercado, onde considera-se também a importância de cada ação no volume de negócios.

De forma sumária, pode-se dizer que um índice tem a função de indicar se determinada ação ou conjunto de ações está se valorizando ou desvalorizando ao longo de tempo.

Cabe destacar que no presente trabalho, são analisados dois índices fornecidos pela BM&FBovespa, a saber:

- Ibovespa - é o mais importante indicador de desempenho médio das cotações do mercado de ações brasileiro, pois, retrata o comportamento dos principais papéis negociados na bolsa de valores brasileira (exemplo: Vale, Petrobrás, Embraer, etc);
- IEE (Índice de Energia Elétrica) - é um índice setorial que tem o objetivo de medir o desempenho do setor de energia elétrica brasileiro.

Estes dois índices foram considerados neste trabalho, pois, o Ibovespa fornece uma visão global do mercado acionário brasileiro, enquanto o IEE possibilita a visão global específica do setor energético. Portanto, será analisado o impacto dessas variáveis nas cotações e na previsão das ações das concessionárias de energia elétrica selecionadas.

Capítulo 3

Mineração de Dados Aplicada à Previsão de Séries Temporais

3.1 FUNDAMENTOS DE MINERAÇÃO DE DADOS

A Mineração de Dados surgiu da necessidade de se obter padrões nos dados que estão contidos, principalmente, em bases de dados empresariais. No entanto, tem-se notado que não somente as bases de dados empresariais possuem um grande volume de dados armazenados. Por este motivo, a mineração de dados foi empregada neste trabalho, visto que torna-se complexa a análise de grandes quantidades de dados que representam séries temporais do mercado de ações.

Atualmente, é possível encontrar diversas definições para o termo "Mineração de Dados", onde autores como Han e Kamber (2001) e Oliveira (2004) definem o termo como o processo de descoberta de padrões em bases de dados. Por outro lado, Fayyad et al. (1996) definem o termo como uma das etapas do processo de descoberta de padrões em bases de dados.

Portanto, este trabalho seguirá a definição de Han e Kamber (2001) devido à metodologia proposta empregar um algoritmo para Seleção de Atributos em sua etapa inicial, onde são descobertas as variáveis com maior relevância à obtenção do padrão comportamental das ações. Ademais, será utilizada uma mineração preditiva, onde são utilizados dados que representam situações passadas do processo/sistema. Assim, por meio destes dados, pretende-se estimar situações atuais e/ou futuras do processo/sistema.

Entretanto, o primeiro passo da metodologia proposta é destinado à descoberta das variáveis mais relevantes para que seja garantida uma melhor estimação/previsão do mercado de ações das concessionárias de energia elétrica brasileiras. Assim, esta primeira etapa é composta por algoritmos destinados à seleção de atributos (Subseção 3.1.1). Por fim, tem-se a etapa de previsão, a qual é realizada por meio de Redes Neurais Artificiais (Seção 3.2).

3.1.1 SELEÇÃO DE ATRIBUTOS

Atributos são colunas de uma base de dados que representam as diferentes características das diversas instâncias contidas nesta base. Em conformidade com este conceito de “atributo”, Liu e Motoda (1998) definem o processo de seleção de atributos como a determinação de um subconjunto de atributos ótimo que será responsável por generalizar a informação contida na base de dados, conforme a resposta que espera-se obter da mesma.

Os algoritmos para seleção de atributos têm sido empregados para casos onde os métodos de classificação, estimação, previsão não conseguem obter a generalização de padrões ou quando estes algoritmos são inviáveis devido à grande quantidade de atributos.

É importante comentar que neste trabalho empregou-se um método baseado em correlação (CFS - Correlation-Based Feature Selection) proposto por Hall (1999). Conforme mostrado por Hall (2000), este método pode ser aplicado tanto em conjuntos de dados contínuos quanto discretos. O CFS emprega correlação para avaliar o custo de atributos individuais e subconjuntos de atributos.

No CFS, a busca pelo melhor subconjunto de atributos somente é finalizada quando o critério de parada é satisfeito, sendo que este critério é obtido quando as últimas cinco iterações retornam o mesmo subconjunto de atributos.

3.2 INTRODUÇÃO ÀS REDES NEURAIS ARTIFICIAIS

Neste tópico a estrutura geral do cérebro é apresentada, assim como a de Redes Neurais Artificiais. Ambas as estruturas são comparadas, já que, conforme Haykin (1999), a RNA é uma técnica de Inteligência Artificial (IA) que objetiva simular por meio de modelos matemático-computacionais o funcionamento do cérebro humano de uma maneira simplificada.

3.2.1 ESTRUTURA DO CÉREBRO

O cérebro dos seres vivos são compostos por células denominadas neurônios. Essas células são especializadas para o processamento de informação. Segundo Gatley (1995), estima-se que o número de neurônios no cérebro humano seja da ordem de 100 bilhões. Além disso, os neurônios biológicos operam em paralelo e têm como objetivo a produção de ações apropriadas para o desenvolvimento de determinado ser vivo, tais como o pensamento e a memorização (Silva, Spatti e Flauzino, 2010).

O cérebro humano é dividido em partes semi-iguais, onde cada "metade" possui diferentes e complementares funções na atividade humana. Assim, ao lado esquerdo são atribuídas as funções lógicas e matemáticas, enquanto o lado direito é responsável pelas emoções, reconhecimento de padrões e sentidos intuitivos (Gately, 1995). Ao longo do texto, o leitor poderá observar que as RNAs agem, na maioria dos casos, como o lado direito do cérebro humano, já que buscam relações entre entradas e saídas para reconhecer padrões e para estimar/prever comportamentos de processos ou sistemas.

Cabe comentar que cada neurônio biológico pode ser dividido em três partes principais: dendritos, núcleo e axônio. O corpo do neurônio mede alguns milésimos de milímetros e os dendritos apresentam poucos milímetros de comprimento, no entanto, o axônio pode ser mais longo.

Os dendritos consistem de vários prolongamentos finos que formam a árvore dendrital. Ademais, os dendritos agem como sensores, pois, recebem os impulsos eletroquímicos (estímulos) provenientes de outros neurônios ou do próprio meio externo. De acordo com Gately (1995), a área que recebe os impulsos enviados pelos axônios é denominada de sinapse. Portanto, as sinapses são realizadas nas ramificações/terminações sinápticas que encontram-se no final do axônio.

Já o corpo celular ou soma processa todas as informações provenientes dos dendritos com o objetivo de criar um potencial de ativação que irá definir se o neurônio encaminhará ou não um impulso ao longo de seu axônio (Silva, Spatti e Flauzino, 2010).

Desta forma, pode-se dizer que as RNAs são semelhantes ao cérebro em duas características:

- conhecimento é adquirido por um processo de aprendizado; e
- conexões entre seus neurônios são utilizadas para armazenar o conhecimento adquirido.

3.2.2 NEURÔNIO ARTIFICIAL

As RNAs são modelos simplificados da arquitetura cerebral, haja visto que estas possuem algumas centenas de neurônios, enquanto o cérebro apresenta em torno de 100 bilhões de neurônios. Outra diferença está no fato de o cérebro utilizar os 5 sentidos como entrada e as RNAs necessitarem, obrigatoriamente, de dados numéricos.

Por meio da Figura 3.1, uma comparação entre o neurônio biológico e o neurônio artificial pode ser visualizada. Nota-se por meio desta figura que o neurônio artificial pode

ser dividido nos seguintes elementos básicos: entradas, combinador linear (soma) e função de ativação $g(\cdot)$. Na sequência, cada um destes elementos são explanados em maiores detalhes:

1. Sinais de entrada $\{x_1, x_2, x_3, \dots, x_n\}$ - cada um ponderado pelo seu peso sináptico $\{w_1, w_2, w_3, \dots, w_n\}$, os quais são provenientes do meio externo e representam os valores assumidos pelas variáveis de uma aplicação específica. O conjunto de entradas é usualmente normalizado visando incrementar a eficiência computacional da RNA (Silva, Spatti e Flauzino, 2010);
2. Combinador linear (representado pelo somatório da Figura 3.1) - realiza a soma da multiplicação dos sinais de entrada pelos seus respectivos pesos sinápticos a fim de gerar um valor de potencial de ativação (Ferreira, 2011);
3. Função de ativação $g(\cdot)$ - objetiva gerar uma saída que esteja dentro de um intervalo de valores válidos. As funções de ativação serão apresentadas na subseção 3.1.3.




Figura 3.1 – Comparação entre neurônio biológico e neurônio artificial.

Fonte: (Fernandes, 2009).

Por meio dos três elementos básicos supracitados, a saída de um neurônio artificial pode ser expressa conforme a Equação 3.1:

$$y = g\left(\sum_{i=1}^n w_i x_i - \theta\right) \quad (3.1)$$

onde:

n representa o número de entradas do neurônio;

w_i é o peso sináptico associado à i -ésima entrada;

θ é o limiar de ativação do neurônio;

x_i é a i -ésima entrada do neurônio;

$g(\cdot)$ é a função de ativação do neurônio;

y é a saída do neurônio.

3.2.3 FUNÇÕES DE ATIVAÇÃO

Conforme previamente citado, a função de ativação fornece um valor de saída limitado. Segundo Silva, Spatti e Flauzino (2010), as funções de ativação são divididas em dois grupos: parcialmente diferenciáveis e as totalmente diferenciáveis.

Dentre as funções de ativação parcialmente diferenciáveis, destacam-se: degrau, degrau bipolar e rampa simétrica. Já as funções de ativação totalmente diferenciáveis que se destacam em redes neurais artificiais são: logística, tangente hiperbólica, gaussiana e linear.

Algumas das funções de ativação mais utilizadas têm seus cálculos e formatos gráficos mostrados nas Figuras de 3.2 a 3.8:

- Degrau bipolar

$$y(n) = \begin{cases} y = 1, & \text{se } n > 0 \\ y = 0, & \text{se } n = 0 \\ y = -1, & \text{se } n < 0 \end{cases} \quad (3.2)$$




Figura 3.2 – Função de ativação do tipo degrau bipolar.

