



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE GESTÃO E NEGÓCIOS
PROGRAMA DE PÓS-GRADUAÇÃO EM GESTÃO ORGANIZACIONAL
CURSO DE MESTRADO PROFISSIONAL EM GESTÃO ORGANIZACIONAL

JOÃO VICTOR DA SILVA ALVES

**UM MODELO PREDITIVO DE COTAÇÃO DE AÇÕES DE EMPRESAS ESTATAIS
BRASILEIRAS UTILIZANDO REDES NEURAIS ARTIFICIAIS NO AMBIENTE
MATLAB**

UBERLÂNDIA/MG
2019

JOÃO VICTOR DA SILVA ALVES

**UM MODELO PREDITIVO DE COTAÇÃO DE AÇÕES DE EMPRESAS ESTATAIS
BRASILEIRAS UTILIZANDO REDES NEURAIS ARTIFICIAIS NO AMBIENTE
MATLAB**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Gestão Organizacional da Faculdade de Gestão e Negócios da Universidade Federal de Uberlândia, como exigência parcial para obtenção do título de Mestre em Gestão Organizacional.

Linha de Pesquisa: Gestão Pública

Orientador: Prof. Dr. Antônio Sérgio Torres Penedo

Co-orientador: Prof. Dr. Flávio Luiz de Moraes Barboza

**UBERLÂNDIA/MG
2019**

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

A474 Alves, João Victor da Silva, 1983-
2019 Um modelo preditivo de cotação de ações de empresas estatais
brasileiras utilizando redes neurais artificiais no ambiente MATLAB
[recurso eletrônico] / João Victor da Silva Alves. - 2019.

Orientador: Antônio Sérgio Torres Penedo.
Coorientador: Flávio Luiz de Moraes Barboza.
Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Pós-graduação em Gestão Organizacional.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2019.2475>
Inclui bibliografia.
Inclui ilustrações.

1. Administração. I. Torres Penedo, Antônio Sérgio, 1979-,
(Orient.). II. de Moraes Barboza, Flávio Luiz, 1980-, (Coorient.). III.
Universidade Federal de Uberlândia. Pós-graduação em Gestão
Organizacional. IV. Título.

CDU: 658

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074

JOÃO VICTOR DA SILVA ALVES

**UM MODELO PREDITIVO DE COTAÇÃO DE AÇÕES DE EMPRESAS ESTATAIS
BRASILEIRAS UTILIZANDO REDES NEURAS ARTIFICIAIS NO AMBIENTE
MATLAB**

Dissertação apresentada ao Programa de Pós-graduação em Gestão Organizacional da Faculdade de Gestão e Negócios da Universidade Federal de Uberlândia, como exigência parcial para obtenção do título de Mestre em Gestão Organizacional.

Uberlândia/MG, 04 de novembro de 2019.

Banca Examinadora:

05/11/2019

SEI/UFU - 1663422 - Ata de Defesa - Pós-Graduação

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Antônio Sérgio Torres Penedo, Professor(a) do Magistério Superior**, em 04/11/2019, às 11:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Flávio Luiz de Moraes Barboza, Professor(a) do Magistério Superior**, em 04/11/2019, às 11:07, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **José Eduardo Ferreira Lopes, Professor(a) do Magistério Superior**, em 04/11/2019, às 11:10, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Ricardo Augusto Souza Fernandes, Usuário Externo**, em 04/11/2019, às 11:51, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1663422** e o código CRC **17974B75**.

*Ao meu filho Miguel, minha esposa Juliana e minha mãe Sueli,
por tudo que são para mim.*

AGRADECIMENTOS

Primeiramente, a Jeová Deus, o grandioso Projetista e Criador de tudo, por me permitir chegar até aqui e por me fornecer saúde, força, persistência e paciência nesta longa jornada.

À minha amada esposa, Juliana, por confiar na minha capacidade de chegar até o fim deste grande projeto com êxito. Muito obrigado pela imensa paciência demonstrada durante todo este longo processo, principalmente na fase final dele.

À minha amada mãe, Sueli, por todos os seus ensinamentos, lições e toda educação e princípios que me ensinou sempre. Sem seu exemplo de força, luta e perseverança, eu jamais teria conseguido chegar até aqui. Muito obrigado, mãe, por tudo que a senhora fez e tem feito por mim durante toda a minha vida.

Ao meu amado filho, Miguel, por ter mudado completamente minha vida ao chegar a este mundo. Muito obrigado, filho, por ter dado um novo significado à minha existência e por ter me tornado um pai responsável e mais comprometido com o futuro. Você, com certeza, foi um motivo especial para eu finalizar este importante projeto.

Ao Professor Dr. Antônio Sérgio Torres Penedo, pela orientação durante todo este trajeto. Agradeço muito pela imensa paciência que demonstrou até a finalização deste trabalho. Sua experiência, acessibilidade e conhecimento foram vitais durante todo o percurso.

Ao Professor Dr. Flávio Luiz de Moraes Barboza, pela co-orientação nesta grande pesquisa. Sua técnica e experiência foram fundamentais para o andamento e conclusão desta dissertação de mestrado.

A Leonel Alejandro Laboissiere, cuja ajuda e orientações foram primordiais para a finalização deste trabalho. Agradeço muito pela prontidão, atenção e tempo despendidos a mim.

Ao Professor Dr. José Eduardo Ferreira Lopes e Professor Dr. Ricardo Augusto Souza Fernandes por, gentilmente, aceitarem participar de minha banca de avaliação. Suas dicas e avaliações, aliadas às suas experiências e conhecimentos, colaboraram sobremaneira para a consecução deste trabalho.

Finalmente, agradeço de coração a todos aqueles que, de alguma maneira, contribuíram para os resultados satisfatórios deste projeto pessoal.

RESUMO

Prever acertadamente o comportamento do mercado financeiro é um objetivo perseguido por investidores, gestores e pesquisadores. Modelos preditivos corretos e confiáveis visam auxiliar a tomada de decisões, buscando a minimização de perdas e a geração de ganhos nas transações financeiras intrínsecas às atividades relacionadas às bolsas de valores. Nesse contexto, a utilização de modelos baseados em redes neurais artificiais (RNA) tem aumentado significativamente na última década. Visto que as RNA são capazes de aprender e armazenar conhecimento experimental, sua aplicação na área de finanças pode prever o comportamento de ações no mercado financeiro. Dessa maneira, o objetivo deste trabalho é elaborar um modelo que utilize RNA para a previsão dos preços máximos e mínimos de ações de mercado de algumas grandes empresas estatais brasileiras atuais previamente selecionadas, no período de 2013 a 2017. Para alcançar tal objetivo, foram utilizados dados históricos de ações negociadas na bolsa de valores oficial brasileira (atualmente denominada B3), os quais se tornaram variáveis de entrada para as RNA utilizadas na construção do modelo preditivo proposto. As arquiteturas escolhidas para a construção do modelo preditivo foram a MLP (*Multilayer Perceptron*) e a LSTM (*Long Short-Term Memory*). Os resultados apresentados pelo modelo baseado em RNA do tipo MLP foram comparados com soluções obtidas por meio de RNA do tipo LSTM, as quais têm sido amplamente utilizadas em pesquisas científicas que objetivam desenvolver modelos preditivos para a área de finanças e diversas outras. Na análise comparativa, os resultados das RNA do tipo LSTM foram mais acertados e confiáveis quando confrontados com as soluções apresentadas pelas RNA do tipo MLP. Dessa forma, foi possível concluir que as RNA com arquitetura LSTM e suas atuais otimizações, são possíveis opções para a construção de modelos para a previsão do comportamento do mercado de ações. Notadamente, o produto tecnológico construído a partir desta pesquisa disponibiliza um modelo preditivo baseado em RNA, possibilitando a escolha da arquitetura do tipo MLP ou recorrente do tipo LSTM.

Palavras-chave: Redes Neurais Artificiais. LSTM. Modelo preditivo. Previsão de preços de ações.

ABSTRACT

Properly predicting financial market behavior is a goal pursued by investors, managers and researchers. Correct and reliable predictive models aim to assist decision making, seeking to minimize losses and generate gains in financial transactions intrinsic to stock market activities. In this context, the use of models based on artificial neural networks (ANN) has increased significantly in the last decade. Since ANN are capable of learning and storing experimental knowledge, their application in finance can predict stock market behavior. Thus, the aim of this dissertation is to develop a model that uses ANN to forecast the maximum and minimum market share prices of some of the currently selected large state-owned Brazilian companies, from 2013 to 2017. To achieve this objective, historical stock data were traded on the official Brazilian stock exchange (currently called B3), which became input variables for the RNAs used in the construction of the proposed predictive model. The architectures chosen to build the predictive model were MLP (Multilayer Perceptron) and LSTM (Long Short-Term Memory). The results presented by the MLP RNA-based model have been compared with LSTM RNA-based solutions, which have been widely used in scientific research aimed at developing predictive models for finance and several others. In the comparative analysis, LSTM RNA results were more accurate and reliable when compared to MLP RNA solutions. Thus, it was possible to conclude that RNA with LSTM architecture and its current optimizations are possible options for the construction of models to predict stock market behavior. Notably, the technological product built from this research provides an RNA-based predictive model, enabling the choice of MLP or recurrent LSTM architecture.

Keywords: Artificial Neural Networks. LSTM. Predictive model. Stock Price Forecast.

LISTA DE FIGURAS

Figura 1:	A célula nervosa (Neurônio).....	39
Figura 2:	Modelo de um neurônio artificial.....	39
Figura 3:	Relação entre um neurônio biológico e um neurônio artificial.....	40
Figura 4:	Função de ativação do tipo Limiar.....	43
Figura 5:	Função de ativação do tipo Linear.....	43
Figura 6:	Função de ativação do tipo Sigmóide.....	44
Figura 7:	Função de ativação do tipo Gaussiana.....	44
Figura 8:	Função de ativação do tipo Tangente hiperbólica.....	45
Figura 9:	Representação de uma rede neural artificial contendo 3 camadas.....	47
Figura 10:	Representação de uma rede neural artificial do tipo <i>feedforward</i> (camada única).....	48
Figura 11:	Representação de uma rede neural artificial do tipo <i>feedforward</i> (multicamadas).....	49
Figura 12:	Representação de uma rede neural artificial do tipo <i>feedback</i>	50
Figura 13:	Representação de uma rede neural artificial recorrente.....	51
Figura 14:	Representação de uma rede neural artificial recorrente do tipo LSTM.....	52
Figura 15:	Representação de uma rede neural artificial do tipo MLP com duas camadas ocultas.....	55
Figura 16:	Fluxograma da metodologia proposta para a construção do modelo preditivo.....	76
Figura 17:	Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de BBAS3.....	82
Figura 18:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de BBAS3.....	83
Figura 19:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de BBAS3.....	83
Figura 20:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de BBAS3.....	84
Figura 21:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de BBAS3.....	84
Figura 22:	Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de CSMG3.....	87
Figura 23:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de CSMG3.....	88

Figura 24:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de CSMG3.....	89
Figura 25:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de CSMG3.....	89
Figura 26:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de CSMG3.....	90
Figura 27:	Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de ELET6.....	91
Figura 28:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de ELET6.....	93
Figura 29:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de ELET6.....	93
Figura 30:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de ELET6.....	94
Figura 31:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de ELET6.....	94
Figura 32:	Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de PETR4.....	96
Figura 33:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de PETR4.....	97
Figura 34:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de PETR4.....	97
Figura 35:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de PETR4.....	98
Figura 36:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de PETR4.....	98
Figura 37:	Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de TELB4.....	101
Figura 38:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de TELB4.....	102
Figura 39:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de TELB4.....	102
Figura 40:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de TELB4.....	103
Figura 41:	Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de TELB4.....	103
Figura 42:	Área de trabalho do MATLAB R2015a.....	117

Figura 43:	Exemplo de execução de uma instrução na janela de comandos do MATLAB.....	119
Figura 44:	Criação e armazenamento de um arquivo de <i>script</i> no MATLAB.....	120
Figura 45:	Execução de um arquivo de <i>script</i> via janela de comandos.....	121
Figura 46:	Plotagem de gráfico bidimensional no MATLAB.....	121
Figura 47:	Plotagem do gráfico bidimensional da função apresentada no Quadro 7.....	122
Figura 48:	Acesso à documentação completa do MATLAB.....	123
Figura 49:	Plotagem do gráfico tridimensional da função apresentada no Quadro 8.....	124
Figura 50:	A <i>toolbox</i> NNTOOL do MATLAB.....	125
Figura 51:	Tela de importação de dados da <i>toolbox</i> NNTOOL.....	126
Figura 52:	Tela de criação de rede neural com a opção “New” da NNTOOL.....	127
Figura 53:	Criação das variáveis de entrada e saída da rede neural artificial.....	128
Figura 54:	Escolha do rótulo de variável e abertura de área tabular para a inserção de dados.....	129
Figura 55:	Cópia dos dados a serem carregados para a variável <i>inputs</i>	129
Figura 56:	Colagem dos dados coletados para a variável <i>inputs</i>	130
Figura 57:	Transposição do conteúdo da variável <i>inputs</i>	130
Figura 58:	Transposição do conteúdo da variável <i>targets</i>	131
Figura 59:	Painel de seleção de variáveis para a importação de dados da rede neural..	131
Figura 60:	Importação dos dados para as entradas da rede neural.....	132
Figura 61:	Importação dos dados para as saídas da rede neural.....	132
Figura 62:	Configuração dos dados de entrada e saída da rede neural artificial.....	133
Figura 63:	Configuração dos parâmetros da rede neural artificial.....	133
Figura 64:	Visualização da rede neural artificial criada.....	134
Figura 65:	Janela com opções para a manipulação da rede neural artificial criada.....	134
Figura 66:	Configuração dos parâmetros de entrada e saída para o treinamento da rede neural.....	135
Figura 67:	Visualização do 1º treinamento da rede neural artificial criada.....	136
Figura 68:	Desempenho da rede neural artificial no 1º treinamento realizado.....	137
Figura 69:	Gráfico de regressão resultante do 1º treinamento da rede neural.....	138
Figura 70:	Visualização de alguns pesos sinápticos no 1º treinamento da rede neural..	138

LISTA DE QUADROS

Quadro 1:	Estrutura da dissertação.....	23
Quadro 2:	Tipos de funções de ativação.....	42
Quadro 3:	Síntese da execução do algoritmo <i>backpropagation</i>	57
Quadro 4:	Estudos históricos realizados no contexto das RNA.....	61
Quadro 5:	Estudos empíricos recentes utilizando RNA como base metodológica.....	63
Quadro 6:	Variáveis de entrada das RNA utilizadas na construção do modelo preditivo.....	75
Quadro 7:	Comandos para geração do gráfico bidimensional de uma função.....	122
Quadro 8:	Comandos para geração do gráfico de uma superfície em 3D.....	123

LISTA DE TABELAS

Tabela 1:	Métodos para estimação do número de neurônios.....	46
Tabela 2:	Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação BBAS3.....	81
Tabela 3:	Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação BBAS3.....	81
Tabela 4:	Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação CSMG3.....	86
Tabela 5:	Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação CSMG3.....	86
Tabela 6:	Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação ELET6.....	91
Tabela 7:	Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação ELET6.....	91
Tabela 8:	Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação PETR4.....	95
Tabela 9:	Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação PETR4.....	95
Tabela 10:	Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação TELB4.....	99
Tabela 11:	Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação TELB4.....	100

LISTA DE ABREVIATURAS E SIGLAS

ADALINE	<i>Adaptative Linear Element</i>
ADAM	<i>Adaptive Moment Estimation</i>
B3	Brasil, Bolsa, Balcão (antiga BM&FBOVESPA)
BACEN	Banco Central do Brasil
BOVESPA	Bolsa de Valores de São Paulo (atualmente denominada B3)
CF88	Constituição Federal de 1988
CLT	Consolidação das Leis do Trabalho
COPASA	Companhia de Saneamento de Minas Gerais
ELETROBRÁS	Centrais Elétricas Brasileiras S. A.
IBOVESPA	Índice BOVESPA
IBICT	Instituto Brasileiro de Informação em Ciência e Tecnologia
LM	Levenberg-Marquardt
LMS	Least Mean-Square
LSTM	<i>Long Short-Term Memory</i>
MADALINE	<i>Multiple-adaline</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentual Error</i>
MATLAB	<i>Matrix Laboratory</i>
MLP	<i>Multilayer Perceptron</i>
RMSE	<i>Root Mean Square Error</i>
NNTOOL	<i>Neural Network Toolbox</i>
PETROBRÁS	Petróleo Brasileiro S. A.
RNA	Redes Neurais Artificiais
TELEBRÁS	Telecomunicações Brasileiras S. A.

SUMÁRIO

1	INTRODUÇÃO.....	17
1.1	Problema de pesquisa.....	19
1.2	Objetivos.....	20
1.3	Justificativa da pesquisa.....	21
1.4	Estrutura da dissertação.....	22
2	REFERENCIAL TEÓRICO.....	24
2.1	Mercado de capitais e Bolsa de ações oficial brasileira.....	24
2.2	Empresas Públicas e Sociedades de Economia Mista.....	27
2.3	Redes Neurais Artificiais.....	37
2.3.1	Definições e conceitos.....	37
2.3.2	Funções de ativação.....	41
2.3.3	Arquiteturas.....	45
2.3.3.1	Arquitetura do tipo <i>feedforward</i>	48
2.3.3.2	Arquitetura do tipo <i>feedback</i>	49
2.3.3.3	Arquitetura do tipo recorrente <i>Long Short-Term Memory (LSTM)</i>	50
2.3.4	Aprendizagem e treinamento.....	53
2.4	Pesquisas empíricas relacionadas.....	58
2.4.1	Estado da Arte.....	58
2.4.2	Pesquisas recentes.....	62
3	METODOLOGIA.....	74
3.1	Classificação da pesquisa.....	74
3.2	Aspectos metodológicos.....	75
3.3	RNA escolhidas e parâmetros de configuração.....	77
4	RESULTADOS.....	80
4.1	Resultados obtidos para a previsão da ação BBAS3.....	80
4.2	Resultados obtidos para a previsão da ação CSMG3.....	85
4.3	Resultados obtidos para a previsão da ação ELET6.....	90
4.4	Resultados obtidos para a previsão da ação PETR4.....	95
4.5	Resultados obtidos para a previsão da ação TELB4.....	99

5	CONCLUSÃO.....	104
	REFERÊNCIAS.....	106
	APÊNDICE A - MATLAB.....	116

1 INTRODUÇÃO

O rápido avanço científico/tecnológico observado nas últimas décadas tem tornado possível a aceleração da criação de modelos preditivos confiáveis nas mais diversas áreas. Um modelo preditivo busca antecipar eventos, de modo a auxiliar o ser humano na tomada de decisões estratégicas e fundamentais a fim de solucionar problemas complexos.

Como citado por Silva (2016), prever o futuro com base em acontecimentos passados é a motivação principal para a utilização de modelos preditivos como solução para diversos tipos de problemas. Tais modelos são capazes de antecipar eventos não conhecidos, estejam eles no passado, presente ou, mais geralmente, no futuro (PROVOST; FAWCETT, 2013).

Nesse sentido, Souza (2014) menciona que desenvolver um modelo preditivo é um método caracterizado pela análise de uma coleção de dados atuais e/ou históricos de um determinado domínio de aplicação, relacionando ao conhecimento de um especialista da área, a fim de definir uma maneira que permita prever um evento futuro definido. Desse modo, o grau de exatidão de um modelo preditivo envolve quantificar a equivalência entre a probabilidade prevista e a que é realmente observada.

Ademais, Valente (2017) aponta que a parte mais importante de qualquer modelo de previsão é identificar quais as melhores variáveis que melhor definem um acontecimento ou uma característica. Nesse trabalho, tais variáveis são as cotações de valores de abertura, fechamento, mínimos e máximos das ações financeiras de cinco empresas estatais brasileiras previamente escolhidas. Também são utilizadas como variáveis de entrada a cotação do dólar e o índice da bolsa de valores oficial do Brasil no período escolhido como recorte temporal.

Nesse contexto, o mercado de ações tem utilizado técnicas e ferramentas computacionais na tentativa de prever o comportamento de seus ativos e recursos negociados nas bolsas de valores nacionais e internacionais.

Dessa maneira, Silva, M. D. O. P. (2017) indica que um fator principal que motiva a realização de pesquisas acerca do comportamento dos preços no mercado financeiro é a necessidade de identificar padrões de comportamento. Tal necessidade é consequência da incerteza associada ao processo de tomada de decisões dos indivíduos que, no mercado de ações, são representados pelos acionistas (SILVA M. D. O. P., 2017).

Soma-se a esse cenário os riscos associados aos investimentos e a volatilidade do mercado acionário. Segundo Fernandes (2018), a volatilidade é uma métrica utilizada para mensurar a oscilação inerente à evolução complexa do mercado financeiro no tempo.

À vista disso, de acordo com Machado (2017), acionistas e economistas financeiros se interessam profundamente na análise da relação entre o risco de um ativo financeiro e a segurança do seu retorno. Tais agentes, sempre buscam estudos e opiniões fidedignas que possam embasar suas decisões sobre a venda, compra ou a renegociação de títulos de dívidas do setor público ou privado (SUZART, 2013).

Dessa forma, dado o intrínseco grau de risco inerente aos investimentos em ações no mercado financeiro, Góes (2018) indica que em décadas recentes, houve um grande aumento de investimentos em títulos públicos devido à relação risco e retorno, pois apresentam baixo risco, taxas elevadas e elevada liquidez. A mesma autora ainda menciona que, devido a isso, tem havido concentração de carteiras de investidores organizacionais em ativos de renda fixa.

Por conseguinte, nesse contexto, como resultado da busca de ferramentas que auxiliem a tomada de decisões, a utilização de modelos baseados em redes neurais artificiais (RNA) tem aumentado significativamente nos últimos dez anos. Conforme Santos M. A. et al. (2016), observou-se um aumento de 50% no número de pesquisas científicas que utilizam RNA como base para o estudo e obtenção de resultados específicos. Os autores também citam que as pesquisas que aplicam RNA concentram-se nas mais variadas áreas de conhecimento como, por exemplo, contabilidade, engenharia, computação e finanças. Analogamente, Paliwal e Kumar (2009) apresentam que as RNA têm sido empregadas como opção aos tradicionais modelos estatísticos.

Conforme menciona Ferro (2013), as RNA são adaptáveis e, de maneira similar aos neurônios biológicos naturais, conseguem reter aprendizado e realizar procedimentos de controle, reconhecimento de padrões e classificação. Devido a tais características, sua utilização para a criação de modelos preditivos é adequada, pois simulam eventos cotidianos com a ajuda de algoritmos e de sistemas computacionais (FERRO, 2013). Ademais, visto que a principal característica de uma rede neural é o armazenamento de conhecimento experimental para ser empregado, sua aplicação na área de finanças pode prever o comportamento de ações no mercado financeiro (BEZERRA, 2017).

Destacando a utilização moderna das RNA nas mais diversas ciências, Ferro (2013) cita alguns exemplos: a análise de eletrocardiogramas e eletroencefalogramas, simulações de voos e de sistemas de controle de aviões, compressão de imagens, filtragem de ruídos telefônicos e a avaliação da aplicação de créditos no sistema bancário.

Analogamente, Disconzi (2018) apresenta que estudos brasileiros recentes evidenciaram sucesso na utilização das RNA para a previsão de preços. A autora ainda cita que os resultados assertivos obtidos na aplicação das RNA para as previsões de séries de preços

justificam as pesquisas que visam criar métodos que apoiem os gestores nos processos decisórios mais críticos.

Nesse contexto, Arantes (2013) destaca que, nas últimas duas décadas, os estudos relacionados à previsão de séries financeiras registraram importantes avanços, principalmente em relação ao desenvolvimento de técnicas que propiciam um melhor entendimento dos padrões presentes em dados financeiros. O autor ainda menciona que o resultado de tais estudos permite a identificação e previsão de sistemas intrincados, considerando a existência de relações não lineares dinâmicas nos dados, cuja característica os modelos lineares tradicionais não conseguem replicar. Assim, as RNA têm contribuído diretamente para esses avanços quando são utilizadas para a construção de modelos preditivos.

Dessa forma, o presente trabalho utiliza RNA na criação de um modelo preditivo para a cotação dos preços máximos e mínimos de ações de importantes empresas estatais brasileiras, a saber: Petróleo Brasileiro S. A. (PETROBRÁS [PETR4]), Centrais Elétricas Brasileiras S. A. (ELETROBRÁS [ELET6]), Banco do Brasil S. A. (BBAS3), Telecomunicações Brasileiras S. A. (TELEBRÁS [TELB4]) e Companhia de Saneamento de Minas Gerais (COPASA [CSMG3]).

A seleção das empresas estatais supracitadas justifica-se pelo fato do contexto deste trabalho ser a gestão pública. Fatores como influência internacional, tempo de existência, atividade econômica/financeira e relevância social no panorama brasileiro também foram considerados.

1.1 Problema de pesquisa

A necessidade de criação de modelos de previsão que gerem prognósticos confiáveis do comportamento de preços de ações financeiras nas bolsas de valores cria o seguinte problema de pesquisa: é possível criar um modelo preditivo baseado em RNA que gere uma satisfatória estimativa do preço de ações financeiras, considerando-se o comportamento histórico de tais ativos negociadas na bolsa de valores oficial brasileira (B3)?

Uma vez que modelos preditivos são muitas vezes construídos utilizando-se modelos estatísticos, a aplicação de RNA é interessante no sentido de testar sua eficiência em relação aos tradicionais métodos empregados nas pesquisas científicas (SANTOS M. A. et al., 2016). Além disso, a criação de um modelo preditivo eficaz pode subsidiar a tomada de decisões por parte de gestores de organizações estatais e de investidores que aplicam seus recursos em tais instituições por intermédio do mercado de ações.

Assim, a investigação da acurácia das RNA aplicada à previsão dos preços máximos e mínimos de ações de empresas estatais brasileiras é interessante no sentido de gerar conhecimento e conclusões para futuras pesquisas que se proponham a utilizar modelos preditivos baseados em ferramentas de RNA.

1.2 Objetivos

Diante do problema de pesquisa formulado supracitado, o presente trabalho tem como objetivo principal:

- Elaborar um modelo que utilize RNA para a previsão dos preços máximos e mínimos de ações de mercado de algumas grandes empresas estatais brasileiras atuais previamente selecionadas.

A partir de valores históricos das negociações de ações na bolsa de valores oficial do Brasil (B3), busca-se comparar os resultados obtidos de modo a indicar a precisão e rigor do modelo proposto baseado em RNA.

Por sua vez, a fim de alcançar o objetivo principal, os objetivos específicos desse trabalho são:

- Elaborar e treinar as RNA do modelo construído utilizando parâmetros comuns de ações negociadas na bolsa de valores oficial brasileira, como os preços de abertura, os preços máximos e mínimos, o índice IBOVESPA e a cotação do dólar americano, nos períodos considerados;
- Construir as RNA do modelo preditivo proposto utilizando arquiteturas do tipo *Multilayer Perceptron* (MLP) e do tipo recorrente *Long Short-Term Memory* (LSTM);
- Comparar os dados históricos das cotações das ações das empresas estatais utilizadas na pesquisa com os resultados obtidos através do modelo preditivo proposto utilizando-se RNA, pontuando-se a acurácia das redes do tipo MLP e do tipo recorrente LSTM mediante a avaliação de métricas de erros comumente utilizadas em estudos estatísticos.

1.3 Justificativa da pesquisa

Santos M. A. et al. (2016) explanam que as RNA imitam o cérebro humano ao reunir evidências empíricas e ao armazenar e permitir o uso de conhecimento experimental. Similarmente, Carvalho et al. (2018) apontam que as RNA objetivam simular sistemas biológicos como, por exemplo, o cérebro humano, e possuem a função principal de armazenar e disponibilizar informações.

Dessa maneira, como justificativa prática, a criação de um modelo preditivo eficaz baseado em RNA pode gerar uma base de conhecimento reutilizável para uma gama de problemas complexos equivalentes, diminuindo o tempo e recursos de buscas por soluções que já estarão prontamente disponíveis. Especificamente no contexto das finanças públicas, tal modelo é extremamente útil ao auxiliar os gestores das instituições e os investidores na tomada de decisões estratégicas num campo tão instável e dinâmico como o mercado de ações financeiras.

Além disso, no campo prático, com o presente trabalho busca-se apresentar a utilidade de modelos preditivos na resolução de problemas relacionados à previsão do comportamento dos preços máximos e mínimos de ações nas bolsas de valores oficiais, mais particularmente na B3, de modo a permitir que os investidores e integrantes do cenário financeiro possam melhorar seus processos decisórios utilizando ferramentas computacionais, métodos e algoritmos apropriados.

No âmbito teórico, a pesquisa gera a expectativa de ampliar o estudo relativo ao tema abordado, visto que busca gerar conhecimento e conclusões para futuras pesquisas que se proponham a utilizar modelos preditivos baseados em ferramentas de RNA aplicados ao campo das finanças. Ademais, almeja gerar conhecimento que subsidie a tomada de decisões por parte de gestores de organizações públicas e de investidores que aplicam seus recursos em tais instituições por intermédio do mercado de ações, agregando tal conhecimento aos trabalhos correlatos atualmente disponíveis na literatura.