Fonte: (Fernandes, 2009).

- Degrau

$$y(n) = \begin{cases} y = 1, & \text{se } n \geq 0 \\ y = 0, & \text{se } n < 0 \end{cases} \quad (3.3)$$




Figura 3.3 – Função de ativação do tipo degrau.

Fonte: (Fernandes, 2009).

- Linear

$$y(n) = n \quad (3.4)$$




Figura 3.4 – Função de ativação do tipo linear.

Fonte: (Fernandes, 2009).

- Tangente hiperbólica

$$y(n) = \frac{1 - e^{-\beta n}}{1 + e^{\beta n}} \quad (3.5)$$




Figura 3.5 – Função de ativação do tipo tangente hiperbólica.

Fonte: (Fernandes, 2009).

onde β é o parâmetro de excentricidade.

- Logística (sigmóide)

$$y(n) = \frac{1}{1 + e^{-\beta n}} \quad (3.6)$$




Figura 3.6 – Função de ativação do tipo logística (sigmóide).

Fonte: (Fernandes, 2009).

onde β é o parâmetro de excentricidade.

- Rampa

$$y(n) \begin{cases} y = 1, & \text{se } n > 1 \\ y = n, & \text{se } -1 \leq n \leq 1 \\ y = -1, & \text{se } n < 0 \end{cases} \quad (3.7)$$




Figura 3.7 – Função de ativação do tipo rampa.

Fonte: (Fernandes, 2009).

- Base radial (gaussiana)

$$y(n) = e^{-\left(\frac{(\sigma n)^2}{2\sigma^2}\right)} \quad (3.8)$$




Figura 3.8 – Função de ativação de base radial (gaussiana).

Fonte: (Fernandes, 2009).

3.2.4 ARQUITETURAS DE REDES NEURAIS ARTIFICIAIS

A arquitetura de uma RNA é determinada pela forma como os neurônios artificiais são organizados e agrupados (Maciel, Ballini e Silveira, 2009). Basicamente, o que define a arquitetura de uma RNA é o número de camadas neurais, tipo de conexão entre os neurônios e o algoritmo de aprendizado aplicado ao seu treinamento.

Quanto ao número de camadas, pode-se categorizá-las em:

- Camada única;
- Múltiplas camadas.

Quanto aos tipos de conexão entre os neurônios, estes podem ser:

- Totalmente conectados;
- Parcialmente conectados.

Quanto à topologia da rede, estas podem ser principalmente divididas em:

- *Feedforward*;
- *Feedback*.

Neste trabalho, serão utilizadas as redes neurais de múltiplas camadas, com neurônios totalmente conectados e topologia do tipo *Feedforward*.

Outro traço marcante no projeto de redes neurais é o algoritmo de treinamento empregado. Os algoritmos de treinamento consistem em um método que irá, de forma iterativa, adaptar os pesos sinápticos para que estes melhor representem o comportamento do sistema. Assim, diz-se que os algoritmos de treinamento visam ajustar os pesos sinápticos de tal maneira que se obtenha soluções generalistas e representativas do sistema sob estudo.

3.3 REDE NEURAL PROPOSTA PARA PREVISÃO DAS AÇÕES

As redes neurais do tipo Perceptron e Adaline não podem ser empregadas para a resolução de problemas relacionados à aproximação funcional, separação de mais do que duas classes de dados e estimação/previsão de processos ou sistemas. Deste modo, neste trabalho, são utilizadas redes neurais de múltiplas camadas do tipo MLP (do inglês, *Multilayer Perceptron*).

Destaca-se que para o treinamento de uma rede MLP é usado o método de treinamento supervisionado, ou seja, são apresentadas à rede a saída desejada correspondente a um conjunto de dados de entrada. Assim, é possível notar que o principal algoritmo de treinamento para redes do tipo MLP é o *backpropagation*. Conforme Araújo e Lotufo (2009), esse método apresenta um elevado esforço computacional, pois, considera as derivadas de primeira ordem nos ajustes dos valores das matrizes de pesos. Em contrapartida, o algoritmo de treinamento de Levenberg-Marquardt emprega derivadas de segunda ordem, assim, o tempo de convergência do mesmo pode ser reduzido e, por consequência, há a redução do esforço computacional (Silva, Spatti e Flauzino, 2010).

Além do algoritmo de treinamento, é importante que os dados sejam separados em dois conjuntos. Assim, um dos conjuntos destina-se apenas ao treinamento da RNA (em

torno de 60% a 90% das amostras do conjunto de dados original) e o outro conjunto é empregado à validação/teste da RNA (composto por 10% a 40% do conjunto de dados original). Esta divisão do conjunto de dados original faz-se necessária para que possa ser verificada a generalização da RNA (Silva, Spatti e Flauzino, 2010).

É importante destacar que neste trabalho foi empregado o algoritmo de treinamento de Levenberg-Marquardt.

Capítulo 4

Previsão de Ações de Concessionárias de Energia Elétrica Brasileiras

4.1 METODOLOGIA PROPOSTA PARA PREVISÃO DAS AÇÕES

Na Figura 4.1 é apresentado um fluxograma que resume a metodologia aplicada neste trabalho. Por meio do fluxograma é possível observar os passos que se iniciam na coleta de dados e são finalizados na obtenção dos resultados da previsão do preço das ações pelas RNAs.

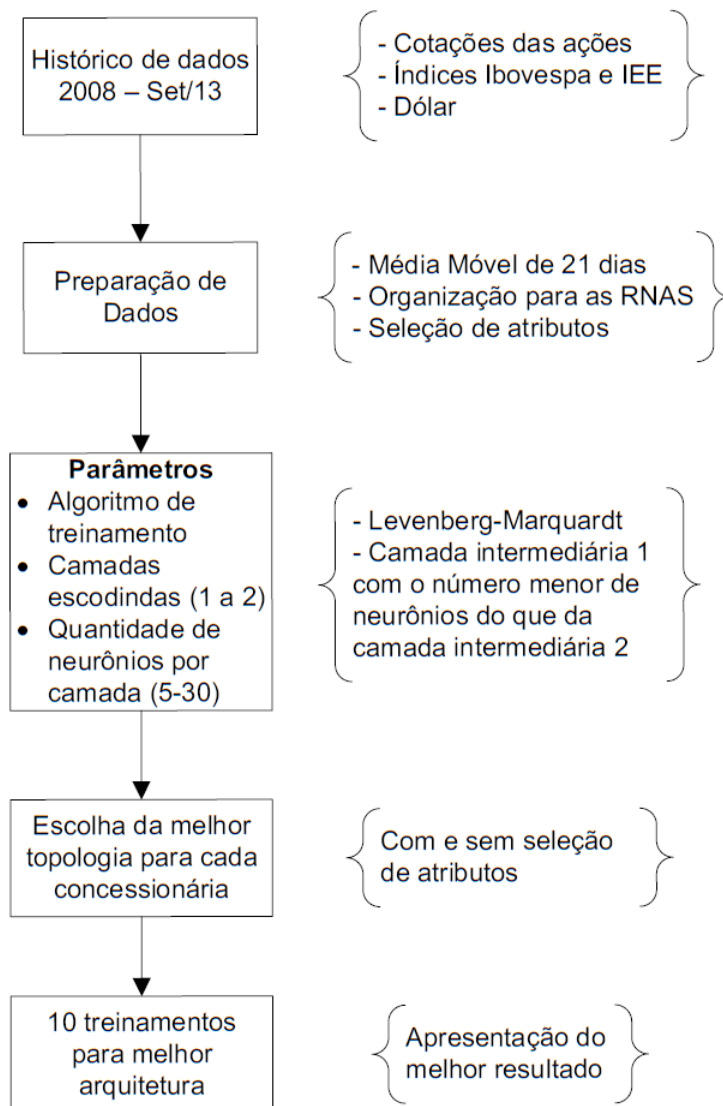


Figura 4.1 – Fluxograma da metodologia proposta para a previsão do preço das ações de concessionárias de energia elétrica brasileiras.

O bloco "Histórico de dados" pode ser interpretado da seguinte forma:

- Obtenção dos valores históricos das ações das concessionárias de energia elétrica brasileiras no site da BM&FBovespa (BM&FBovespa, 2013b);
- Obtenção de histórico de índices de ações no site da Revista Exame, onde foram utilizados os índices Ibovespa e IEE (Revista Exame, 2013);
- Obtenção dos valores históricos de cotação do dólar americano no site do Banco Central do Brasil (Banco Central do Brasil, 2013).

É importante destacar que para todos os dados obtidos foi considerado um horizonte que se inicia em Janeiro de 2008 e tem término em Setembro de 2013.

Na sequência, os dados foram pré-processados, onde foram feitos cálculos de Média Móvel de 21 dias e organização dos dados para que fossem devidamente submetidos ao Seletor de Atributos.

O objetivo deste cálculo é filtrar eventuais flutuações demasiadas e mostrar mais explicitamente a tendência do mercado de ações. Neste trabalho, foi usada a média móvel ponderada para n termos, cuja notação matemática é expressa pela Equação 4.1:

$$M_{Móvel}(n) = \frac{2}{n(n+1)} \sum_{i=1}^n P[t - (n-i)](i) \quad (4.1)$$

Destaca-se que foi usado $n = 21$ devido ao número de dias da média móvel. Este número corresponde à quantidade média de dias úteis que compreendem um mês. Assim, o objetivo desta média móvel é a de fornecer um avaliação da série temporal em médio prazo. Cabe ainda comentar que as médias móveis foram calculadas para os índices (Ibovespa e IEE), cotação do dólar americano e para as ações (valores máximos e mínimos dos preços, preço de abertura, preço do último negócio, melhor oferta de compra e melhor oferta de venda).

Após esta etapa de pré-processamento, os dados foram devidamente organizados e separados em dois conjuntos de amostras (treinamento e validação). A organização destes dados pode ser observada por meio da Tabela 4.1.

Deve-se entender da Tabela 4.1 que D representa o dia para o qual deseja-se estimar os valores dos preços máximos e mínimos, ou seja, a saída desejada da rede neural. Para a metodologia proposta foi considerado apenas o preço de abertura de D como possível entrada do método de predição (RNA).

Tabela 4.1 – Organização dos dados (atributos contidos na base de dados).

D	Preço de abertura
$D - i$	Preço de abertura
	Preço máximo
	Preço de mínimo
	Preço do último negócio
	Melhor oferta de compra
	Melhor oferta de venda
Média Móvel de 21 dias	Preço de abertura
	Preço de máximo
	Preço de mínimo
	Preço do último negócio
	Melhor oferta de compra
	Melhor oferta de venda
	IEE
	Ibovespa
	Dólar
Saída desejada para D	Preço máximo
	Preço mínimo

Nota-se, por meio da Tabela 4.1, que existem os atributos dos $D - i$ dias, onde $i = 1, \dots, 5$, ou seja, cinco dias anteriores ao dia atual (D).

Deste modo, tem-se um total de 40 variáveis de entrada (atributos) e 2 variáveis de saída (Preço máximo e Preço mínimo do dia D). Recorda-se que o histórico de dados considerado é de Janeiro de 2008 até Setembro de 2013 e que esta base de dados foi dividida em 25% de dados mais recentes para o conjunto de validação e os 75% dos dados restantes foram destinados ao conjunto de treinamento.

Tendo em mãos todas as variáveis (atributos) supracitadas, o algoritmo de Seleção de Atributos foi aplicado ao conjunto de dados de treinamento de cada uma das concessionárias de energia elétrica.

Os resultados das seleções de atributos para cada um dos conjuntos de treinamento podem ser visualizados na sequência por meio das Tabelas 4.2 a 4.6.

Na Tabela 4.2, são apresentados os resultados da seleção de atributos para a CPFL. Para ambos os preços, máximo e mínimo, a entrada Preço de abertura do dia D foi selecionada. Para a previsão do preço mínimo há uma variável a mais, a Média Móvel de 21 dias do Ibovespa.

Tabela 4.2 – Resultados da seleção de atributos para a CPFL.

Atributos Selecionados	
Preço Máximo	Preço Mínimo
Preço de abertura do dia D	Preço de abertura do dia D
-	Média Móvel do Ibovespa

Na Tabela 4.3, são apresentados os resultados da seleção de atributos para a COELBA. Para ambos os preços, máximo e mínimo, as entradas Preço de abertura do dia D e o índice IEE foram selecionados. Para a previsão do Preço Máximo existem mais variáveis influentes na formação do preço, a Média Móvel de 21 dias do IEE, o que pode indicar influência da COELBA nesse índice, além do preço do último negócio do dia $D-1$ e as melhores ofertas de compra e venda do dia $D-1$.

Tabela 4.3 – Resultados da seleção de atributos para a COELBA.

Atributos Selecionados	
Preço Máximo	Preço Mínimo
Preço de abertura do dia D	Preço de abertura do dia D
Preço do último negócio do dia $D-1$	IEE
Melhor oferta de compra do dia $D-5$	-
Melhor oferta de venda do dia $D-5$	-
IEE	-

Tabela 4.4 – Resultados da seleção de atributos para a COSERN.

Atributos Selecionados	
Preço Máximo	Preço Mínimo
Preço de abertura do dia D	Preço de abertura do dia D
Preço de abertura do dia $D-1$	Preço de abertura do dia $D-1$
Preço máximo do dia $D-1$	Preço mínimo do dia $D-1$
Preço do último negócio do dia $D-1$	Preço do último negócio do dia $D-1$
Melhor oferta de venda do dia $D-4$	Preço de abertura do dia $D-2$
Preço do último negócio do dia $D-5$	-
Média móvel do dólar	-

Na Tabela 4.4, são apresentados os resultados da seleção de atributos para a COSERN. Para ambos os preços, máximo e mínimo, as entradas Preço de abertura do dia D , o Preço de abertura do dia $D-1$ e o Preço do último negócio do dia $D-1$ foram

selecionadas. O preço máximo também é influenciado pelo Preço máximo do dia D-1, melhor oferta de venda do dia D-4, preço do último negócio do dia D-5 e a Média móvel de 21 dias do dólar. Já os preços mínimo e de abertura do dia D-1 são os outros fatores que influem na previsão do Preço mínimo do dia D.

Tabela 4.5 – Resultados da seleção de atributos para a CELESC.

Atributos Selecionados	
Preço Máximo	Preço Mínimo
Preço de abertura do dia D	Preço de abertura do dia D
Preço máximo do dia $D - 1$	Preço mínimo do dia $D - 1$
-	Média móvel do dólar

Na Tabela 4.5, são apresentados os resultados da seleção de atributos para a CELESC. Para ambos os preços, máximo e mínimo, a entrada Preço de abertura do dia D foi selecionada. O preço máximo também é influenciado pelo Preço máximo do dia D-1. enquanto o preços mínimo dia D-1 e a Média móvel de 21 dia do dolar são os outros fatores que influem na previsão do Preço mínimo do dia D.

Tabela 4.6 – Resultados da seleção de atributos para a CEB.

Atributos Selecionados	
Preço Máximo	Preço Mínimo
Preço de abertura do dia D	Preço de abertura do dia D
Preço do último negócio do dia $D - 1$	Preço do último negócio do dia $D - 1$
Média móvel do dólar	IEE

Na Tabela 4.6, são apresentados os resultados da seleção de atributos para a CEB. Para ambos os preços, máximo e mínimo, as entradas Preço de abertura do dia D e o Preço do último negócio foram selecionadas. O preço máximo também é influenciado pela Média móvel de 21 dias do dólar. Já o índice setorial IEE é o outro fator que influe na previsão do Preço mínimo do dia D.

A partir dos atributos selecionados, as RNAs foram configuradas da seguinte forma:

- Algoritmo de treinamento: Levenberg-Marquardt;
- Erro quadrático médio: 10^{-12} ;
- Número máximo de épocas: 250
- Número de camadas: topologias com 1 e 2 camadas neurais intermediárias;
- Número de neurônios por camada: de acordo com as Tabelas 4.7 e 4.8;

Tabela 4.7 – Quantidade de neurônios para RNAs com 1 camada neural intermediária.

Nº de neurônios
5
10
15
20
25
30

No caso de topologias com 2 camadas neurais intermediárias, foi feita uma combinação entre o número de neurônios da primeira e da segunda camada. Esta combinação foi realizada de acordo com a Tabela 4.8.

Tabela 4.8 – Quantidade de neurônios para RNAs com 2 camadas neurais intermediárias.

Número de neurônios da 1ª camada	Número de neurônios da 2ª camada
5	10
	15
	20
	25
	30
10	15
	20
	25
	30
15	20
	25
	30
20	25
	30
25	30

Ressalta-se que as funções de ativação dos neurônios das camadas neurais intermediárias são do tipo tangente hiperbólica e as funções de ativação dos neurônios da camada de saída são do tipo linear.

Realizados todos os treinamentos propostos, foram obtidas 21 topologias de RNAs (com 1 e 2 camadas neurais intermediárias) para cada concessionária. Entretanto, as topologias foram treinadas considerando-se a entrada dos dados originais e a entrada dos

dados após a seleção dos atributos, ou seja, ao final de todos os treinamentos obteve-se um total de 42 resultados de previsão para cada concessionária.

Por consequência, houve a necessidade de se estabelecer critérios que pudessem julgar o desempenho das RNAs. Assim, foram realizados cálculos de Erro Absoluto Médio (MAE - *Mean Absolute Error*), Erro Absoluto Percentual Médio (MAPE - *Mean Absolute Percentual Error*) e Erro Médio Quadrático (MSE - *Mean Square Error*) conforme respectivamente apresentados por meio das Equações 4.2 a 4.4:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |P_i - \hat{P}_i| \quad (4.2)$$

$$\text{MAPE} = \frac{100}{N} \sum_{i=1}^N \frac{|P_i - \hat{P}_i|}{P_i} \quad (4.3)$$

$$\text{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - \hat{P}_i)^2} \quad (4.4)$$

onde,

P_i representa o preço desejado;

\hat{P}_i representa o preço estimado pela RNA;

N é o número de amostras usadas para validação da RNA.

Após selecionadas as RNAs que apresentaram o melhor desempenho para a previsão das ações de cada uma das concessionárias, as mesmas voltam a ser treinadas mais 10 vezes a fim de se verificar a capacidade de repetibilidade dos resultados, onde espera-se que estes resultados apresentem baixo desvio da média dos 10 resultados.

4.2 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CPFL

As Tabelas 4.9 e 4.10 mostram os resultados obtidos para a validação das RNAs treinadas para prever ações da CPFL, onde os resultados da Tabela 4.9 foram obtidos utilizando a base de dados sem seleção de atributos e RNAs com apenas uma camada neural intermediária e os resultados da Tabela 4.10 foram obtidos considerando-se a seleção de atributos e mantendo-se a RNA com apenas uma camada neural intermediária.

Tabela 4.9 – Resultados obtidos para previsão de ações da CPFL: dados sem seleção de atributos e RNA com 1 camada neural intermediária.

Sem Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,00104	0,891608	3,1E-05	0,01725	3,831398	0,00039
10	0,00379	3,324088	0,00033	0,02407	5,292933	0,00073
15	0,00299	2,522141	0,00023	0,01004	2,239001	0,00016
20	0,01677	14,61382	0,00502	0,01567	3,351605	0,00038
25	0,01004	8,784896	0,00193	0,01941	4,340338	0,0007
30	0,01105	9,892002	0,0031	0,03057	6,650788	0,00162

Por meio das Tabelas 4.11 e 4.12 são mostrados os resultados que foram obtidos utilizando a base de dados sem seleção de atributos e RNAs com duas camadas neurais intermediárias (Tabela 4.11) e os resultados que foram obtidos considerando-se a seleção de atributos e mantendo-se as RNAs com duas camadas neurais intermediárias (Tabela 4.12).