Complementarmente, a justificativa social deste trabalho dá-se pelo fato de que o suporte para decisões corretas por parte dos gestores de empresas públicas e sociedades de economia mista, as quais são mantidas parcialmente com os recursos gerados pelos próprios cidadãos brasileiros, contribui para a melhoria da qualidade do gasto público e, conseqüentemente, para a sociedade como parte diretamente atingida por programas e políticas públicas.

1.4 Estrutura da dissertação

Após esta introdução, a dissertação apresenta o referencial teórico utilizado para a realização do trabalho. Apresentam-se os principais conceitos acerca das RNA e o seu crescente uso no contexto de modelos preditivos para o comportamento de ações no cenário das finanças. Um panorama geral do mercado de ações e investimentos financeiros, bem como os principais critérios e parâmetros utilizados no seu funcionamento, também são apresentados. Os conceitos de empresa pública e sociedade de economia mista, bem como suas principais características e definições, são abordados e explicitados, uma vez que foram escolhidas ações financeiras de cinco importantes empresas estatais brasileiras para a pesquisa.

Em seguida, descreve-se a metodologia utilizada na pesquisa, focando-se na criação do modelo preditivo baseado em RNA para a comparação com os resultados históricos reais obtidos da base de dados da B3 concernente às ações das empresas estatais escolhidas para o estudo. Finalmente, elencam-se os resultados alcançados e as considerações finais, destacando-se as conclusões obtidas a partir da análise comparativa do modelo preditivo baseado em RNA do tipo MLP e RNA recorrentes do tipo LSTM.

Há uma parte específica para a apresentação do ambiente MATLAB e um breve tutorial sobre a sua utilização básica, inserido como apêndice ao texto principal. A presença de tal apêndice é motivada pela necessidade de familiarização do referido ambiente caso o leitor decida reproduzir o trabalho realizado na presente pesquisa, mais especificamente a construção do modelo preditivo baseado em RNA do tipo MLP.

No referido apêndice, a *toolbox* NNTOOL (*Neural Network Tool*) do ambiente MATLAB é apresentada, uma vez que foi utilizada para a criação do modelo preditivo baseado em RNA do tipo MLP descrito neste trabalho. Um passo-a-passo de como criar, treinar e validar uma rede neural artificial MLP genérica é mostrado utilizando-se a referida *toolbox*, de modo a capacitar o leitor a entender como o modelo baseado em RNA MLP desta pesquisa foi construído com o auxílio da ferramenta computacional citada.

Ademais, o Quadro 1 mostra, esquematicamente, a estrutura desta dissertação, conforme exposto acima, destacando cada capítulo e os respectivos assuntos apresentados em cada um deles.

Quadro 1 - Estrutura da dissertação

Capítulo	Assuntos apresentados
Introdução	Problema de pesquisa Objetivos Justificativa da pesquisa Estrutura da dissertação
Referencial teórico	Mercado de capitais e bolsa de ações oficial brasileira Empresas públicas e sociedades de economia mista Redes Neurais Artificiais Pesquisas empíricas relacionadas
Aspectos metodológicos	Classificação da pesquisa Técnica de coleta de dados Análise dos dados Construção do modelo preditivo baseado em RNA
Resultados	Análise dos resultados do modelo preditivo utilizando RNA Comparação dos resultados das RNA do tipo MLP e do tipo recorrente LSTM
Conclusão	Alcance dos objetivos Contribuição teórica/prática Limitações da pesquisa Proposta de trabalhos futuros

Fonte: Elaborado pelo autor.

A seguir, o próximo capítulo apresenta a fundamentação teórica da presente dissertação, de modo a respaldar a investigação realizada e permitir um melhor entendimento das técnicas utilizadas na criação de modelos preditivos baseados em RNA para o suporte decisório nas negociações de ações no mercado financeiro. Tal referencial teórico utiliza importantes trabalhos de autores históricos no contexto das redes neurais e pesquisas atuais de acadêmicos que também utilizaram RNA como cerne de investigações e soluções aplicadas à área de finanças e diversas outras.

2 REFERENCIAL TEÓRICO

Segundo Marconi e Lakatos (2003), o referencial teórico possibilita a verificação do problema de pesquisa sob o aspecto da teoria e de estudos e pesquisas já realizados. Caracteriza-se por uma revisão sistemática e aprofundada de trabalhos existentes no meio científico que fundamentam e embasam a pesquisa que está sendo executada, de modo a nortear o trabalho e lhe conferir rigor acadêmico e científico.

Desse modo, as próximas partes apresentam os conceitos teóricos dos principais itens constituintes deste trabalho, conforme encontrados nos trabalhos de autores recentes, os quais são devidamente citados no texto e indicados nas referências bibliográficas.

2.1 Mercado de capitais e Bolsa de ações oficial brasileira

Fernandes (2018) explicita que o sistema financeiro é composto por um conjunto de organizações, concentradas nos bancos, os não bancos e o mercado financeiro. Nesse âmbito, segundo o autor, o mercado financeiro é formado pelo mercado monetário, cambial, de títulos, acionário e os derivativos. Sua natureza é dinâmica e comumente envolve riscos e incertezas.

Nessa perspectiva, corrobora Suzart (2013) citando que, essencialmente, nos mercados de capitais, ocorrem as negociações de títulos patrimoniais que concedem a participação no capital social das organizações. Por sua vez, as negociações de títulos de dívida entre dois ou mais agentes econômicos acontece nos mercados de títulos de dívidas.

Suzart (2013, p. 48) ainda acrescenta que um mercado de títulos “representa um mercado onde são negociados instrumentos financeiros, nos quais as entidades emissoras se comprometem a remunerar em parcelas, prazos e formas pré-fixados as entidades compradoras [...]”.

Nesse contexto, os títulos mais negociados são aqueles que representam o capital das empresas e são denominados de ações. Conforme explica Silva A. R. (2017), em termos gerais, uma determinada ação é um valor mobiliário que corresponde à menor fração do total do capital de uma sociedade anônima emissora. O detentor da ação torna-se um acionista da sociedade que emitiu a respectiva ação.

Um título emitido e negociado num mercado de ações pode ter natureza particular ou privada. Como explicado por Lopes et al. (2007), os títulos públicos são emitidos pelo governo federa, estadual ou municipal e os títulos privados são emitidos por empresas e bancos com a finalidade de financiamento de suas atividades.

Nesse cenário, surge a figura do investidor em ações que, conforme salienta Cunha (2012), passa a ser um sócio da empresa ao adquirir tais ativos. O autor explicita que no procedimento de abertura de seu capital, a empresa busca ampliar seu quadro de sócios com os novos compradores das ações. Assim, os investidores se tornam parceiros e proprietários de uma parte da instituição, proporcionalmente ao montante de ações que obtêm (CUNHA, 2012). Pela participação dos acionistas, as empresas obtêm novos recursos, os quais financiam novos investimentos e proporcionam o desenvolvimento das mesmas.

Um aspecto interessante no processo decisório de investir ou não em ações de uma empresa, segundo Cunha (2012), é que, para os investidores, o valor da organização dependerá de informações da indústria e de informações próprias da companhia.

Como parte desse universo dinâmico, uma peça fundamental é a denominada bolsa de valores. Conforme cita Dutra (2008), devido a constantes mudanças no cenário financeiro, o conceito de bolsa de valores é amplo e diverso. Segundo ele, uma definição suficiente é:

As bolsas são entidades [autorreguladoras] (na maioria das vezes por imposição legal, como no caso brasileiro) e, como tais, estabelecem padrões de listagem para as companhias abertas, regras de comportamento para os participantes, supervisionam a negociação dos ativos financeiros admitidos à negociação e realizam inspeções periódicas nos seus membros, dentre outras tarefas (DUTRA, 2008, p. 14).

Nesse sentido, Giacomel (2016, p. 18) cita que o fato de um país possuir diversas empresas de capital aberto, torna necessária a existência de um lugar em comum para a negociação de suas ações: a bolsa de valores. É na bolsa de valores onde ocorre toda a movimentação e negociação das ações das empresas e instituições participantes devidamente credenciadas.

Silva A. R. (2017) explica que cada sessão de compra e venda é denominada pregão e, atualmente, em sua grande maioria, é realizada de maneira eletrônica através dos sítios oficiais das bolsas de valores ou das instituições financeiras previamente autorizadas. O autor ensina que “o pregão eletrônico é o sistema pelo qual são desenvolvidas as atividades de negociação, por meio de transmissão e recepção eletrônica de dados entre os intermediários” (SILVA A. R., 2017, p. 27).

Vieira e Corrêa (2002) apontam que o investidor em ações busca otimizar três aspectos básicos em um investimento: retorno, prazo e proteção. Dessa forma, associado a um investimento há sempre um grau de risco, estando a rentabilidade esperada diretamente relacionada a ele. Logo, o investidor deve avaliar o grau de risco associado a uma ação e decidir se está disposto a enfrentá-lo na busca por lucratividade. Conforme cita Fernandes (2018), os

investidores profissionais apenas realizarão os seus investimentos quando conseguirem definir suas expectativas de retorno fornecidas pelos riscos associados às operações, de modo a assumirem determinados níveis de incertezas relacionados ao processo decisório.

Nesse âmbito, é importante salientar que o investimento imobiliário (como terrenos e edificações) sempre intenciona a transferência imediata de propriedade. Conforme menciona Nogueira Junior (2008, p. 19), um ativo imobiliário "representa um instrumento de obtenção de recursos de longo prazo que são aplicados na construção ou na aquisição de empreendimentos imobiliários". Como principais exemplos desses recursos aparecem os imóveis residenciais, edifícios e semelhantes.

Por sua vez, o investimento mobiliário sempre visa a liquidez imediata de um ativo. Segundo Mattos Filho (1985, apud PAVIA, 2015), os valores mobiliários são investimentos de empréstimo ou especulação ofertados ao público, em que os investidores não possuem controle direto, cujas aplicações são realizadas em dinheiro, bens ou serviços, visando o lucro.

Como parte desse cenário, a B3 (Brasil, Bolsa, Balcão), antiga BM&FBOVESPA, é atualmente a bolsa de valores oficial brasileira. Silva A. R. (2017) aponta que é correto afirmar que, no Brasil, existe somente uma bolsa de valores que realiza a negociação de valores mobiliários: a B3. O mesmo autor indica que, atualmente, a B3 é o único espaço para a realização de negociações de ações no Brasil, sendo responsável por todos os registros e negociações de ativos no mercado de ações brasileiro, caracterizando um monopólio autorregulador.

É interessante ressaltar que a própria B3 negocia suas ações na sua plataforma eletrônica de negócios. As empresas devidamente credenciadas e registradas são autorizadas a transacionar seus títulos, ofertando-os a investidores interessados. Nesse cenário, aparecem empresas privadas e públicas. Dutra (2008) explica que as corretoras que gerenciam as ações de seus investidores pagam à B3 mensalidades para a manutenção do acesso aos sistemas específicos de negociação, em valores segundo o volume de negócios gerado para cada uma delas.

Considerando-se a negociação de títulos públicos, Suzart (2013) menciona que nesse panorama existe o mercado primário e secundário. O autor aponta que a oferta de títulos por um ente público implica que as transações ocorrem no denominado mercado primário, e que tal definição é típica do mercado brasileiro, uma vez que o governo federal negocia grande parte de seus títulos por intermédio de oferta pública ou em operações compromissadas. Nesse caso, quem emite os títulos exerce grande interferência nos preços dos mesmos (SUZART, 2013).

Por outro lado, as transações no mercado secundário ocorrem quando os agentes negociam títulos diretamente entre si, sem a participação do emissor. Nesse mercado, normalmente, a entidade emissora não consegue influenciar os preços dos títulos (SUZART, 2013).

Analogamente, Cunha (2012) explicita que na emissão primária de ações, a empresa emite e vende novas ações ao mercado. O vendedor é a própria instituição e, portanto, os recursos captados são direcionados para ela. Em contrapartida, na emissão secundária de ativos, é o sócio e/ou empreendedor que vende suas próprias ações já existentes. Neste caso, o mesmo é quem receberá os recursos arrecadados (CUNHA, 2012).

É importante salientar que, como Suzart (2013) explica, as definições elencadas acima são diferentes para os mercados de capitais e crédito para entidades privadas. Em tais mercados as negociações primárias se caracterizam pela primeira negociação de um determinado título, realizada com a participação do seu emissor. Após a emissão, todas as negociações subsequentes são secundárias (SUZART, 2013).

Para fins de análise do presente trabalho, foram consideradas as séries históricas de negociações de ações de cinco grandes empresas estatais brasileiras, conforme os pregões eletrônicos ocorridos na plataforma eletrônica da B3. A parte seguinte elenca os principais conceitos e definições relacionados às empresas públicas e sociedades de economia mista.

2.2 Empresas Públicas e Sociedades de Economia Mista

Posto que as instituições escolhidas para a presente pesquisa são empresas públicas ou sociedades de economia mista, faz-se necessário elencar as principais definições, atributos e características de tais organizações. Também é interessante explicitar as semelhanças e diferenças dessas organizações.

Pietro (2018) apresenta que as empresas públicas e sociedades de economia mista surgem como novas medidas de descentralização dos serviços públicos. A autora explica que tais organizações são criadas mediante leis, adquirindo o direito de prestação de serviços específicos. Ademais, Carvalho Filho (2015, p. 515) explica que, “embora sejam de categorias jurídicas diversas, as empresas públicas e as sociedades de economia mista devem ser estudadas em conjunto” devido aos pontos em comum entre tais instituições.

Carvalho Filho (2015, p. 515) ainda ensina que tanto as empresas públicas, quanto as sociedades de economia mista, são entidades “dotadas de personalidade jurídica de direito privado e delas se vale o Estado para possibilitar a execução de alguma atividade de seu

interesse com maior flexibilidade”. O autor aponta que existe uma relação de domínio entre Estado e tais organizações.

Melo Neto (2016) contribui com a definição de empresa pública ao mencionar que envolve duas dimensões importantes: a primeira está relacionada à natureza econômica e a segunda ao grau de controle exercido pelo governo em tais organizações. O autor ainda cita que as empresas estatais são aquelas entidades sob o controle significativo do governo e que possuem a maior parte de suas receitas oriundas da comercialização de produtos e serviços. Dessa maneira, é interessante notar que, excluem-se como empresas estatais as universidades públicas, fundos de pensão e afins, uma vez que a maior parte de suas receitas são advindas de transferências governamentais, contribuições sociais, repasses de impostos e outros (MELO NETO, 2016).