Tabela 4.10 – Resultados obtidos para previsão de ações da CPFL: dados com seleção de atributos e RNA com 1 camada neural intermediária.

Com Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,00093	0,802085	2,3E-05	0,00424	0,918722	3,3E-05
10	0,00126	1,105966	4,8E-05	0,00681	1,499263	9,2E-05
15	0,00112	0,968183	3,7E-05	0,00777	1,728009	0,00011
20	0,00111	0,971785	3,3E-05	0,0107	2,401747	0,00036
25	0,001	0,859054	2,7E-05	0,01047	2,30306	0,0002
30	0,00112	0,969702	3,1E-05	0,02712	6,175443	0,004

Tabela 4.11 – Resultados obtidos para previsão de ações da CPFL: dados sem seleção de atributos e RNA com 2 camadas neurais intermediárias.

Sem Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,002019	1,74088	9,2E-05	0,038625	8,57233	0,002259432
	15	0,002492	2,21058	0,00022	0,014599	3,12702	0,000309174
	20	0,015434	13,7507	0,00552	0,014989	3,33222	0,000296751
	25	0,00144	1,22771	5,4E-05	0,017075	3,78761	0,000409131
	30	0,002967	2,60772	0,00026	0,015948	3,44949	0,000409088
10	15	0,005357	4,73128	0,00056	0,012917	2,84198	0,000247214
	20	0,012698	11,2611	0,00351	0,035416	7,8451	0,001601901
	25	0,006687	5,73923	0,00087	0,02692	6,03062	0,000991317
	30	0,010182	9,01991	0,00217	0,01328	2,97355	0,000368289
15	20	0,004449	3,94753	0,00053	0,011885	2,62188	0,000228391
	25	0,004083	3,52903	0,00034	0,007561	1,6397	9,16401E-05
	30	0,016198	14,5193	0,00732	0,014839	3,22697	0,000353298
20	25	0,003891	3,38914	0,00036	0,043408	9,6487	0,002258395
	30	0,002517	2,0966	0,00018	0,017246	3,76706	0,000401625

Conforme previamente comentado, a RNA com o melhor desempenho foi submetida a outros 10 treinamentos e validações para a previsão dos preços máximos (Tabela 4.13) e dos preços mínimos (Tabela 4.14).

Tabela 4.12 – Resultados obtidos para previsão de ações da CPFL: dados sem seleção de atributos e RNA com 2 camadas neurais intermediárias.

Com Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,001008	0,88013	2,8E-05	0,004552	0,99128	3,5E-05
	15	0,001113	0,97929	3,6E-05	0,008521	1,85798	0,00012
	20	0,001024	0,89428	2,9E-05	0,004957	1,07832	4,6E-05
	25	0,00103	0,88476	2,7E-05	0,010479	2,31218	0,00054
	30	0,001117	0,98425	6,4E-05	0,00892	1,98373	0,00027
10	15	0,001086	0,95304	3,3E-05	0,007172	1,59759	9,7E-05
	20	0,001411	1,27018	9,4E-05	0,006047	1,31879	7,6E-05
	25	0,000947	0,81426	2,4E-05	0,027962	6,37627	0,00435
	30	0,001003	0,87001	2,7E-05	0,024163	5,4756	0,00314
15	20	0,001047	0,89754	2,8E-05	0,018203	4,13354	0,00109
	25	0,001854	1,68058	0,00024	0,026119	5,74395	0,00186
	30	0,001085	0,94223	3,2E-05	0,007839	1,73164	0,00011
20	25	0,001078	0,93771	3,3E-05	0,00645	1,41003	9,4E-05
	30	0,001517	1,34759	7,5E-05	0,014261	3,21391	0,00052

Tabela 4.13 – Resultados obtidos para previsão de ações da CPFL: 10 treinamentos para previsão do preço máximo.

Preço máximo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,00089	0,754545	2,3E-05	0,00093	0,802085	2,3E-05
2	0,00116	0,999518	3,7E-05	0,00115	1,007579	3,9E-05
3	0,00114	0,992952	3,4E-05	0,00182	2,512937	0,00011
4	0,00259	2,236531	0,00015	0,00117	1,027038	3,9E-05
5	0,00552	4,2422764	0,00019	0,00098	0,847264	2,6E-05
6	0,00991	8,846103	0,00231	0,00192	2,775593	0,00014
7	0,00687	6,012659	0,00107	0,00467	6,934364	0,00056
8	0,00296	2,51926	0,00022	0,00414	5,532717	0,00046
9	0,00308	2,778084	0,00032	0,00292	4,20979	0,00022
10	0,02511	22,00465	0,01136	0,0073	11,78752	0,00117




Figura 4.2 – Comparação entre o valor desejado do preço máximo da ação da CPFL e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

Os melhores resultados obtidos durante os 10 treinamentos encontram-se destacados nas Tabelas 4.13 e 4.14. Ademais, as Figuras 4.2 (preço máximo) e 4.3 (preço mínimo) mostram a representação gráfica dos dados destinados à validação das RNAs.

Tabela 4.14 – Resultados obtidos para previsão de ações da CPFL: 10 treinamentos para previsão do preço mínimo.

Preço mínimo						
Treinamento	Sem mineração			Com mineração		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,007561	1,6397	9,16401E-05	0,00389	0,83944	2,6E-05
2	0,014432	3,02379	0,000356166	0,00424	0,918722	3,3E-05
3	0,010948	2,3768	0,000188047	0,00426	0,918877	3E-05
4	0,0141	4,69204	0,000374285	0,00436	0,944389	3E-05
5	0,046687	9,8671	0,003181152	0,00402	0,868345	2,7E-05
6	0,018174	4,01718	0,000580214	0,00848	1,900516	0,00015
7	0,078303	17,5245	0,013785028	0,00999	2,233958	0,00038
8	0,032076	6,98127	0,001368822	0,0043	0,924155	3,3E-05
9	0,02144	4,77473	0,000773961	0,00477	1,027435	4,1E-05
10	0,029839	6,55346	0,001710233	0,00747	1,617245	9,8E-05




Figura 4.3 – Comparação entre o valor desejado do preço mínimo da ação da CPFL e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

4.3 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COELBA

Por meio das Tabelas de 4.15 a 4.18 é possível visualizar os resultados obtidos para a validação das RNAs que foram treinadas visando prever as ações da COELBA. Os resultados das previsões realizadas sem a etapa de seleção de atributos encontram-se nas Tabelas 4.15 e 4.17 e, portanto, os resultados obtidos após a seleção de atributos está alocado nas Tabelas 4.16 e 4.18.

Ressalta-se que os resultados, novamente, foram obtidos para estimativas de preços máximos e mínimos da ação.

Tabela 4.15 – Resultados obtidos para previsão de ações da COELBA: dados sem seleção de atributos e RNA com 1 camada neural intermediária.

Sem Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,00631	10,94306	0,00098	0,01134	4,525856	0,00019
10	0,003	4,865705	0,00024	0,01537	6,488707	0,00042
15	0,01692	30,16547	0,00718	0,02497	9,315632	0,00106
20	0,00449	7,42666	0,00052	0,024	9,162419	0,00098
25	0,01199	18,62143	0,00312	0,01532	6,059238	0,00038
30	0,00516	7,461998	0,0007	0,04544	18,85607	0,00296

Tabela 4.16 – Resultados obtidos para previsão de ações da COELBA: dados com seleção de atributos e RNA com 1 camada neural intermediária.

Com Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,00182	2,512937	0,00011	0,00536	2,360995	7,5E-05
10	0,00192	2,775593	0,00014	0,01983	8,987125	0,00078
15	0,00467	6,934364	0,00056	0,01641	7,379829	0,00058
20	0,00414	5,532717	0,00046	0,0565	25,69009	0,00647
25	0,00292	4,20979	0,00022	0,03467	15,75874	0,00221
30	0,0073	11,78752	0,00117	0,05002	22,71097	0,00533

Tabela 4.17 – Resultados obtidos para previsão de ações da COELBA: dados sem seleção de atributos e RNA com 2 camadas neurais intermediárias.

Sem Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,004451	6,91798	0,00049	0,011754	4,43524	0,000220591
	15	0,007229	11,2958	0,00134	0,007046	2,75903	8,89698E-05
	20	0,008076	14,33	0,00184	0,039352	16,7389	0,00406523
	25	0,002603	3,70981	0,00025	0,008748	3,28777	0,000123738
	30	0,010344	18,1943	0,00334	0,006658	2,3607	8,39574E-05
10	15	0,00691	11,4619	0,00106	0,016431	6,03372	0,000445384
	20	0,008158	12,5743	0,00174	0,025154	10,9795	0,001234167
	25	0,00682	10,5565	0,0012	0,016277	6,61473	0,000429665
	30	0,006987	11,0078	0,00144	0,015924	5,87258	0,000395898
15	20	0,00575	9,31374	0,00082	0,02653	8,81137	0,001087623
	25	0,006622	10,9306	0,00115	0,0141	4,69204	0,000374285
	30	0,014159	23,0436	0,00503	0,016898	6,94478	0,000439048
20	25	0,008381	13,6473	0,00171	0,033123	11,9066	0,001560129
	30	0,007128	10,1418	0,00169	0,019509	6,44558	0,000725438

Tabela 4.18 – Resultados obtidos para previsão de ações da COELBA: dados com seleção de atributos e RNA com 2 camadas neurais intermediárias.