Nesse contexto, Carvalho Filho (2015) cita os seguintes exemplos de empresas estatais no âmbito federal: a Empresa Brasileira de Correios e Telégrafos, a Casa da Moeda do Brasil, a FINEP (Financiadora de Estudos e Projetos), o BNDES (Banco Nacional de Desenvolvimento Econômico e Social), a Caixa Econômica Federal e o SERPRO (Serviço Federal de Processamento de Dados). É importante ressaltar que há empresas públicas federais, estaduais e municipais.

A fim de classificar as empresas públicas, Schirato (2005) menciona que é necessário considerar as atividades que elas desempenham. O autor cita que a maioria das empresas estatais foi constituída ou adquirida pelo poder público, com o intuito de prestar serviços públicos. Nesse caso, o governo pode optar por prestar diretamente tais serviços ou criar uma entidade em sua administração indireta sob seu controle para desempenhá-los. Pode, também, proceder à outorga de concessão ou permissão para que terceiros possam desempenhar tais atividades (SCHIRATO, 2005).

Além disso, o autor supracitado explica que as empresas públicas exploradoras de atividades econômicas são: as constituídas pela União com a finalidade de exploração de atividades consideradas monopólios federais; as instituições financeiras criadas por qualquer ente federativo; as constituídas por qualquer ente federativo com a função de explorar atividades essenciais ao interesse coletivo; as constituídas pela União com a finalidade de exploração de atividades ligadas à segurança nacional (SCHIRATO, 2005).

Referente à concessão de serviços públicos, Pietro (2018, p. 378) ensina que se trata do contrato administrativo no qual a Administração Pública encarrega a outro a execução de serviço público, o qual assume as responsabilidades inerentes a tal serviço, sendo assegurada a respectiva remuneração. Tal concessão vem acompanhada de cláusulas que dão à concedente

os direitos de alteração e rescisão unilateral do contrato, bem como o direito de fiscalização da execução do serviço e a aplicação de penalidades, quando necessária.

Ainda acerca da concessão de serviços públicos, Pietro (2018, p. 379) explicita suas principais peculiaridades, a saber:

1. A concessão do serviço público existe somente quando o Estado possui a titularidade do mesmo, de modo que “a lei define determinadas atividades como sendo serviços públicos, permitindo que sejam executadas diretamente ou mediante concessão ou permissão”;
2. “O poder concedente só transfere ao concessionário a execução do serviço, continuando titular do mesmo, o que lhe permite dele dispor de acordo com o interesse público [...]”;
3. “A concessão tem que ser feita sempre mediante processo de licitação, consoante exigido pelo artigo 175 da Constituição Federal de 1988 [...]”;
4. “É cabível o procedimento de manifestação de interesse como meio para subsidiar a Administração Pública na realização de projetos, levantamentos, investigações ou estudos, por pessoa física ou jurídica de direito privado”;
5. “O concessionário executa o serviço em seu próprio nome e corre os riscos normais do empreendimento; ele faz jus ao recebimento da remuneração, ao equilíbrio econômico da concessão, e à inalterabilidade do objeto”;
6. A tarifa, se cabível, possui natureza de preço público e é fixada pelo contrato;
7. O usuário possui o direito de prestação de um serviço adequado;
8. “Na concessão devem ser observados os princípios da continuidade do serviço público, da mutabilidade do regime jurídico, da igualdade de tratamento dos usuários”;
9. “A responsabilidade do concessionário por prejuízos causados a terceiros, em decorrência da execução de serviço público, é objetiva”.

Em relação à 3ª peculiaridade do contrato de concessão de serviços públicos, conforme citado acima, Pietro (2018) enfatiza que, de acordo com o artigo 175 da Constituição Federal de 1988 (CF88), é incumbência do poder público, na forma da lei, diretamente ou sob regime de concessão ou permissão, sempre por meio de licitação, prestar serviços públicos. A autora também menciona que os serviços públicos são assim denominados porque são reservados à titularidade exclusiva do Estado, que pode, se necessário, atribuir a sua execução ao particular que deseje prestá-lo, não para atender à coletividade, mas às suas próprias necessidades.

É importante assinalar, conforme mencionado por Carvalho Filho (2015), que nem todos os serviços públicos podem ser exercidos por sociedades de economia mista e empresas públicas, mas somente aqueles que poderiam ser pela iniciativa privada. Dessa maneira, excluem-se do rol de tais serviços públicos aqueles que são ditos inerentes ao Estado como, por exemplo, a prestação de justiça, a segurança pública e a defesa da soberania nacional. Também se excluem aqueles outros que possuem acentuada especificidade social e que, devido a isso, se apresentam deficitários como, por exemplo, serviços de assistência social a determinadas categorias sociais ou os de apoio a regiões desfavorecidas.

Ademais, Pietro (2018) ensina que empresa estatal ou governamental designa o conjunto de organizações civis ou comerciais em que o Estado possui o controle acionário, de maneira direta ou por meio de outra organização da administração indireta, incluindo empresa pública, sociedade de economia mista e suas subsidiárias. Nesse sentido, a autora explica que a empresa estatal que realiza um serviço público atua como uma concessionária de tal serviço, estando constitucionalmente sujeita a deveres, política de tarifas, manutenção e demais princípios que regem a prestação adequada dos serviços públicos.

Citando as peculiaridades das empresas públicas, Pietro (2018) menciona que: são pessoas de direito privado; têm suas criações autorizadas por leis; possuem patrimônio próprio; possuem capital totalmente mantido pela União, Estados, Distrito Federal ou Municípios, sendo possível a participação de outras pessoas jurídicas de direito público ou de organizações da administração indireta pertencentes a qualquer esfera governamental, sob a condição de que a maioria do capital sujeito a voto permaneça em propriedade da União ou suas entidades.

Pietro (2018) ainda acrescenta que o objetivo da criação de uma empresa pública é a exploração de atividade econômica de produção, comercialização de bens ou prestação de serviços, mesmo se tal atividade econômica for monopólio da União.

Nessa perspectiva, Oliveira (2017) acrescenta que as empresas públicas possuem uma dualidade em sua ação, variando entre a estatal e a empresarial. No contexto estatal, necessita alcançar objetivos ligados à política e no contexto empresarial precisa atingir objetivos inerentes às empresas privadas comuns, isto é, índices de rentabilidade e lucro (OLIVEIRA, 2017).

Carvalho Filho (2015) aponta que a CF88 faz referência direta a sociedades de economia mista e empresas públicas quando trata dos princípios normativos da atividade econômica. Segundo o autor, no art. 173, § 1º, a exploração de atividade econômica enseja a sujeição ao regime próprio das empresas privadas, incluindo obrigações tributárias e trabalhistas. Já no § 2º do mesmo artigo da carta magna brasileira, tais entidades são igualadas às empresas privadas

no que concerne aos privilégios fiscais, de modo a indicar a vedação de distinções fiscais que não se apliquem ao setor privado.

No que concerne às sociedades de economia mista, Carvalho Filho (2015) apresenta que são sociedades por ações, apropriadas para operações empresariais, nas quais as ações estão distribuídas entre particulares e a União. O autor ainda explica que tais organizações são pessoas jurídicas de direito privado e integram a Administração Indireta do Estado. São entidades criadas mediante autorização legal, tendo a forma de sociedades anônimas em que o controle acionário pertence ao Estado. Seu objetivo, via de regra, é a exploração de atividades econômicas e, em alguns casos, a prestação de serviços públicos.

Pietro (2018) ainda ensina que a sociedade de economia mista, de forma análoga à empresa pública, somente pode ser instituída com a finalidade de exploração de atividade econômica de produção, comercialização de bens ou prestação de serviços, mediante justificativa de relevante interesse público ou razão de segurança nacional. Além disso, a autora aponta que o controle acionário majoritário de uma sociedade de economia mista é detido pelo poder público.

Ademais, Carvalho Filho (2015) apresenta alguns exemplos de sociedades de economia mista federais, a saber: Banco do Brasil S.A., Banco da Amazônia S.A. e PETROBRÁS. O autor cita que ainda há diversas outras vinculadas às administrações municipais e estaduais.

Carvalho Filho (2015) ainda menciona que a definição legal das empresas públicas e das sociedades de economia mista evidencia que a execução de atividades econômicas é o objetivo de sua instituição. Dessa maneira, conforme citado pelo autor, tais organizações são ferramentas de atuação do Estado na função de empresário.

Quanto às empresas subsidiárias, Pietro (2018) explica que são instituições em que o controle acionário é desempenhado por empresa pública ou sociedade de economia mista, permanecendo a União ou suas entidades com o controle indireto. A autorização para a criação de tais organizações também depende de autorização legislativa, de acordo com o artigo 37, inciso XX da CF88.

Nesse sentido, Carvalho Filho (2015) também contribui explicando que as empresas subsidiárias possuem o controle e a gestão de suas atividades atribuídas a empresa pública ou sociedade de economia mista inteiramente criadas pelo Estado. Dessa forma, as empresas controladas originalmente pelo Estado, que passam a gerir outras empresas públicas ou de sociedades de economia mista, são denominadas empresas primárias. O autor ainda menciona que é comum a denominação de sociedade ou empresa de primeiro grau para a empresa primária e de sociedade ou empresa de segundo grau para a empresa subsidiária.

Dessa forma, entende-se que as empresas diretamente controladas pela União, Estados, Municípios ou Distrito Federal são as empresas públicas e sociedades de economia mista, ao passo que as que são indiretamente controladas são as subsidiárias, onde o controle direto é exercido por sociedade de economia mista ou por empresa pública (PIETRO, 2018).

Carvalho Filho (2015) cita mais um aspecto importante sobre as empresas subsidiárias, a saber, que são controladas indiretamente pelo ente federativo que criou a entidade primária. Assim, a subsidiária possui o único objetivo de se empenhar num segmento específico da entidade primária. Ademais, é parte integrante da Administração Indireta, sendo também controlada pelo Estado.

É interessante a explicação de Carvalho Filho (2015) sobre os bens que inicialmente integram o patrimônio das empresas públicas e sociedades de economia mista. O autor destaca que geralmente provêm do ente federativo instituidor. Tais bens, enquanto pertenciam à entidade criadora, eram qualificados como bens públicos. Porém, uma vez que são transferidos ao patrimônio das entidades criadas, tornam-se bens privados, sujeitos à sua própria administração.

Destacando as similaridades entre empresas públicas e sociedades de economia mista, Pietro (2018) elenca as seguintes: são criadas ou extintas por meio de autorização legal; possuem personalidade jurídica de direito privado; estão sujeitas ao controle estatal; possuem supressão parcial do regime de direito privado por regras do direito público; são vinculadas às finalidades nas normas que as instituíram; desempenham atividade de caráter econômico.

Ainda referente às semelhanças entre tais organizações, Carvalho Filho (2015) contribui dizendo que as sociedades de economia mista e empresas públicas andam de mãos dadas, sendo semelhantes em seus perfis e coligadas quanto aos objetivos visados pelo Estado. Dessa maneira, praticamente não há características que levem o Estado a optar por uma outra. O autor também cita que tais instituições traduzem a ideia básica do Estado-empresário, que objetiva aliar uma atividade econômica com outras de interesse coletivo.

Referente às principais diferenças entre empresas públicas e sociedades de economia mista, Pietro (2018) menciona duas: o formato da organização e a constituição do capital. Concernente à forma de organização, a autora explica que o artigo 5º do Decreto-lei nº 200/67 determina que a sociedade de economia mista seja constituída sob a forma de sociedade anônima e a empresa pública sob qualquer forma permitida em lei. Quanto à composição do capital, a sociedade de economia mista constitui-se de capital privado e público, ao passo que a empresa pública se constitui apenas de capital público.

Sobre a diferença na composição do capital, Carvalho Filho (2015) cita que nas sociedades de economia mista, o capital é formado pela união de recursos provenientes das pessoas de direito público ou de recursos da iniciativa privada. Dessa forma, as ações são distribuídas entre o ente governamental e os particulares.

Ademais, referente à composição do capital das empresas públicas, o autor supracitado ensina que somente é admitida a participação do capital de pessoas administrativas, seja qual for seu nível federativo ou sua natureza jurídica (pública ou privada). Assim, pessoas da iniciativa privada, físicas ou jurídicas, são impedidas de participar do capital integrante das empresas públicas (CARVALHO FILHO, 2015).

Destacando as formas de empresas públicas, Pietro (2018) indica que foram criadas três inéditas, a saber: sociedade unipessoal, cuja sociedade precisa possuir um órgão necessário nesse tipo de pessoa jurídica, que é a assembleia geral; sociedade pluripessoal, cujo capital pertence à União (sócia majoritária) e a outras pessoas políticas ou administrativas; empresa pública unipessoal, que equivale à empresa individual do direito privado, com a diferença de que a empresa pública tem personalidade jurídica e a constituição de empresa individual, no direito privado, não acarreta a criação de pessoa jurídica.

Diante do exposto anteriormente, Pietro (2018) indica que a diferença entre a empresa pública unipessoal e a empresa instituída sob a forma de sociedade unipessoal é que, na segunda, há a existência de uma assembleia geral que manifesta a vontade do ente estatal.

Pietro (2018) observa que não basta apenas a participação dominante do poder público na organização para que ela seja considerada uma sociedade de economia mista. É também necessário que o Estado participe na gestão da organização de modo a tornar a mesma uma ferramenta de ação do próprio Estado, apresentada por sua lei instituidora. A falta de tal prerrogativa configura uma empresa estatal, mas não uma sociedade de economia mista.

Carvalho Filho (2015) chama a atenção para a hipótese de extinção das empresas públicas e das sociedades de economia mista. Assim como acontece no ato de autorização para sua criação, a extinção também requer lei autorizadora. Isso significa que o Poder Executivo não possui competência exclusiva para extinguir tais entidades.

Citando a função social das empresas públicas e das sociedades de economia mista, Pietro (2018) apresenta que, quer sejam prestadoras de atividade econômica, serviço público comercial ou industrial, em caráter de monopólio ou em competição direta com a iniciativa privada, o atendimento da função social é obrigatório, uma vez que os objetivos sociais são a motivação para que o Estado exerça atividade econômica. Dessa forma, sua função social

primordial é realizar o interesse coletivo ou a realização obrigatória de ações inerentes à segurança nacional.

No que concerne ao pessoal das empresas públicas e das sociedades de economia mista, Carvalho Filho (2015) destaca que são subordinados ao regime trabalhista comum expressos na Consolidação das Leis do Trabalho (CLT). Dessa maneira, o vínculo jurídico firmado entre os empregados e tais organizações tem natureza de contrato de trabalho típico. Além disso, os cargos de presidente ou direção dessas organizações equivalem a cargos de confiança e são ocupados mediante padrões da autoridade pública a que estão vinculadas. Ao integrarem o quadro da organização, mesmo que o regime de trabalho seja temporário, submetem-se às leis trabalhistas conforme a CLT.