Com Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,002411	3,4256	0,00018	0,007803	3,24857	0,00011
	15	0,00156	2,20926	0,00012	0,027914	12,7174	0,00159
	20	0,001388	1,90091	0,00011	0,028719	12,4946	0,00156
	25	0,001799	2,79687	0,00013	0,036352	16,9359	0,0035
	30	0,007239	12,3811	0,00188	0,012065	5,05591	0,00025
10	15	0,003763	5,72815	0,0004	0,011975	4,16475	0,00044
	20	0,004989	7,79951	0,00073	0,018544	7,59541	0,00071
	25	0,002794	4,07162	0,00025	0,022228	10,3377	0,00097
	30	0,005351	8,46284	0,00079	0,053063	25,6168	0,00636
15	20	0,00243	3,82357	0,00019	0,035819	12,7165	0,00343
	25	0,00293	4,23613	0,00028	0,073764	35,2911	0,01182
	30	0,003087	4,74321	0,0003	0,035707	16,2155	0,00277
20	25	0,010068	15,7673	0,00369	0,02961	13,7064	0,00338
	30	0,00679	10,8293	0,00124	0,170491	79,5013	0,06031

Conforme previamente apresentado para a ação da CPFL, as Tabelas 4.19 e 4.20 mostram os resultados obtidos após os 10 treinamentos consecutivos realizados para a melhor topologia das RNAs.

Tabela 4.19 – Resultados obtidos para previsão de ações da COELBA: 10 treinamentos para previsão do preço máximo.

Preço máximo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,005079	2,57935	0,00076	0,001388	1,90091	0,00011
2	0,016318	7,79432	0,00616	0,015472	7,04039	0,00759
3	0,013996	6,74452	0,00687	0,011698	5,36664	0,00436
4	0,012406	5,71826	0,00446	0,013313	6,05687	0,00622
5	0,017228	8,0154	0,0078	0,012112	5,52026	0,00496
6	0,006225	3,03103	0,00106	0,00963	4,43647	0,00276
7	0,014006	6,66472	0,00495	0,008126	3,72724	0,00206
8	0,014696	7,09502	0,00507	0,008257	3,86337	0,00192
9	0,014412	7,18438	0,00548	0,005729	2,69511	0,00121
10	0,019688	9,09415	0,01072	0,00709	3,35064	0,00177

Já as Figuras 4.4 e 4.5 fornecem a representação gráfica que compara os preços máximos e mínimos das ações da COELBA (provenientes do histórico de cotações) aos valores estimados pelas RNAs com e sem a etapa de seleção de atributos.

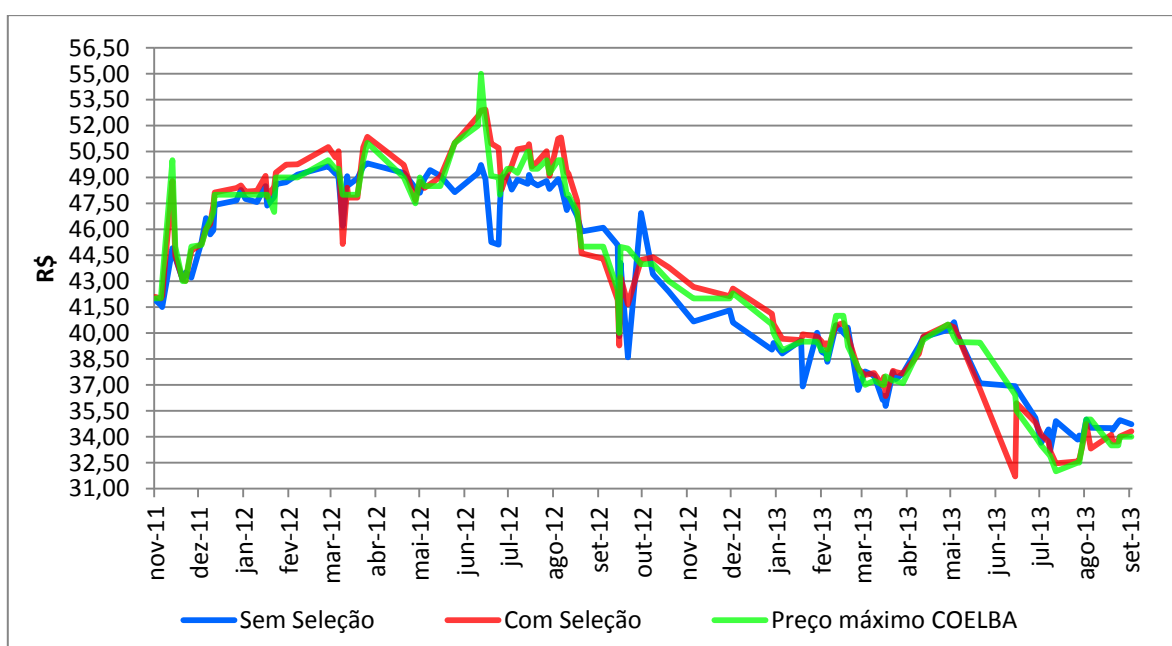


Figura 4.4 – Comparação entre o valor desejado do preço máximo da ação da COELBA e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

Tabela 4.20 – Resultados obtidos para previsão de ações da COELBA: 10 treinamentos para previsão do preço mínimo.

Preço mínimo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,006658	2,3607	8,39574E-05	0,00536	2,360995	7,5E-05
2	0,02232	2,80518	0,001359846	0,02557	2,839044	0,00128
3	0,037386	4,40791	0,002690832	0,02854	3,152869	0,00166
4	0,138456	15,1769	0,036613592	0,03045	3,341094	0,00193
5	0,107283	11,72	0,022709503	0,0229	2,524331	0,00122
6	0,063408	7,24497	0,006611482	0,03783	4,11934	0,00414
7	0,055215	6,02647	0,00625	0,04723	5,244028	0,00513
8	0,1044	11,7359	0,019226473	0,05804	6,367823	0,00671
9	0,051256	5,74411	0,004700365	0,06168	6,788113	0,00744
10	0,047148	5,39595	0,003796064	0,05529	6,098482	0,00745




Figura 4.5 – Comparação entre o valor desejado do preço mínimo da ação da COELBA e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

4.4 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA COSERN

As Tabelas 4.21 e 4.22 mostram os valores obtidos pelas RNAs com e sem a etapa de seleção de atributos, considerando-se para tanto topologias com somente 1 camada neural intermediária.

Tabela 4.21 – Resultados obtidos para previsão de ações da COSERN: dados sem seleção de atributos e RNA com 1 camada neural intermediária.

Sem Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,005174	2,4554222	0,00019	0,005653	2,128253	0,000295
10	0,018032	10,028082	0,001745	0,007267	2,8892124	0,000378
15	0,003826	1,6484038	0,000122	0,008366	3,974813	0,000392
20	0,020496	12,995096	0,003446	0,007708	3,572663	0,000436
25	0,012294	7,4158955	0,001106	0,010335	6,1833665	0,000663
30	0,011501	4,3514467	0,000887	0,007998	3,2500792	0,000469

Tabela 4.22 – Resultados obtidos para previsão de ações da COSERN: dados com seleção de atributos e RNA com 1 camada neural intermediária.

Com Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,001437	0,6223633	4,45E-05	0,00745	2,679661	0,00039
10	0,006227	2,2473564	0,000293	0,01824	4,559123	0,00117
15	0,007366	2,6852742	0,000344	0,0277	7,06178	0,00347
20	0,007924	3,3065134	0,000479	0,01987	5,350593	0,00143
25	0,007576	3,159747	0,000382	0,00795	2,717559	0,0005
30	0,010562	4,0841607	0,000873	0,05196	12,29251	0,01557

Por meio das Tabelas 4.23 e 4.24 podem ser visualizados os resultados obtidos para as RNAs com topologias que consideram 2 camadas neurais intermediárias.

Tabela 4.23 – Resultados obtidos para previsão de ações da COSERN: dados sem seleção de atributos e RNA com 2 camadas neurais intermediárias.

Sem Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,01198	4,50465	0,00085	0,029107	9,6329	0,002136687
	15	0,006017	3,16882	0,00027	0,021459	8,30523	0,00112803
	20	0,01436	9,38415	0,00176	0,028644	10,0474	0,001699599
	25	0,013634	4,63975	0,0011	0,033728	12,8476	0,001865952
	30	0,027471	9,14873	0,00479	0,021132	10,1901	0,001204737
10	15	0,009493	4,18739	0,00061	0,026568	19,9664	0,001491518
	20	0,014403	7,76072	0,00127	0,041898	17,4672	0,003270938
	25	0,014615	7,16565	0,00131	0,05511	27,1535	0,005469381
	30	0,010303	6,04662	0,00097	0,038776	17,5635	0,002424259
15	20	0,008872	5,14931	0,00054	0,059739	26,7324	0,006188884
	25	0,012299	5,65999	0,00085	0,022093	12,9195	0,000946893
	30	0,013838	7,45721	0,00109	0,028728	12,5921	0,001545046
20	25	0,009966	4,45491	0,00094	0,065939	29,7459	0,006778
	30	0,010397	5,4794	0,00064	0,051709	21,8448	0,003974605

Tabela 4.24 – Resultados obtidos para previsão de ações da COSERN: dados com seleção de atributos e RNA com 2 camadas neurais intermediárias.

Com Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,00634	8,59265	0,00136	0,009283	4,96463	0,00073
	15	0,006504	10,8685	0,00127	0,008777	4,49396	0,00068
	20	0,007611	13,9537	0,00173	0,010551	5,20177	0,00093
	25	0,008926	18,1147	0,00241	0,009944	5,62832	0,00079
	30	0,015701	34,5206	0,00815	0,009705	5,6056	0,00078
10	15	0,010767	22,0787	0,00262	0,015389	6,61199	0,00382
	20	0,007946	14,0884	0,0017	0,008423	5,35678	0,00074
	25	0,010973	24,3704	0,00333	0,008781	5,10169	0,00064
	30	0,011145	23,8192	0,00364	0,011883	5,7513	0,00143
15	20	0,007663	17,4616	0,00167	0,010145	4,94229	0,00097
	25	0,00767	16,0378	0,00166	0,013599	6,22161	0,00165
	30	0,011706	20,9994	0,00402	0,013785	7,90136	0,00214
20	25	0,012068	19,8567	0,00417	0,016459	7,75798	0,00281
	30	0,010844	27,8196	0,00388	0,0179	7,14865	0,00427

A melhores topologias encontradas para a estimação dos preços máximos e mínimos foram submetidas a novos 10 treinamentos, onde obteve-se os resultados contidos nas Tabelas 4.25 e 4.26.

Tabela 4.25 – Resultados obtidos para previsão de ações da COSERN: 10 treinamentos para previsão do preço máximo.

Preço máximo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,00367	9,19491	0,00099	0,00148	7,20553	0,00157
2	0,024569	43,4906	0,02148	0,004794	7,88335	0,00071
3	0,008478	15,1892	0,00199	0,021519	22,9976	0,01901
4	0,017965	41,4365	0,00809	0,007275	10,8222	0,0013
5	0,008051	13,0371	0,00195	0,009287	12,5505	0,00259
6	0,009038	18,8753	0,00262	0,02204	35,6849	0,0124
7	0,008124	15,8305	0,0016	0,007995	15,403	0,00222
8	0,010426	18,2888	0,00248	0,013661	26,695	0,0045
9	0,008222	17,9569	0,00221	0,007563	11,2627	0,0021
10	0,011096	24,2992	0,00333	0,005143	8,85797	0,00095

Em conformidade com as representações gráficas que comparam as ações da CPFL e da COELBA com suas respectivas previsões realizadas pelas RNAs, o mesmo foi feito para a ação da COSERN (Figuras 4.6 e 4.7).




Figura 4.6 – Comparação entre o valor desejado do preço máximo da ação da COSERN e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

Tabela 4.26 – Resultados obtidos para previsão de ações da COSERN: 10 treinamentos para previsão do preço mínimo.

Preço mínimo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,00544	7,32696	0,000832867	0,00123	1,73276	0,00031
2	0,028737	16,9106	0,001583897	0,030209	7,84408	0,00352
3	0,035295	13,7921	0,002398861	0,048076	12,5052	0,01167
4	0,026922	10,0101	0,002448028	0,010542	3,00961	0,00052
5	0,045183	23,0922	0,004153153	0,065068	15,2745	0,02919
6	0,042762	19,602	0,003560055	0,025502	6,67837	0,0031
7	0,029008	14,5445	0,001295782	0,034572	8,74467	0,00629
8	0,027566	16,2459	0,001257432	0,023982	6,85923	0,00198
9	0,031103	16,5639	0,001805845	0,020814	5,61307	0,00165
10	0,043454	15,8367	0,00373935	0,036877	9,97532	0,00516




Figura 4.7 – Comparação entre o valor desejado do preço mínimo da ação da COSERN e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

4.5 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CELESC

As Tabelas 4.27 e 4.28 são destinadas a mostrar os resultados das RNAs com topologia de somente uma camada neural intermediária.

Tabela 4.27 – Resultados obtidos para previsão de ações da CELESC: dados sem seleção de atributos e RNA com 1 camada neural intermediária.

Sem Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,00631	10,94306	0,00098	0,01134	4,525856	0,00019
10	0,003	4,865705	0,00024	0,01537	6,488707	0,00042
15	0,01692	30,16547	0,00718	0,02497	9,315632	0,00106
20	0,00449	7,42666	0,00052	0,024	9,162419	0,00098
25	0,01199	18,62143	0,00312	0,01532	6,059238	0,00038
30	0,00516	7,461998	0,0007	0,04544	18,85607	0,00296

Tabela 4.28 – Resultados obtidos para previsão de ações da CELESC: dados com seleção de atributos e RNA com 1 camada neural intermediária.

Com Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,00182	2,512937	0,00011	0,00536	2,360995	7,5E-05
10	0,00192	2,775593	0,00014	0,01983	8,987125	0,00078
15	0,00467	6,934364	0,00056	0,01641	7,379829	0,00058
20	0,00414	5,532717	0,00046	0,0565	25,69009	0,00647
25	0,00292	4,20979	0,00022	0,03467	15,75874	0,00221
30	0,0073	11,78752	0,00117	0,05002	22,71097	0,00533

Tabela 4.29 – Resultados obtidos para previsão de ações da CELESC: dados sem seleção de atributos e RNA com 2 camadas neurais intermediárias.

Sem Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,004451	6,91798	0,00049	0,011754	4,43524	0,000220591
	15	0,007229	11,2958	0,00134	0,007046	2,75903	8,89698E-05
	20	0,008076	14,33	0,00184	0,039352	16,7389	0,00406523
	25	0,002603	3,70981	0,00025	0,008748	3,28777	0,000123738
	30	0,010344	18,1943	0,00334	0,006658	2,3607	8,39574E-05
10	15	0,00691	11,4619	0,00106	0,016431	6,03372	0,000445384
	20	0,008158	12,5743	0,00174	0,025154	10,9795	0,001234167
	25	0,00682	10,5565	0,0012	0,016277	6,61473	0,000429665
	30	0,006987	11,0078	0,00144	0,015924	5,87258	0,000395898
15	20	0,00575	9,31374	0,00082	0,02653	8,81137	0,001087623
	25	0,006622	10,9306	0,00115	0,0141	4,69204	0,000374285
	30	0,014159	23,0436	0,00503	0,016898	6,94478	0,000439048
20	25	0,008381	13,6473	0,00171	0,033123	11,9066	0,001560129
	30	0,007128	10,1418	0,00169	0,019509	6,44558	0,000725438

Tabela 4.30 – Resultados obtidos para previsão de ações da CELESC: dados com seleção de atributos e RNA com 2 camadas neurais intermediárias.

Com Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,002411	3,4256	0,00018	0,007803	3,24857	0,00011
	15	0,00156	2,20926	0,00012	0,027914	12,7174	0,00159
	20	0,001388	1,90091	0,00011	0,028719	12,4946	0,00156
	25	0,001799	2,79687	0,00013	0,036352	16,9359	0,0035
	30	0,007239	12,3811	0,00188	0,012065	5,05591	0,00025
10	15	0,003763	5,72815	0,0004	0,011975	4,16475	0,00044
	20	0,004989	7,79951	0,00073	0,018544	7,59541	0,00071
	25	0,002794	4,07162	0,00025	0,022228	10,3377	0,00097
	30	0,005351	8,46284	0,00079	0,053063	25,6168	0,00636
15	20	0,00243	3,82357	0,00019	0,035819	12,7165	0,00343
	25	0,00293	4,23613	0,00028	0,073764	35,2911	0,01182
	30	0,003087	4,74321	0,0003	0,035707	16,2155	0,00277
20	25	0,010068	15,7673	0,00369	0,02961	13,7064	0,00338
	30	0,00679	10,8293	0,00124	0,170491	79,5013	0,06031

Ao final dos treinamentos supracitados, obteve-se as melhores topologias para a previsão dos preços máximos e mínimos. Na sequência, foram realizados 10 treinamentos consecutivos com o objetivo de verificar o desempenho somente das melhores topologias. Os resultados das validações para estes 10 treinamentos podem ser observados pelas Tabelas 4.31 e 4.32.

Por fim, são apresentados gráficos das ações da CELESC (somente dados de validação), onde realiza-se uma comparação entre os dados reais das cotações e os dados previstos pelas RNAs (Figuras 4.8 e 4.9).

Tabela 4.31 – Resultados obtidos para previsão de ações da CELESC: 10 treinamentos para previsão do preço máximo.

Preço máximo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,002603	3,70981	0,00025	0,001388	1,90091	0,00011
2	0,011871	10,5802	0,00456	0,049524	46,2043	0,0666
3	0,061883	57,1912	0,10017	0,031487	29,094	0,02544
4	0,006166	5,68022	0,00141	0,011001	9,42677	0,00309
5	0,01472	13,3544	0,00655	0,042615	38,0875	0,04204
6	0,015584	14,4629	0,00815	0,039352	16,7389	0,00406523
7	0,044732	40,8596	0,04864	0,026884	6,01264	0,001483273
8	0,071732	64,1623	0,1153	0,024706	23,1124	0,01675
9	0,040945	36,9161	0,0397	0,039233	35,4781	0,03621
10	0,021857	20,182	0,01257	0,015194	13,2613	0,00491




Figura 4.8 – Comparação entre o valor desejado do preço máximo da ação da CELESC e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

Tabela 4.32 – Resultados obtidos para previsão de ações da CELESC: 10 treinamentos para previsão do preço mínimo.