Ademais, como citado por Oliveira (2017), nas empresas públicas é possível nomear livremente seus dirigentes ocupantes de postos de direção, chefia e assessoramento. Historicamente, os postos de direção são ocupados por escolhidos pela Administração Direta, cujas decisões, quase sempre, possuem o viés político.

Carvalho Filho (2015) ainda menciona que o ingresso dos empregados das empresas públicas e das sociedades de economia mista se dá mediante aprovação em concurso público, conforme especificado no artigo 37, inciso II da CF88. Ademais, para tais empregados não se aplicam regras especiais dos servidores públicos estatutários como, por exemplo, a estabilidade adquirida. Nesse caso, as regras da CLT se aplicam na formação do contrato e na rescisão do mesmo.

Pietro (2018, p. 626) também menciona que é importante perceber a responsabilidade social e prática de sustentabilidade que alcançam as empresas públicas, sociedades de economia mista e suas subsidiárias. Além do mais, a autora cita que se admite a tais entidades atuarem em “atividades culturais, sociais, esportivas, educacionais e de inovação tecnológica, mediante convênio ou contrato de patrocínio com pessoa física ou com pessoa jurídica”.

Como exposto, devido ao fato de as empresas públicas, sociedades de economia mista e suas subsidiárias estarem inseridas no contexto financeiro, tais organizações emitem e negociam suas ações nas bolsas de valores, tanto na B3 quanto em diversas bolsas internacionais.

Nesse âmbito, para o presente trabalho foram escolhidas cinco importantes empresas estatais brasileiras, a saber: Petróleo Brasileiro S. A. (PETROBRÁS), Centrais Elétricas Brasileiras S. A. (ELETROBRÁS), Banco do Brasil S. A., Telecomunicações Brasileiras S. A. (TELEBRÁS) e Companhia de Saneamento de Minas Gerais (COPASA), sendo que tais

instituições atuam em diferentes segmentos de mercado. As ações negociadas na B3 consideradas no estudo são, respectivamente: PETR4, ELET6, BBAS3, TELB4 e CSMG3.

O Banco do Brasil S. A. é um banco público organizado sob a forma de sociedade de economia mista. (SANTOS, L. L. A. A., 2016). Conforme cita Araujo (2017), é uma empresa estatal cuja participação da União representa pouco mais de 60% de suas ações, possuindo unidades no Brasil e em diversos outros países. A referida autora destaca sua influência no cenário nacional ao citar que o Banco do Brasil S. A. é o mais destacado negociador da política de crédito rural do governo brasileiro, sendo responsável pelo pagamento e provimentos necessários à efetivação do orçamento geral da União, mediante a aquisição e financiamento de negócios no contexto das exportações. Ademais, é o receptor de créditos do Tesouro Nacional e demais entidades federais.

Por sua vez, quanto à Telecomunicações Brasileiras S. A. (TELEBRÁS), Granato (2011) menciona que é uma sociedade de economia mista, ligada ao Ministério das Comunicações, com atribuições de planejamento, implantação e operação do SNT (Sistema Nacional de Telecomunicações). Citando sua grande atuação em âmbito nacional, o referido autor destaca que a TELEBRÁS caracteriza-se como um monopólio estatal no campo das telecomunicações, tendo absorvido diversas companhias estaduais e sendo responsável pela implementação da rede privada do governo federal, provimento de infraestrutura e de redes de assistência a serviços de telecomunicações, prestação de serviços de conexão em banda larga para utilizadores finais em locais em que não exista oferta apropriada desse serviço (GRANATO, 2011).

Quanto à Companhia de Saneamento de Minas Gerais (COPASA), Muniz (2016) apresenta que é também uma empresa de economia mista, cujas atividades principais são o fornecimento de serviços em abastecimento de água, esgotamento sanitário e resíduos sólidos. Sobre a importância das suas atividades no cenário regional e nacional, a autora também menciona que o tratamento da água necessita de altos investimentos nos processos de produção, armazenamento, distribuição e controle de qualidade. A fim de garantir a quantidade e qualidade compatíveis com os padrões mundialmente estabelecidos, a COPASA realiza um controle rigoroso e investe recursos em programas para a preservação das fontes de água que suprem o abastecimento público.

Muniz (2016) ainda cita que as atividades da COPASA atingiram em 2016 quase seis milhões de pessoas somente na região metropolitana de Belo Horizonte, a qual, à época, era o terceiro maior agrupamento urbano do Brasil, ficando atrás apenas do eixo Rio-São Paulo (MUNIZ, 2016).

Referente à ELETROBRÁS, ao ser criada, recebeu a coordenação da evolução da indústria de energia elétrica, criação de taxas e busca de recursos nos fundos multilaterais de investimentos para financiar o crescimento da capacidade de geração energética (PAGLIARDI; DIAS, 2011). É uma empresa de economia mista, de capital aberto e com ativos negociados em bolsas de valores. Também atua na coordenação financeira, técnica e administrativa no ramo de energia elétrica (SABINO, 1999).

No contexto social, a ELETROBRÁS fomenta projetos de educação, cultura, esportes e inclusão social (PEREIRA, 2017). A empresa também tem atuado no cenário internacional, conforme mostrado no trabalho de Bisetto (2018), onde destaca-se a parceria da estatal brasileira com o Uruguai.

Sabino (1999) também menciona que, no conjunto de suas principais atividades, inclui-se o planejamento, a gestão ambiental, a criação de fontes alternativas, intercâmbio internacional e coordenação financeira e econômica do setor elétrico nacional. Assim, percebe-se a sua importância estratégica para a conjuntura nacional e internacional.

No que concerne à PETROBRÁS, conforme explicita Chevarria (2007), é uma empresa de economia mista, cujo controle pertence ao governo federal brasileiro. Tal instituição integra o setor de gás e petróleo, com atuação nos segmentos de exploração e produção de petróleo. O autor ainda menciona que a quebra do monopólio das operações ligadas ao petróleo brasileiro impulsionou a busca da PETROBRÁS por mercados externos e o desenvolvimento de novas tecnologias de ponta (CHEVARRIA, 2007).

Ademais, no âmbito nacional, a PETROBRÁS é uma empresa pública que, sendo a maior operadora dos campos do pré-sal, torna-se a principal investidora em pesquisa e desenvolvimento no território brasileiro (SCHMIDT, 2017). Citando a importância estratégica da PETROBRÁS, Schmidt (2017, p. 26) também menciona que "a riqueza gerada pode ser fonte de grandes investimentos em saúde, educação e infraestrutura", gerando efeitos positivos internos e externos. A autora ainda destaca que a empresa investe pesadamente em tecnologia de ponta, o que alavanca diversos outros setores da economia nacional e internacional. Dessa forma, constata-se que a PETROBRÁS é uma empresa muito importante para a economia brasileira e mundial.

Dessa maneira, as empresas estatais escolhidas são organizações importantes no cenário econômico/financeiro, social e cultural do Brasil. Movimentam grande quantitativo financeiro, geram empregos e renda, investem em saúde, educação, infraestrutura, lazer, esporte e tecnologia de ponta. Assim, são entidades significativas no que diz respeito ao contexto nacional e internacional, atuando em diversos panoramas e cenários.

2.3 Redes Neurais Artificiais

Esta seção apresenta uma descrição conceitual das RNA, os seus tipos fundamentais e os processos de aprendizagem e testes. Também são apresentados estudos históricos e recentes encontrados que utilizaram as RNA nas mais diversas áreas de conhecimento, principalmente na criação de modelos preditivos para o mercado financeiro.

2.3.1 Definições e conceitos

As RNA são assunto de interesse em pesquisas desde o ano de 1943, quando Warren McCulloch e Walter Pitts apresentaram um modelo matemático que correspondia ao neurônio biológico. Em seu trabalho, McCulloch e Pitts (1943), os autores descreveram o modelo artificial de neurônio e suas características sem quaisquer técnicas de aprendizagem, o que foi feito somente a partir de 1949 (FERNANDES, 2009).

Uma rede neural artificial é inspirada na biologia, mais notadamente nas características do cérebro humano, cujas principais operações estão centradas nos neurônios. Conforme Haykin (2001), é uma máquina configurada para moldar o modo de funcionamento do cérebro, utilizando componentes eletrônicos e/ou ferramentas computacionais.

Laboissiere, Fernandes e Lage (2015) apresentam que uma característica fundamental das RNA é a capacidade de aprender por intermédio de exemplos, generalizando soluções a partir do conhecimento aprendido. A unidade básica de processamento, armazenamento e aprendizagem das RNA são os chamados neurônios ou nódulos, fazendo uma alusão ao cérebro humano.

Carvalho et al. (2018) acrescentam que as RNA são métodos que aprendem através de funções de aproximação universal, caracterizando-se como um conjunto de modelos não lineares que possibilitam a identificação de padrões em determinados dados. Assim, aprendem através da experiência, associam diferentes padrões e realizam generalizações a novos dados de entrada com base nos padrões anteriores (CARVALHO et al., 2018).

Conforme Haykin (2001), as RNA refletem máquinas projetadas para a modelagem de maneiras como o cérebro humano executa uma tarefa específica ou uma função de empenho, utilizando-se elementos eletrônicos e/ou simulações por programação em computadores digitais, mediante a associação entre neurônios.

Ademais, Lima (2014) destaca que a performance computacional de uma rede neural artificial é caracterizada pela habilidade de aprendizagem e por sua estrutura paralela

distribuída, o que possibilita saídas apropriadas para entradas que não estavam disponíveis durante o procedimento de aprendizado, caracterizando, dessa forma, a generalização. O autor ainda cita propriedades úteis das RNA para a resolução de problemas, a saber: não-linearidade, mapeamento de entrada/saída, adaptabilidade, respostas a evidências, informação contextual, tolerância a falhas, implementação utilizando tecnologia de integração em larga escala, uniformidade de análise e projeto e analogia neurobiológica.

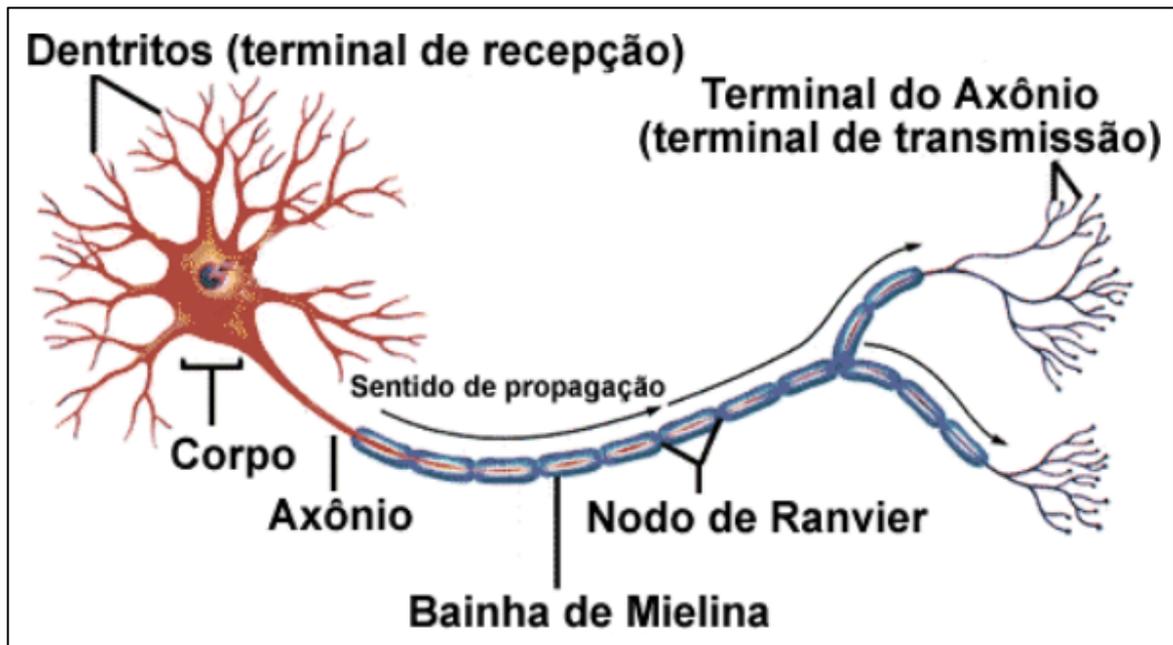
Nesse contexto, Santos M. A. et al. (2016) destacam que desde a década de 80, a utilização das RNA apresentou notável progresso, possibilitando o aumento de pesquisas em diversas aplicações científicas. Os autores também destacam que as habilidades de modelagem do cérebro humano proporcionaram a utilização das RNA num número crescente de áreas científicas. Mencionam que, particularmente em pesquisas na área financeira, a atenção foi dada a problemas relativos a previsão de falências e insolvências, avaliação de crédito e detecção de fraudes.

Citando os benefícios da utilização de RNA na resolução de problemas, Santos M. A. et al. (2016) apontam que, ao serem aplicadas como metodologia de pesquisa, propiciam vantagens como a simplificação das variáveis utilizadas e uma melhor adaptação no tratamento das relações entre elas. Como uma desvantagem, os autores mencionam, entre outras, o tempo despendido na busca da configuração ótima da rede quando aplicada a problemas complexos.

Nesse contexto, em uma rede neural, os neurônios são conectados entre si, utilizando em tais conexões os chamados pesos de ligação. Na rede, os neurônios de entrada processam as variáveis previamente definidas, semelhantemente aos impulsos elétricos externos captados pelos dendritos de um neurônio biológico natural. A saída da rede é determinada pelo processamento de um ou mais algoritmos e uma função de ativação (VALE, 2016).

A Figura 1 mostra a estrutura de um neurônio biológico natural. Silva (2003) descreve brevemente cada parte constituinte dessa célula citando que um neurônio se evidencia de outras células por apresentar a capacidade de processar informações. Morfologicamente, seu corpo (soma) é constituído por um núcleo, o axônio (fibra nervosa), cujo prolongamento é responsável pela condução do impulso nervoso ao próximo neurônio, e os dendritos, que são prolongamentos ramificados que surgem do soma e do fim do axônio, sendo responsáveis, quase sempre, pela comunicação entre os neurônios.