Preço mínimo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,006658	2,3607	8,39574E-05	0,00536	2,360995	7,5E-05
2	0,108754	23,3838	0,01596889	0,10669	24,62375	0,01892
3	0,103226	22,7151	0,015106584	0,00536	2,360995	7,5E-05
4	0,16209	35,8688	0,036649221	0,04338	9,933691	0,00308
5	0,12073	26,8951	0,020950473	0,03573	8,017578	0,00189
6	0,189987	42,7282	0,054218782	0,03949	9,384413	0,00336
7	0,264647	58,9562	0,10135329	0,0791	18,26575	0,01052
8	0,227142	49,5049	0,071270738	0,13713	30,37316	0,0278
9	0,045113	9,07168	0,002680277	0,0933	21,33409	0,01379
10	0,238911	54,1409	0,090095713	0,08984	20,12366	0,01208

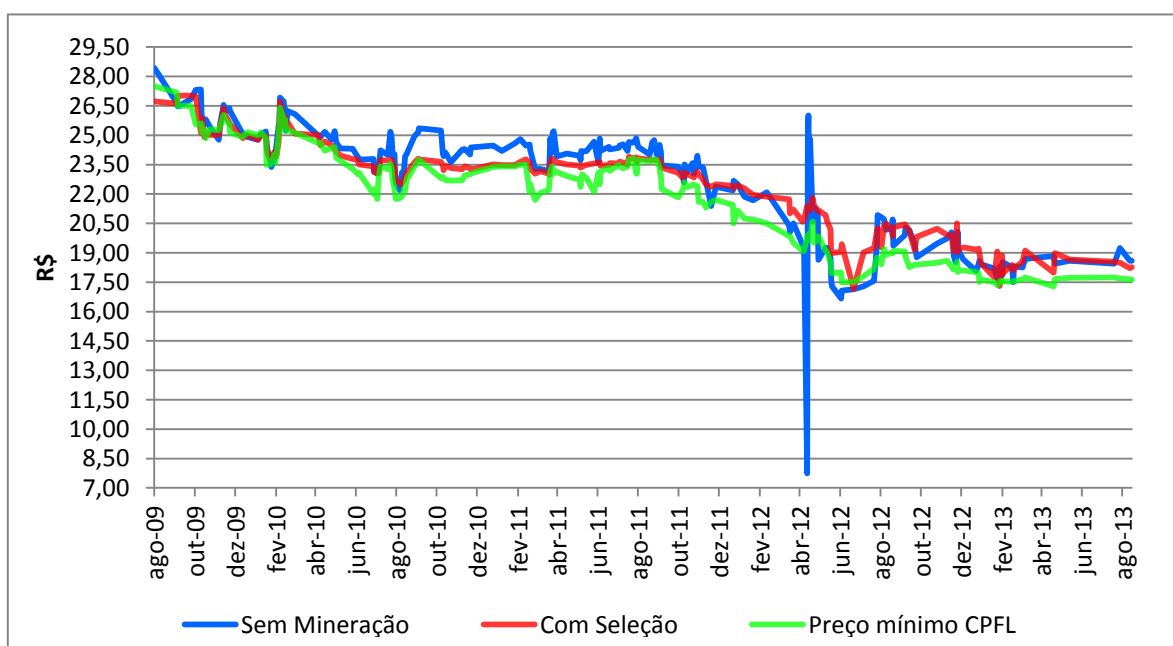


Figura 4.9 – Comparação entre o valor desejado do preço mínimo da ação da CELESC e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

4.6 RESULTADOS OBTIDOS PARA PREVISÃO DE AÇÕES DA CEB

As últimas ações analisadas foram da CEB, onde todos os testes já feitos para as demais ações foram replicados. Portanto, as Tabelas de 4.33 a 4.36 são destinadas a

apresentar os resultados das validações das RNAs com topologias contendo uma e duas camadas neurais intermediárias.

Tabela 4.33 – Resultados obtidos para previsão de ações da CEB: dados sem seleção de atributos e RNA com 1 camada neural intermediária.

Sem Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,00339	2,754085	0,00028	0,02844	5,741228	0,00107
10	0,00881	7,156655	0,00163	0,01144	2,245392	0,00027
15	0,00612	5,006135	0,00096	0,02729	5,790283	0,00119
20	0,00541	4,304557	0,00075	0,02071	4,459011	0,0006
25	0,0106	8,758359	0,00261	0,02996	6,514592	0,00144
30	0,01356	11,44002	0,00382	0,02034	4,076433	0,00066

Tabela 4.34 – Resultados obtidos para previsão de ações da CEB: dados com seleção de atributos e RNA com 1 camada neural intermediária.

Com Seleção de Atributos						
Nº de neurônios	Preço máximo			Preço mínimo		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	0,00115	0,855265	0,0001	0,00447	0,945185	5,3E-05
10	0,00118	0,889064	0,0001	0,00526	1,10491	5,7E-05
15	0,00616	5,103947	0,00085	0,01044	2,240319	0,00021
20	0,00146	1,145004	9,2E-05	0,02089	4,538744	0,00087
25	0,00151	1,148995	0,00012	0,00974	1,94085	0,00016
30	0,00168	1,279827	0,00014	0,01031	2,136294	0,00016

Tabela 4.35 – Resultados obtidos para previsão de ações da CEB: dados sem seleção de atributos e RNA com 2 camadas neurais intermediárias.

Sem Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,002913	1,15978	5,4E-05	0,014524	3,11074	0,00035
	15	0,002678	1,00068	5,8E-05	0,009583	1,99782	0,00014
	20	0,004318	1,50093	0,00012	0,008196	1,66419	0,00012
	25	0,002916	1,11288	6,8E-05	0,016326	3,31756	0,00055
	30	0,008547	3,69469	0,00053	0,048495	10,4418	0,00413
10	15	0,00456	1,7305	0,00014	0,038497	8,29511	0,00245
	20	0,007123	2,86774	0,00032	0,016696	3,50672	0,00044
	25	0,00357	1,3365	9,4E-05	0,03055	6,66469	0,00203
	30	0,019583	8,04875	0,00185	0,017919	3,78082	0,00045
15	20	0,016237	6,37275	0,00125	0,028325	5,80636	0,00148
	25	0,027446	10,7388	0,00397	0,041763	8,74547	0,0025
	30	0,003756	1,39858	9,3E-05	0,036972	8,12585	0,0023
20	25	0,010029	3,75752	0,00054	0,032459	6,47184	0,00141
	30	0,007709	3,10063	0,00041	0,021406	4,55347	0,00078

Ao final da análise das respostas das RNAs, obteve-se as melhores topologias que foram submetidas aos 10 treinamentos consecutivos previamente comentados para as demais ações. Os resultados destes novos treinamentos são visualizados por meio das Tabelas 4.37 e 4.38.

Os gráficos que compararam os dados reais da ação da CEB podem ser analisados pelas Figuras 4.10 e 4.11.

É importante comentar que todas as análises das RNAs foram feitas considerando-se treinamentos e validações com e sem a etapa de seleção de atributos. Portanto, os testes das RNAs foram exaustivos, proporcionando assim uma análise refinada da metodologia proposta para a previsão das ações das concessionárias de energia elétrica brasileiras.

Tabela 4.36 – Resultados obtidos para previsão de ações da CEB: dados com seleção de atributos e RNA com 2 camadas neurais intermediárias.

Com Seleção de Atributos							
Nº de neurônios da camada 1	Nº de neurônios da camada 2	Preço máximo			Preço mínimo		
		MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
5	10	0,001612	1,27574	0,00011	0,009313	1,91195	0,00013
	15	0,001509	1,16249	0,0001	0,014336	3,12787	0,00042
	20	0,001382	1,05011	0,00011	0,021257	4,59394	0,00108
	25	0,001876	1,4434	0,00016	0,008287	1,72282	0,00012
	30	0,001269	0,94371	0,00011	0,016705	3,45143	0,00043
10	15	0,001796	1,32689	0,00016	0,017693	3,81447	0,00065
	20	0,001748	1,34327	0,00016	0,014066	2,97711	0,00035
	25	0,001619	1,23897	0,00014	0,025032	5,22851	0,00104
	30	0,001691	1,30433	0,00012	0,006692	1,3683	8,9E-05
15	20	0,001333	0,98724	0,00011	0,02334	5,06555	0,0011
	25	0,001544	1,17895	0,00013	0,01082	2,12311	0,00019
	30	0,001676	1,26185	0,00015	0,025126	5,37211	0,00102
20	25	0,001662	1,20132	0,00014	0,013966	2,83121	0,00029
	30	0,001499	1,10273	0,00011	0,035551	7,13382	0,00176

Tabela 4.37 – Resultados obtidos para previsão de ações da CEB: 10 treinamentos para previsão do preço máximo.

Preço máximo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,001561	0,63627	1,905E-05	0,00139	0,53285	1,5E-05
2	0,01935	3,71784	0,00063	0,00361	0,761829	4,5E-05
3	0,016978	3,52032	0,00076	0,00455	0,939973	0,00455
4	0,011031	2,38399	0,00025	0,00626	1,308596	7,6E-05
5	0,010208	2,17226	0,0002	0,00453	0,933232	4,8E-05
6	0,022059	4,26121	0,0007	0,00536	2,360995	7,5E-05
7	0,016326	3,31756	0,00055	0,00333	0,706016	4E-05
8	0,048495	10,4418	0,00413	0,00551	1,179932	5,8E-05
9	0,015264	3,14749	0,00039	0,00447	0,945185	5,3E-05
10	0,013212	2,72301	0,00025	0,00546	1,114877	5,7E-05




Figura 4.10 – Comparação entre o valor desejado do preço máximo da ação da CEB e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

Tabela 4.38 – Resultados obtidos para previsão de ações da CEB: 10 treinamentos para previsão do preço mínimo.

Preço mínimo						
Treinamento	Sem Seleção de Atributos			Com Seleção de Atributos		
	MAE	MAPE (%)	MSE	MAE	MAPE (%)	MSE
1	0,00124	0,927836	0,0001	0,00361	0,761829	4,5E-05
2	0,00157	1,218762	9,8E-05	0,00889	1,82484	0,00012
3	0,00179	1,406114	0,00012	0,01169	2,421082	0,00019
4	0,00206	1,549387	0,00014	0,01979	4,319515	0,00075
5	0,00236	1,823364	0,00018	0,02237	4,791458	0,0009
6	0,00176	1,312285	0,00015	0,01013	2,109714	0,00019
7	0,001934	1,50271	0,00013	0,004692	0,98062	4,6E-05
8	0,001683	1,33637	0,0001	0,008204	1,60981	0,0001
9	0,001501	1,15897	0,00011	0,020342	4,2917	0,00076
10	0,001698	1,31946	0,00013	0,013391	2,61971	0,00024




Figura 4.11 – Comparação entre o valor desejado do preço mínimo da ação da CEB e os valores estimados pelas RNAs considerando os dados com e sem a seleção dos atributos.