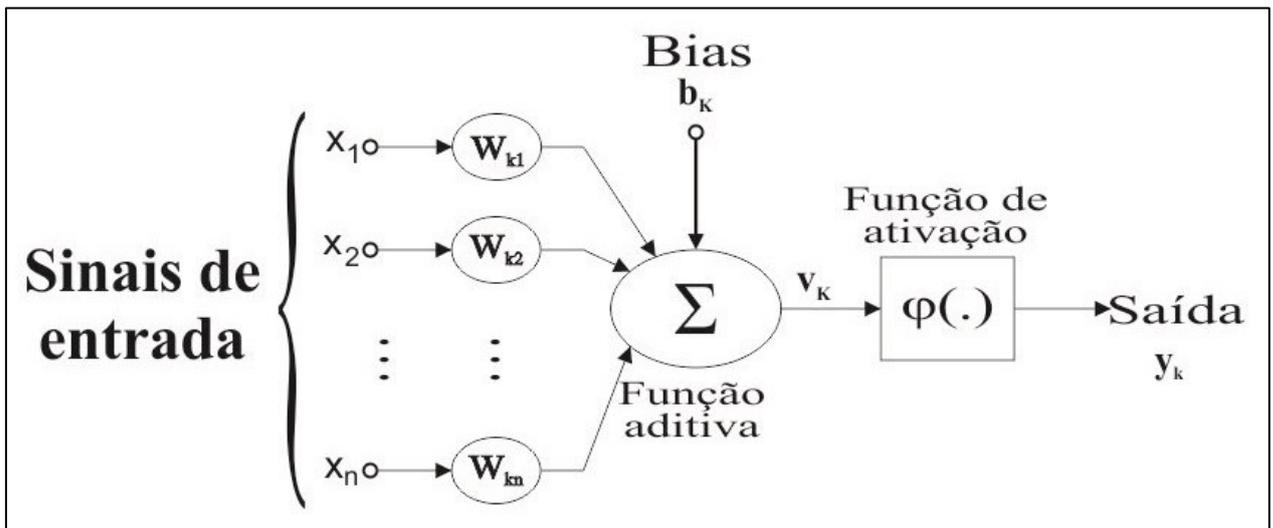
Figura 1 - A célula nervosa (Neurônio).



Fonte: Silva (2003).

Por sua vez, inspirado no neurônio biológico, o modelo de um neurônio de uma rede neural artificial é mostrado na Figura 2.

Figura 2 - Modelo de um neurônio artificial.



Fonte: Adaptado de Haykin (2001).

Na Figura 2, os valores x_1, x_2, \dots, x_n representam os sinais de entrada e são equivalentes a impulsos elétricos do meio externo captados pelos dendritos de um neurônio. Numa aplicação específica, tais sinais representam os valores atribuídos às variáveis pertencentes ao domínio

do problema em questão. O conjunto $W_{k1}, W_{k2}, \dots, W_{kn}$ corresponde aos pesos sinápticos do neurônio e são responsáveis pela ponderação de cada sinal de entrada (HAYKIN, 2001).

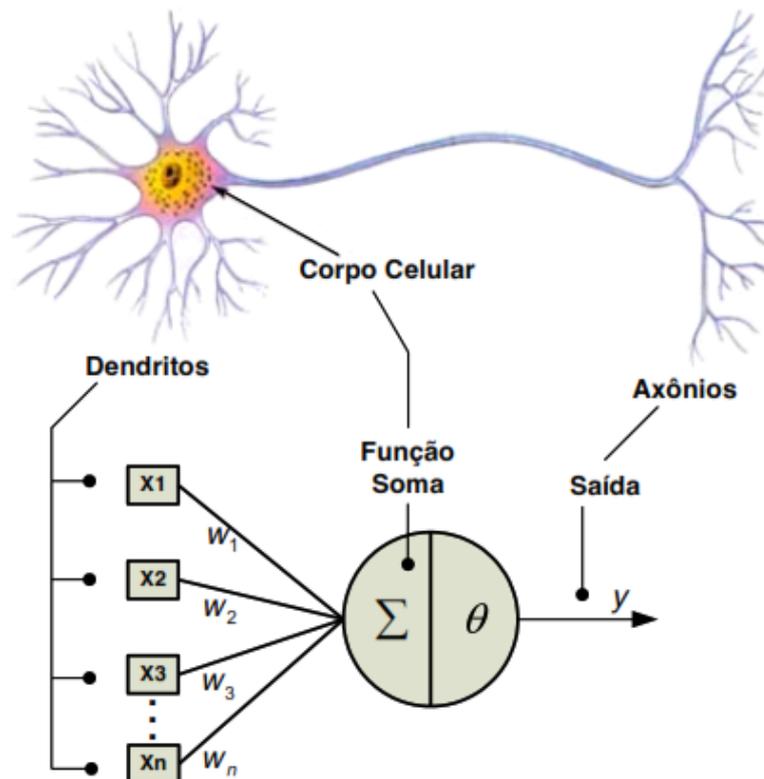
Por sua vez, a função aditiva (também conhecida como função soma), representa o corpo celular do neurônio biológico natural, sendo responsável pela soma da multiplicação dos sinais de entrada pelos seus pesos sinápticos específicos, de modo a gerar um valor de potencial de ativação (FERREIRA, 2011).

Ademais, a função de ativação $\varphi(\cdot)$ tem como objetivo a geração de uma saída que esteja compreendida num intervalo de valores válidos. Os principais tipos de funções de ativação comumente utilizadas em RNA serão apresentados mais adiante. Na referida figura, Y_k corresponde à saída propagada ao longo do axônio (HAYKIN, 2001).

Conforme apresentado por Lima (2014), o *Bias* b_k tem execução fora do neurônio, com capacidade de incrementar ou decrementar o valor entregue à função de ativação. O resultado é a influência na resposta de saída da rede neural, tentando ajustar o resultado obtido com a saída desejada.

A Figura 3 apresenta uma comparação entre o neurônio biológico e o neurônio artificial, de modo a mostrar a correspondência entre os elementos constituintes de cada um.

Figura 3 - Relação entre um neurônio biológico e um neurônio artificial.



Fonte: Fernandes (2009).

Dessa maneira, como explicita Lima (2014), matematicamente, o neurônio pode ser representado pelas equações (1) e (2) a seguir:

$$y_k = F(v_k + b_k) \quad (1)$$

com

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (2)$$

onde:

- $X_1, X_2, X_3, \dots, X_m$ representa o vetor contendo as entradas;
- $W_{k1}, W_{k2}, W_{k3}, \dots, W_{km}$ representam os pesos sinápticos do neurônio k ;
- v_k representa a saída do somador;
- b_k representa o *bias*;
- F corresponde à função de ativação;
- y_k representa a saída do neurônio.

Explicando o fluxo de informação e operação de um neurônio artificial, Laboissiere, Fernandes e Lage (2015) apresentam a seguinte sequência: os sinais são enviados às entradas; cada sinal individual é multiplicado pelo seu respectivo peso sináptico; é realizada uma soma entre os sinais de entrada ponderados e o valor limite do neurônio; a função de ativação do neurônio processa a informação e produz uma saída.

À vista disso, uma rede neural é caracterizada pela arquitetura de ligação entre seus neurônios, por sua função de ativação e pelo seu treinamento, que se refere ao método de ajuste dos pesos sinápticos das conexões (LIMA, 2014). Cada uma dessas características será descrita nas seções a seguir, de modo a propiciar um melhor entendimento dos tipos de RNA que podem ser construídas e utilizadas através da derivação dos seus diversos itens constituintes, caracterizando várias arquiteturas conhecidas e que foram empregadas nas construções de modelos preditivos.

2.3.2 Funções de ativação

A função de ativação é responsável pela definição da saída de um neurônio, podendo seu valor variar de -1 a +1 ou $-\infty$ a $+\infty$, dependendo do modelo matemático da função (LIMA,

2014). Lima (2014) ainda aponta que tal função pode apresentar atributos lineares ou não-lineares, sendo que as não-lineares simulam de modo mais preciso o comportamento de um neurônio biológico.

Silva, Spatti e Flauzino (2010) explicam que as funções de ativação podem ser do tipo totalmente diferenciáveis ou do tipo parcialmente diferenciáveis. Os autores mencionam que, no estudo das redes neurais, as funções do primeiro grupo que se destacam são tangente hiperbólica, linear e gaussiana.

O Quadro 2 apresenta os principais tipos de funções de ativação utilizados em RNA, sendo que β é denominado parâmetro de excentricidade (FERNANDES, 2009).

Quadro 2 - Tipos de funções de ativação.

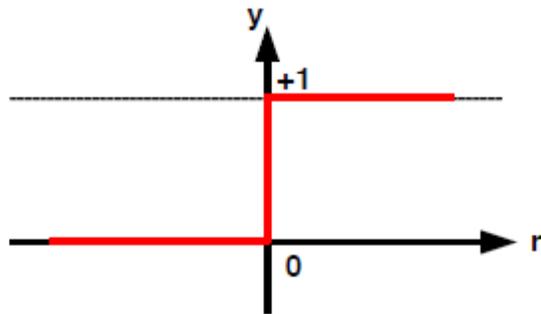
Nome	Função	Domínio
Limiar	$y(n) = \begin{cases} y = 1, & \text{se } n \geq 0 \\ y = 0, & \text{se } n < 0 \end{cases}$	[0, 1]
Linear	$y(n) = n$] $-\infty$, $+\infty$ [
Sigmóide	$y(n) = \frac{1}{1 + e^{-\beta n}}$	[0, 1]
Gaussiana	$y(n) = e^{-\left(\frac{(\beta n)^2}{2\beta^2}\right)}$	[0, 1]
Tangente hiperbólica	$y(n) = \frac{1 - e^{-\beta n}}{1 + e^{\beta n}}$	[-1, 1]

Fonte: Adaptado de Lima (2014).

Graficamente, as funções de ativação elencadas no Quadro 2 possuem seus formatos e cálculos apresentados nas Figuras de 4 a 8.

Figura 4 - Função de ativação do tipo Limiar.

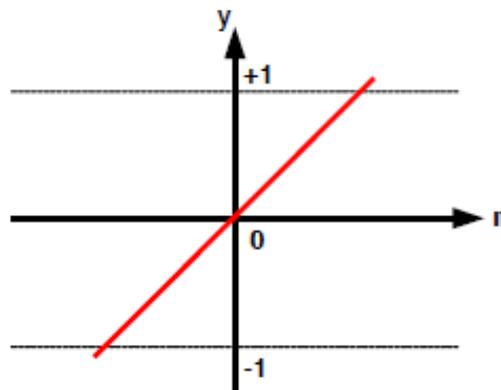
$$y(n) = \begin{cases} y = 1, & \text{se } n \geq 0 \\ y = -1, & \text{se } n < 0 \end{cases}$$



Fonte: Fernandes (2009).

Figura 5 - Função de ativação do tipo Linear.

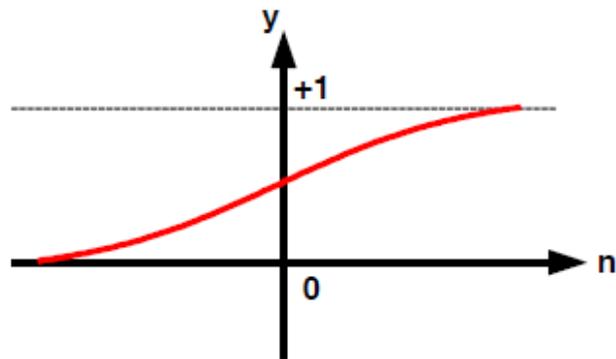
$$y(n) = n$$



Fonte: Fernandes (2009).

Figura 6 - Função de ativação do tipo Sigmóide.

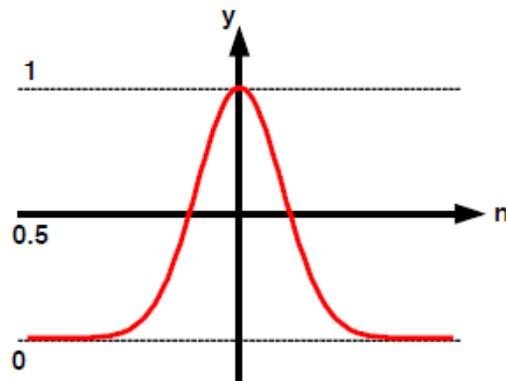
$$y(n) = \frac{1}{1 + e^{-\beta n}}$$



Fonte: Fernandes (2009).

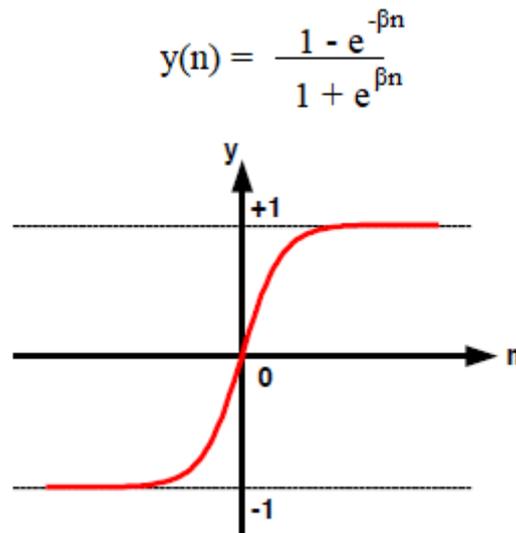
Figura 7 - Função de ativação do tipo Gaussiana.

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



Fonte: Fernandes (2009).

Figura 8 - Função de ativação do tipo Tangente hiperbólica.



Fonte: Fernandes (2009).

É importante destacar que a geração do sinal de saída do neurônio artificial é realizada por intermédio da aplicação de uma função de ativação, cuja escolha, deve melhor se aproximar do efeito de ativação da capacidade de ação de um neurônio natural (FERRO, 2013).

2.3.3 Arquiteturas

A construção de uma rede neural necessita da caracterização de sua arquitetura ou topologia, cuja definição se dá pelos seguintes componentes: número de neurônios, quantidade de camadas de entrada e saída, número de camadas ocultas (caso seja necessário), distribuição dos neurônios em cada camada e os valores ótimos dos pesos sinápticos entre os neurônios que descrevem melhor a relação entre entrada e saída (SANTOS M. A. et al., 2016).

Disconzi (2018) apresenta que a arquitetura de uma rede neural varia conforme o propósito de sua aplicação. Segundo a autora, é através de análise do problema e experimentação que o pesquisador tem condições de definir as informações acerca da rede que irá modelar, tais como o número de camadas, a quantidade de neurônios pertencente a cada camada e o algoritmo de treinamento e aprendizagem.