Capítulo 5

Discussões

5.1 COMPORTAMENTO DAS AÇÕES DAS CONCESSIONÁRIAS SELECIONADAS DEVIDO À MEDIDA PROVISÓRIA 579 DE 2013

A Medida Provisória nº 579 tinha como um de seus objetivos a redução da tarifa de energia elétrica. Portanto, poder-se-ia esperar uma redução de arrecadação das empresas de distribuição de energia elétrica, pois, seu produto principal sofreria uma desvalorização. Portanto, torna-se óbvio que uma possível redução de receita apresentaria-se como uma informação negativa a qualquer investigador, fazendo com que estes deixem de investir na concessionária. Esta medida provisória foi anunciada em 11 de Setembro de 2012 e convertida na Lei 12.783 em 11 de Janeiro de 2013 (Presidência da República - Casa Civil, 2013).

Assim, esta Seção é destinada a discutir o impacto da medida provisória, desde Agosto de 2012 até Setembro de 2013, no valor das ações das concessionárias de energia elétrica analisadas neste trabalho. Para uma melhor análise, a Figura 5.1 apresenta os gráficos das cotações para cada uma das concessionárias.




Figura 5.1 – Histórico de cotações das ações das concessionárias analisadas neste trabalho para o horizonte de Agosto/2012 a Setembro/2013.

Observa-se, por meio da Figura 5.1, que na véspera da divulgação da medida provisória, as cotações das ações apresentam queda em seus valores. Entre Agosto e Outubro de 2012, é possível notar uma tendência de queda das curvas da COELBA, CELESC e COSERN, bem como uma "leve" recuperação de valor das ações da CPFL e CEB.

Ao considerar o período recente de aplicabilidade da lei, nota-se que as ações da CELESC, CPFL e CEB, apresentam grande tendência de queda, sendo que o caso da CEB é mais acentuado (perda de valor de R\$10,00). Já a COELBA e a COSERN apresentaram um comportamento oposto, ou seja, os valores de sua ações aumentaram.

5.2 RESULTADOS OBTIDOS POR MEIO DAS PREVISÕES

Conforme exposto nas Seções de 4.1 a 4.5, os resultados de estimação obtidos pela aplicação das RNAs para os preços máximos e mínimos das ações todos satisfatórios. As medidas de erro calculadas dão respaldo a esta afirmação, visto que os MAE, MAPE e MSE são aceitáveis do ponto de vista da previsão de ações.

Cabe comentar ainda que a etapa de Seleção de Atributos foi efetiva para se atingir os bons resultados apresentados. Além disso, torna-se evidente que o emprego de RNAs com a etapa de pré-análise e/ou pré-processamento dos dados é de extrema importância para a previsão de séries temporais, principalmente, no caso de séries financeiras.

Capítulo 6

Conclusões

A metodologia proposta para abordar o problema em questão, previsão de preços máximos e mínimos de ações de concessionárias de energia elétrica, apresentou resultados satisfatórios. Estes resultados somente foram possíveis de se atingir devido à preparação dos dados. Portanto, ao se trabalhar com séries temporais, é importante questionar quais são os tipos de variáveis que devem formar a base de dados, isto é, quais fatores podem influenciar na previsão da série temporal.

Neste trabalho, tem-se a preocupação de obter uma metodologia que justamente considere os fatores supracitados. Por este motivo, índices como Ibovespa e IEE foram levados em conta, pois, eles fornecem um indicativo do comportamento geral tanto da bolsa de valores como do setor elétrico brasileiro. Além disso, devido à grande participação de investidores estrangeiros, a cotação do dólar também foi utilizada como possível variável de entrada.

É importante destacar que a base de dados deve ter uma organização cronológica, pois, o fator tempo é crucial para a previsibilidade de uma série temporal.

Cabe comentar ainda que o emprego da seleção de atributos possibilitou a redução de dimensionalidade dos dados de entrada que, por consequência, contribuiu para a minimização do esforço computacional. Além disso, a seleção de atributos faz-se importante devido à eliminação de variáveis que pudessem contrair para o mal desempenho das Redes Neurais Artificiais durante o processo de previsão.

Por fim, a análise de diversas configurações das Redes Neurais (variação de camadas e número de neurônios) junto ao emprego do algoritmo de Levenberg-Marquardt possibilitou a obtenção de bons resultados para todas as concessionárias de energia elétrica selecionadas para este trabalho. Portanto, pode-se dizer que a Mineração de Dados baseada em Seleção de Atributos e Redes Neurais Artificiais é eficiente para a previsão das ações destas concessionárias.

Referências Bibliográficas

AMORIM, M. C. *Previsão de séries temporais usando séries exógenas e combinação de redes neurais aplicada ao mercado financeiro*. Dissertação de Mestrado. Centro de Informática, Universidade Federal de Pernambuco, 2008.

ARAÚJO, K. A. M. e LOTUFO, A. D. P. Previsão de cargas elétricas através de uma rede neural feedforward com treinamento por Levenberg-Marquardt utilizando as toolboxes do MATLAB. *XXI Congresso de Iniciação Científica da UNESP*, 2009.

BANCO CENTRAL DO BRASIL. "Cotação de Moeda Estrangeira: Dólar Americano", Disponível em: <http://www4.bcb.gov.br/pec/taxas/port/ptaxnpesq.asp?id=txcotacao>, Acessado em 04 de Outubro de 2013.

BM&FBOVESPA. "Introdução ao Mercado de Capitais", Disponível em: <http://www.bmfbovespa.com.br/pt-br/a-bmfbovespa/download/merccap.pdf>, Acessado em 02 de Setembro de 2013a.

BM&FBOVESPA. "Histórico de Ações das Concessionárias de Energia Elétrica", Disponível em: <http://www.bmfbovespa.com.br>, Acessado em 04 de Outubro de 2013b.

BOX, G. E. P.; JENKINS, G. M. e REINSEL, G. C. *Time Series Analysis, Forecasting and Control*, Wiley Series in Probability and Statistics, 2008.

CERETTA, P. S.; BRUTTI, M. R. e SCHLENDER, S. G. Previsão do preço da soja: uma comparação entre os modelos ARIMA e redes neurais artificiais. *Informações Econômicas*, v.40, pp. 15-17, 2010.

COAKLEY, J. R. e BROWN, C. E. Artificial Neural Networks in Accounting and Finance: Modeling Issues. *International Journal of Intelligent Systems in Accounting, Finance & Management*, v. 9, pp. 119-144, 2000.

FERREIRA, L.; MOURA, G. L.; BORENSTEIN D. e FISCHMANN, A. A. Utilização de redes neurais artificiais como estratégia de previsão de preços no controle de agronegócio. *Revista de Administração e Inovação*, v. 8, n. 4, pp. 6-26, 2011.

FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMYTH, P. e UTHURUSAMY, R. *Advances in Knowledge Discovery and Data Mining*, AAAI Press, 1996.

FERNANDES, R. A. S. *Identificação de fontes de correntes harmônicas por redes neurais artificiais*. Dissertação de Mestrado. Escola de Engenharia de São Carlos, Universidade de São Paulo, 2009.

GATELY, E. *Neural Networks for Financial Forecasting*, John Wiley & Sons, 1995.

GUJARATI, D. *Economia Básica*. Editora Campus, 2006.

HALL, M. A. *Correlation-based Feature Selection for Machine Learning*, Ph.D. Thesis, The University of Waikato, 1999.

HALL, M. A. Correlation-based Feature Selection for Discrete and Numeric Class Machine Learning. *Proc. of the 17th International Conference on Machine Learning (ICML)*, pp. 359-366, 2000.

HAN, J. e KAMBER, M. *Data Mining: Concepts and Techniques*, Morgan Kaufmann, 2001.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. Prentice Hall, 1999.

HU, J. W.; HU, Y. C. e LIN, R. R. Applying Neural Networks to Prices Prediction of Crude Oil Futures. *Mathematical Problems in Engineering*, v. 2012, 2012

KAASTRA, I. e BOYD M. Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, v.10, pp. 215-236, 1996.

KIMOTO, T.; ASAKAWA, K.; YODA, M. e TAKEOKA, M. Stock market prediction system with modular neural networks, *IJCNN International Joint Conference on Neural Networks*, pp.1-6, 1990.

LATORRE, M. R. D. O. e CARDOSO, M. R. A. Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. *Revista Brasileira de Epidemiologia*, v. 4, n. 4, pp.145-152, 2001.

LIU, H. e MOTODA, H. *Feature Selection for Knowledge Discovery and Data Mining*, Kluwer Academic Publishers, 1998.

MACIEL, L. D. S.; BALLINI, R. e SILVEIRA, R. L. Apreçamento de opções de dólar no Brasil: uma avaliação dos modelos de redes neurais. *Economia - Revista da Associação Nacional dos Centros de Pós-Graduação em Economia*, 2009.

OLIVEIRA, S. R. *De Dados a Conhecimento: Evolução e Desafios*, Tese de Livre Docência, Universidade de São Paulo (USP/ICMC), São Carlos - SP, 2004.

Presidência da República - Casa Civil. "Medida Provisória 579", Disponível em: http://www.planalto.gov.br/ccivil_03/ato2011-2014/2012/Mpv/579.htm. Acessado em 31 de outubro de 2013.

Presidência da República - Casa Civil. "Lei 12.783", Disponível em: http://www.planalto.gov.br/ccivil_03/ato2011-2014/2013/Lei/L12783.htm. Acessado em 31 de outubro de 2013.

REVISTA EXAME. "Histórico do Ibovespa e do Índice de Energia Elétrica", Disponível em: <http://exame.abril.com.br/mercados/cotacoes-bovespa/indices>. Acessado em 04 de Outubro de 2013.

SILVA, I. N.; SPATTI, D. H. e FLAUZINO, R. A. *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: curso prático*, Artliber, 2010.

ZHANG, G. P. Times series forecasting using a hybrid ARIMA and neural network. *Neurocomputing*, v. 50, pp. 159-175, 2003.