Determinados autores asseguram que a melhor definição do número de neurônios para uma rede neural artificial se dá por tentativa e erro, averiguando-se qual escolha oferece o menor erro implicado (HAYKIN, 2001; REINKE, 2008; VALENÇA, 2010). Entretanto, surgiram algumas sugestões que buscam auxiliar a previsão do número de neurônios, ajudando

com aproximações do melhor valor. Algumas dessas propostas são o método de Fletcher-Gloss, o método de Kolmogorov e o método de Weca (FINOCCHIO, 2010). A Tabela 1 elenca as equações propostas por tais métodos.

Tabela 1 – Métodos para estimação do número de neurônios.

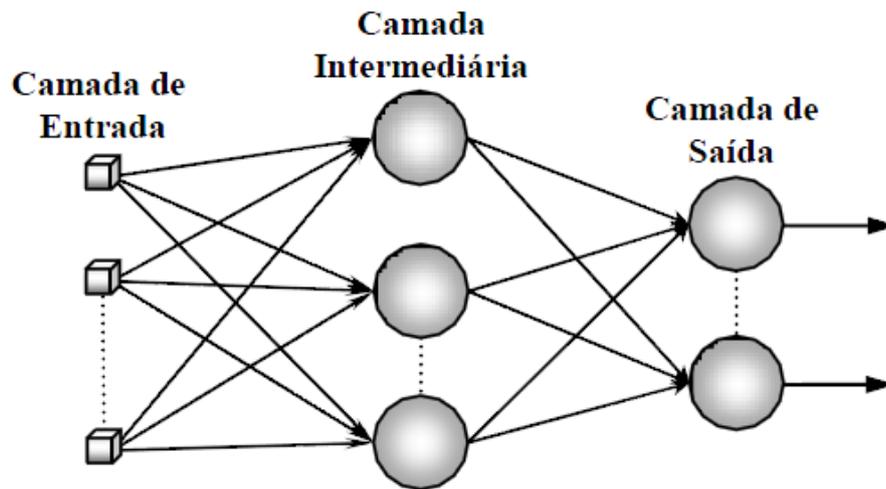
Método	Equação	Onde
Kolmogorov	$n = 2 \times n_1 + 1$	n_1 – representa o número de variáveis de entradas da rede
Fletcher-Gloss	$2 \times \sqrt{n_1} + 1 \leq n \leq 2 \times n_2 + 1$	n_1 – representa o número de variáveis de entradas da rede n_2 – representa o número de neurônios de saída da rede n – quantidade de neurônios
Weca	$n_1 = \frac{n + n_c}{2}$	n_1 – representa o número de variáveis de entradas da rede n – quantidade de neurônios n_c – número de classes

Fonte: Disconzi (2018).

A organização dos neurônios da rede neural em camadas caracteriza uma rede em camadas. Na forma mais simplificada, uma rede neural possui uma camada de entradas de neurônios que são projetados sobre uma camada de saída (HAYKIN, 2001). No entanto, a rede pode possuir uma ou mais camadas intermediárias - também denominadas de ocultas -, as quais, conforme Pao (2008), possuem a capacidade de apanhar a relação não linear entre as variáveis inerentes ao problema pesquisado. A Figura 9 apresenta uma rede neural típica contendo três camadas.

Nesse cenário, conforme Demuth, Beale e Hagan (2014), teoricamente, não existem restrições para a quantidade de camadas que possam estar presentes numa rede neural artificial, no entanto, na prática, sua grande maioria são implementadas contendo três camadas, a saber: uma camada de entrada, uma camada de saída e somente uma camada intermediária (oculta).

Figura 9 - Representação de uma rede neural artificial contendo 3 camadas.



Fonte: Silva, Spatti, Flauzino (2010).

Conforme explica Piccoli (2014), uma camada ou *layer* é um grupo de neurônios que realizam o processamento em paralelo, sendo o menor conjunto de nodos de processamento que lidam com um vetor de entrada. Por sua vez, uma camada interna utiliza como entrada a saída de alguma outra camada e sua saída é usada por uma camada posterior.

Nesse contexto, Muntaser, Da Silva e Penedo (2017) citam que nas camadas ocultas de uma rede neural, as variáveis de entrada são transformadas, de modo que tais camadas representam uma forma muito eficaz de modelagem de processos estatísticos não lineares. Ademais, Malik e Nasereddin (2006) apresentam que a camada oculta situa-se entre as camadas de entrada e saída, possuindo a função de identificar as propriedades especiais dos dados.

Dessa forma, a camada de entrada é formada pelas informações de entrada (*inputs*) da rede, onde são recebidos os dados do problema estudado. Na camada intermediária ocorre a maior parte do processamento da rede neural, abrangendo as conexões ponderadas, o treinamento e a aprendizagem. Na camada de saída se dá a conclusão e apresentação do resultado final (DISCONZI, 2018).

Zhang, Patuwo e Hu (1998) apontam pesquisas que asseguram a suficiência de apenas uma única camada oculta para alcançar a aproximação de qualquer função não linear. No entanto, os autores também destacam que existem casos problemáticos devido a utilização de somente uma camada escondida. Se forem necessários muitos neurônios em tal camada, o tempo de treinamento e/ou a generalização da rede podem ser afetados.

Fernandes (2009) também explicita que a arquitetura de uma rede neural artificial está diretamente relacionada com o algoritmo de aprendizagem utilizado para o seu treinamento.

Nesse sentido, Zhang, Patuwo e Hu (1998) ainda mencionam que o projeto de uma rede neural artificial geralmente não é trivial, sendo dependente do problema especificamente analisado.

Concernente ao número de camadas, as RNA podem ser categorizadas como redes de camada única ou de múltiplas camadas. Quanto aos tipos de interligações entre os neurônios, estes podem ser totalmente conectados ou parcialmente conectados. Por sua vez, referente às arquiteturas, as mais usuais são *feedforward* e *feedback* (FERNANDES, 2009).

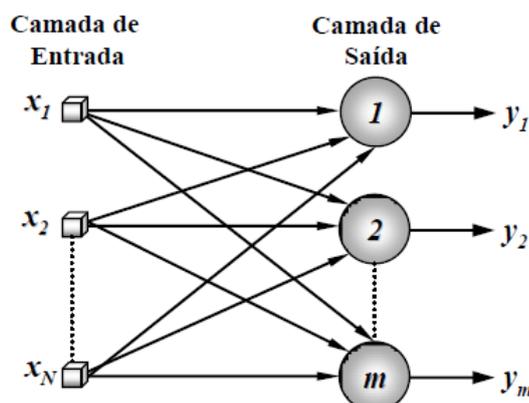
2.3.3.1 – Arquitetura do tipo *feedforward*

Conforme apresenta Piccoli (2014), as RNA do tipo *feedforward* foram as primeiras a serem desenvolvidas. Nessa arquitetura, as conexões entre os neurônios da rede não formam ciclos, de modo que a informação se propaga em apenas um sentido, na direção das entradas para a saída.

Disconzi (2018) contribui mencionando que as RNA com arquitetura *feedforward* são muito utilizadas para a modelagem de soluções para a classificação e reconhecimento de padrões. Conforme explica a autora, nesse tipo de rede neural artificial, a saída de um neurônio na “i-ésima” camada não pode ser utilizada como entrada para os neurônios em camadas que apresentam índice menor ou igual a “i”.

Nesse sentido, Turcato (2015) menciona que as RNA com topologia *feedforward* podem ser do tipo camada única ou multicamadas. Nas redes do primeiro tipo, o autor apresenta que se caracterizam por possuírem uma camada de entrada e apenas uma única camada interna de neurônios, a qual já é a camada de saída da rede. A Figura 10 mostra a representação gráfica deste tipo de rede.

Figura 10 - Representação de uma rede neural artificial do tipo *feedforward* (camada única).

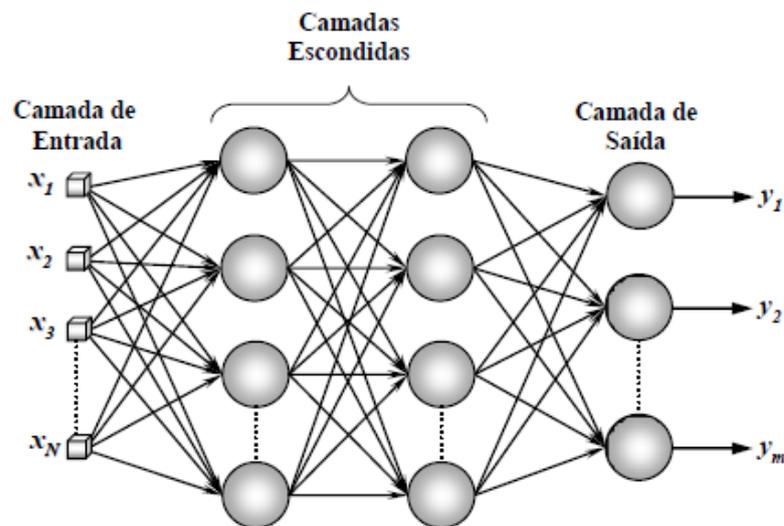


Fonte: Silva, Spatti, Flauzino (2010).

Já nas RNA com topologia do tipo *feedforward* multicamadas, há a presença de uma ou mais camadas intermediárias (ocultas). O fluxo de informações se dá pelo recebimento dos *inputs* na camada de entrada, processamento na camada ou camadas ocultas e apresentação dos resultados na camada de saída da rede. Como salienta Haykin (2001, p. 47), a inserção de uma ou mais camadas ocultas capacita a rede a “extrair estatísticas de ordem elevada”. Esse tipo de rede neural é bastante utilizado no reconhecimento de padrões e aproximação universal de funções não lineares (TURCATO, 2015).

Ademais, Silva (2015) cita que as RNA dessa categoria são conhecidas como *Perceptrons* multicamadas, do inglês *Multilayer Perceptron* (MLP). A Figura 11 mostra a representação de uma rede neural artificial com arquitetura *feedback* multicamada, contendo uma camada de entrada, duas camadas ocultas e uma camada de saída, responsável pela saída global da rede.

Figura 11 - Representação de uma rede neural artificial do tipo *feedforward* (multicamadas).



Fonte: Silva, Spatti, Flauzino (2010).

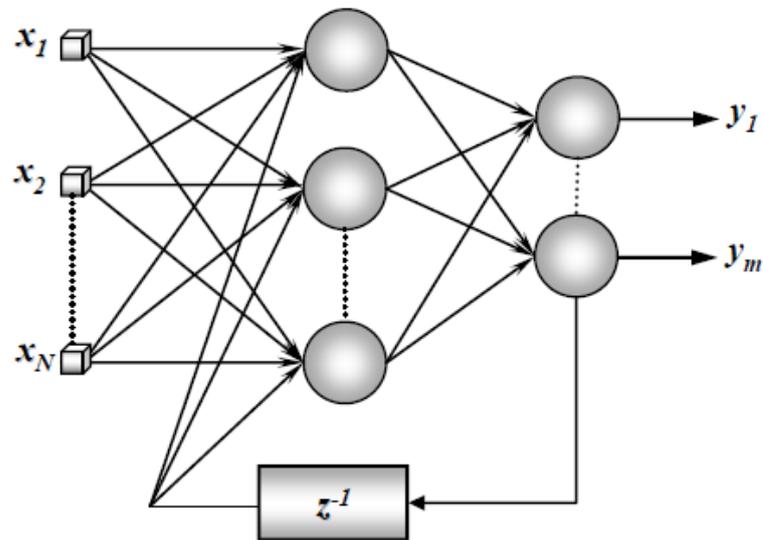
2.3.3.2 – Arquitetura do tipo *feedback*

Nas RNA desenvolvidas com topologia *feedback*, há a presença de pelo menos um ciclo nas conexões entre os neurônios (HAYKIN, 2001). Tais redes também são denominadas de recorrentes e caracterizam-se por terem a saída de algum neurônio da “i-ésima” camada sendo utilizada como entrada de nodos em camadas com índice igual ou menor que “i”, de modo a formar um ciclo (DISCONZI, 2018). Dessa forma, há a presença de realimentação entre os nodos de camadas distintas.

Analogamente, Piccoli (2014) explica que as redes neurais recorrentes (arquitetura do tipo *feedback*) são classes de redes em que predominam ciclos nas conexões entre os neurônios, de maneira que a informação de saída se torna *input* para outro neurônio. O autor destaca que este tipo de topologia é importante devido ao fato de habilitar a rede neural artificial a comportar-se dinamicamente ao longo do tempo.

A Figura 12 mostra a representação de uma rede neural artificial recorrente composta por uma camada de entrada que processa n entradas (*inputs*), uma camada oculta e uma camada de saída que gera m saídas (*outputs*), sendo z^{-1} a etapa que representa a realimentação da rede.

Figura 12 - Representação de uma rede neural artificial do tipo *feedback*.

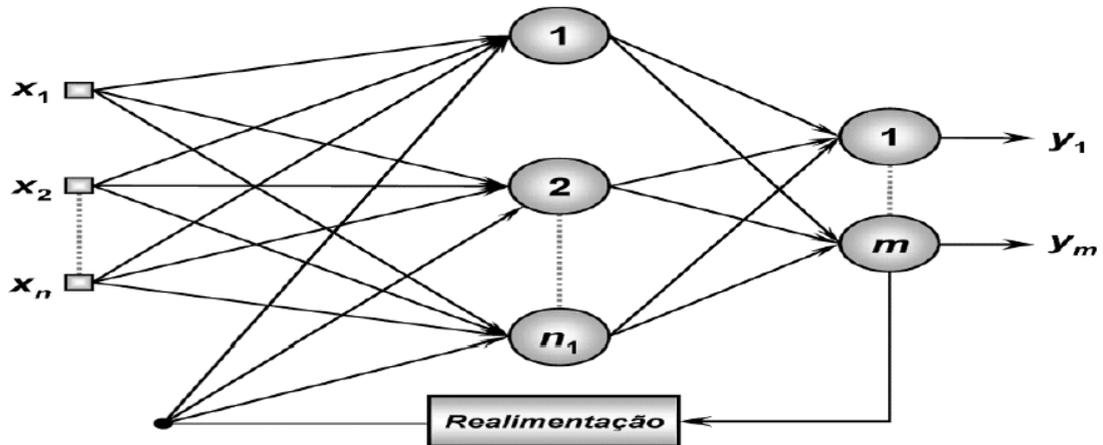


Fonte: Silva, Spatti, Flauzino (2010).

2.3.3.3 – Arquitetura do tipo recorrente *Long Short-Term Memory* (LSTM)

As RNA com arquitetura LSTM são uma variação de um tipo de rede denominada recorrente (DAMETTO, 2018). Segundo Bessa (2018), as redes neurais recorrentes são caracterizadas por possuírem as saídas de seus neurônios realimentadas como sinais de entrada para outros neurônios. Dessa maneira, as saídas se tornam entradas, de modo a realimenta a rede neural. Haykin (2001) afirma que o processo de realimentação proporciona grande influência na rede em termos de treinamento e desempenho. A Figura 13 apresenta um exemplo de rede neural artificial recorrente, destacando, principalmente, o processo de realimentação dos neurônios.

Figura 13 – Representação de uma rede neural artificial recorrente.



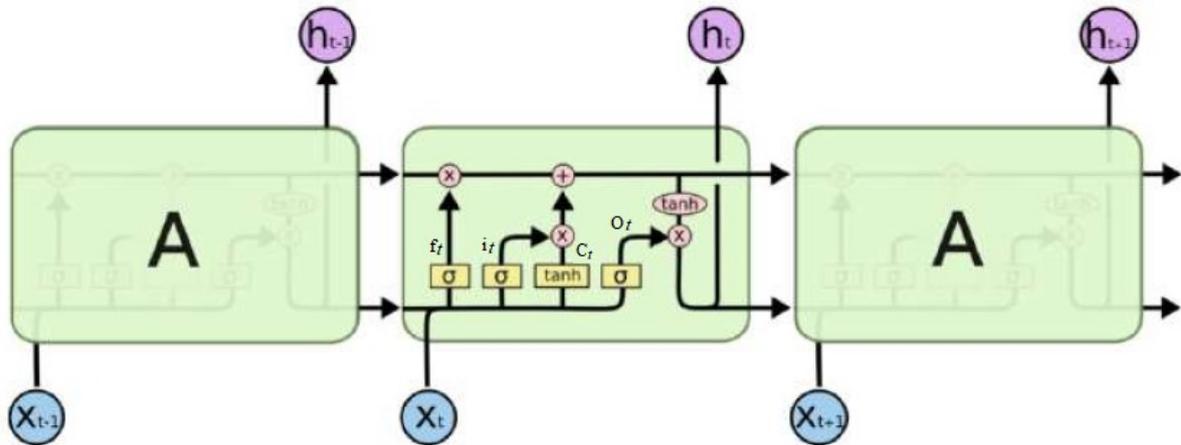
Fonte: Bessa (2018).

Comparando RNA do tipo MLP com redes neurais recorrentes, Bessa (2018) explica que uma rede recorrente pode ser entendida como uma rede neural MLP com *loops*, onde os neurônios de cada camada podem passar seus sinais para a frente e para os lados. O autor ainda destaca que, nos últimos anos, o tipo de rede neural recorrente que obteve maior êxito nos resultados apresentados foi a LSTM.

As RNA do tipo LSTM foram concebidas em 1997 por Sepp Hochreiter e Jurgen Schmidhuber, sendo aprimoradas em 2000 pela equipe de Felix Gers (BESSA, 2018). Visto que são um tipo especial de rede neural recorrente, possuem as mesmas características e propriedades de uma rede recorrente padrão, contudo, se destacam pela capacidade de armazenamento de informações por longos períodos de tempo ao processarem sequências, o que não é possível nas RNA do tipo MLP tradicionais (DAMETTO, 2018; BESSA, 2018).

Dametto (2018) apresenta que os nós de memória de uma rede neural artificial do tipo LSTM é denominado de célula, cujas propriedades são mais complexas pelo fato de aprenderem dependências no longo prazo. Nesse contexto, Bessa (2018) cita que as RNA do tipo LSTM possuem blocos de memória conectados através de camadas, ao invés de neurônios convencionais. Esquematicamente, a Figura 14 mostra uma rede neural artificial LSTM e seus itens constituintes.

Figura 14 – Representação de uma rede neural artificial recorrente do tipo LSTM.



Fonte: Dametto (2018).

Na Figura 14, Dametto (2018) apresenta cada item de uma célula inerente a uma rede neural LSTM da seguinte maneira:

- t : representa o tempo;
- C_t : é o estado da célula no instante de tempo t ;
- h_t : representa a saída da célula;
- x : é a amostra da sequência;
- f_t : é denominado de *gate* (portão) de esquecimento;
- i_t : é denominado de *gate* (portão) de entrada;
- O_t : é denominado de *gate* (portão) de saída;

Ademais, Dametto (2018) ainda destaca que, em cada célula, há cinco pontos de conexão com o exterior da mesma. Bessa (2018) explica que o *gate* de entrada estabelece os valores da entrada para atualizar o estado da memória. Por sua vez, o *gate* de esquecimento estabelece as informações que serão descartadas do bloco. Já o *gate* de saída, determina o que é produzido baseado na entrada e memória do respectivo bloco. A autora também menciona que cada célula opera como se fosse uma máquina de miniestados, em que os portões de cada unidade possuem pesos que são descobertos durante todo o processo de treinamento da rede neural artificial.

Bessa (2018) ainda argumenta que, nos últimos anos, as RNA do tipo LSTM têm se tornado os padrões de estado da arte para diversos problemas que envolvem aprendizagem de máquina, sendo empregadas para processamento, classificação e previsão de séries temporais. Também têm sido utilizadas na implementação de soluções para o reconhecimento de voz, compreensão de texto e controle de robôs.

Acerca das vantagens da utilização de RNA do tipo LSTM, é importante destacar que evitam problemas de propagação do erro e propiciam a resolução de tarefas mais complexas e de longa extensão, cujas soluções ainda não haviam sido encontradas por algoritmos de RNA recorrentes (BESSA, 2018).

2.3.4 Aprendizagem e treinamento

Uma das características mais importantes das RNA, sem dúvida, é a aptidão em aprender desde a apresentação de amostras que indicam o comportamento de um sistema, de modo a generalizar a informação entendida. Dessa forma, a rede é capaz de gerar uma solução aproximada da esperada a partir dos dados inseridos em suas entradas (SILVA, 2015).

É importante salientar que a aprendizagem e o treinamento das RNA estão intrinsecamente relacionados. Conforme apresenta Silva (2015), o processo de aprendizagem de uma rede neural se dá mediante um processo iterativo de ajustes nos pesos sinápticos e níveis de *bias*. A etapa de aprendizagem finaliza quando a rede apresenta uma solução geral de acordo com critérios preestabelecidos.

Nesse âmbito, Disconzi (2018) cita que o aprendizado da rede neural artificial acontece através de exemplos, onde o algoritmo de aprendizagem é o responsável pela adaptação dos parâmetros da rede, buscando a obtenção da solução desejada com um número finito de iterações. A autora também apresenta que é através da aprendizagem e do treinamento que as RNA são capazes de estimar a solução desejada com um certo grau de erro envolvido.

Ademais, Turcato (2015) destaca que, durante a fase de aprendizagem, a rede extrai as particularidades do sistema ou processo que lhe é apresentado. A seguir, os pesos das conexões entre os neurônios são ajustados e o conhecimento adquirido pela rede é armazenado. O autor apresenta que o conjunto de regras predefinidas que altera os parâmetros da rede é denominado algoritmo de aprendizagem.

A principal diferença entre os vários tipos de algoritmos de aprendizagem utilizados em RNA é a maneira em que proporcionam a alteração dos pesos sinápticos da rede. Dessa forma, o processo de aprendizagem e treinamento de uma rede neural artificial está intimamente relacionado com o tipo de algoritmo escolhido (TURCATO, 2015).

Referente aos paradigmas de aprendizagem em RNA, Disconzi (2018) explicita que se classificam, principalmente, em dois: supervisionado e não-supervisionado. A autora apresenta que a característica central do aprendizado supervisionado é a presença de um agente externo que apresenta um conjunto de amostras dos sinais de entrada e a saída almejada, fazendo uma

checagem da saída gerada e a desejada. Se a saída da rede não for igual ou próxima da intencionada, os pesos sinápticos e níveis de *bias* são ajustados sob a influência de um sinal de erro, de modo a minimizar a diferença entre a solução inicialmente desejada e a solução encontrada pela rede neural.

Adicionalmente, Turcato (2015) aponta que no processo de aprendizado supervisionado, a rede gera um mapeamento das variáveis e tem seus parâmetros alterados pelo agente externo (supervisor) até que a generalização seja suficiente, minimizando a diferença entre a saída apresentada e saída desejada.

Ademais, Haykin (2001) salienta que a saída desejada é a ação ótima a ser efetuada pela rede. No processo de aprendizagem supervisionada, o autor menciona que os parâmetros da rede são ajustados sob a ingerência combinada de um vetor de treinamento e um sinal de erro, sendo tal sinal a diferença entre a resposta almejada e a resposta gerada. Tal processo transfere à rede, através de treinamento, o conhecimento a ela apresentado inicialmente mediante o vetor de entradas. Quando tal condição é alcançada, a rede neural está totalmente treinada e dispensa o supervisor.

Por sua vez, no paradigma de aprendizado não-supervisionado, não existe a necessidade de um supervisor externo para verificação do processo de aprendizagem. Nesse caso, somente os padrões de entrada são oferecidos à rede, diferentemente do aprendizado supervisionado, onde os padrões de treinamento têm pares entrada e saída (SILVA, 2015). Dessa forma, a rede se organiza buscando particularidades similares nos subconjuntos que lhe são fornecidos. O algoritmo de treinamento altera os pesos sinápticos da rede neural e proporciona ao sistema a criação da sua representação própria para os impulsos de entrada (TURCATO, 2015).

Nesse contexto, Haykin (2001, p. 90) ensina que a aprendizagem não-supervisionada também é denominada de auto-organizada. Nesse processo, são fornecidas condições para a realização de uma “medida independente da tarefa da qualidade da representação que a rede deve aprender, e os parâmetros livres da rede são otimizados em relação a esta medida”. O autor apresenta que, quando a rede neural se ajusta às regularidades estatísticas dos dados de entrada, desenvolve-se a “habilidade de formar representações internas para codificar as características da entrada e, desse modo, criar automaticamente novas classes”.

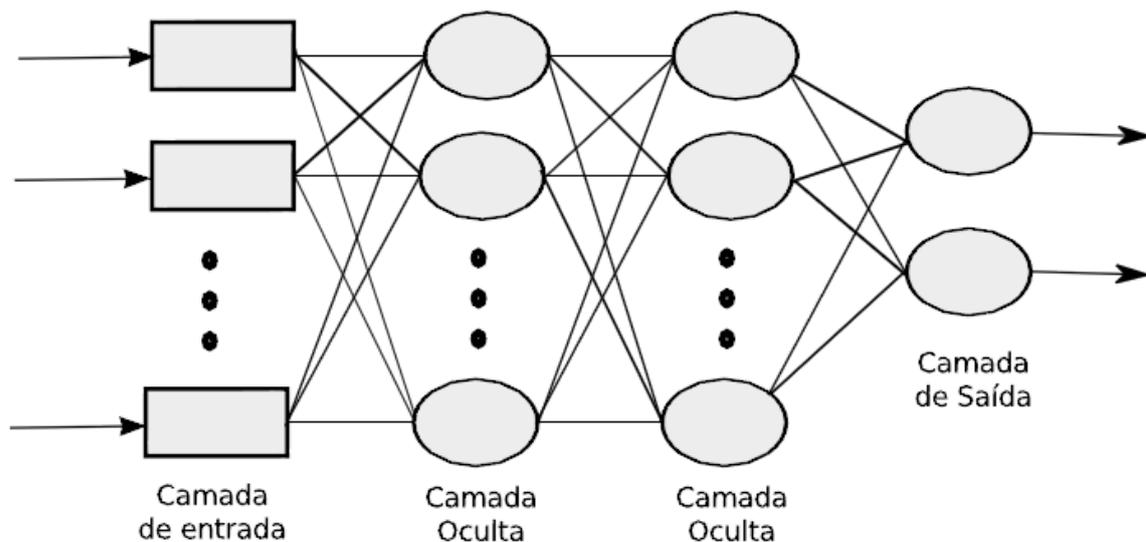
À vista disso, um tipo especial de rede neural artificial é a denominada *Perceptron* Multicamadas, em inglês *Multilayer Perceptron* (MLP). Conforme citado por Silva (2012), as RNA do tipo MLP são uma classe importante de redes neurais devido à sua versatilidade. Nesse sentido, Laboissiere, Fernandes e Lage (2015) mencionam que são muito utilizadas em problemas que envolvem previsão e Ribas (2013) destaca que têm sido aplicadas

satisfatoriamente em problemas relacionados ao reconhecimento de padrões. Por sua vez, Turcato (2015) ainda cita que também são bastante empregadas em problemas inerentes à aproximação de funções, controle e identificação de processos, aperfeiçoamento de processos e previsão de séries temporais.

A arquitetura padrão das RNA do tipo MLP caracteriza-se pela presença de pelo menos uma camada intermediária presente entre as camadas de entrada e saída da rede. Dessa forma, tais redes possuem, no mínimo, duas camadas (HAYKIN, 2001). Outra particularidade de tais redes é o fato de serem do tipo *feedforward* e seu treinamento ser de forma supervisionada. Isso significa que a propagação dos seus cálculos ocorre num sentido único, sem a presença de laços (RIBAS, 2013).

Ademais, destacando o funcionamento das RNA do tipo MLP, Turcato (2015) apresenta que os sinais ou estímulos são apresentados à camada de entrada. Em seguida, as informações são extraídas pela camada intermediária e codificadas através dos pesos sinápticos, de modo a formar uma representação do ambiente exterior. Por fim, a camada de saída recebe os sinais da camada intermediária e mapeia o padrão de resposta. A Figura 15 apresenta, esquematicamente, a estrutura de uma rede neural MLP que contém uma camada de entrada, duas camadas intermediárias (ocultas) e uma camada de saída. É possível perceber que se trata da mesma rede mostrada anteriormente na Figura 11.

Figura 15 – Representação de uma rede neural artificial do tipo MLP com duas camadas ocultas.



Fonte: Ribas (2013).

Em relação ao processo de aprendizagem das redes neurais do tipo MLP, Laboissiere, Fernandes e Lage (2015) indicam que, na literatura, muitos algoritmos podem ser encontrados. Um dos mais utilizados é o *backpropagation*, cuja fundamentação é a retropropagação do erro no decorrer da fase de treinamento da rede (RIBAS, 2013).

Nesse cenário, Ribas (2013) apresenta que a aprendizagem por retropropagação do erro é realizada em duas etapas. O autor detalha tais etapas da seguinte maneira: na primeira etapa acontece a aplicação do vetor de entrada aos neurônios da primeira camada, propagando o seu efeito adiante, através das camadas da rede, utilizando, inicialmente, os pesos sinápticos fixos, um elemento de compensação (bias) e uma função de ativação para os neurônios. Após a propagação pela camada de saída da rede, obtém-se a resposta resultante do vetor apresentado à camada de entrada. Na segunda etapa, há a aplicação de uma regra para o cálculo de erros. Os pesos sinápticos são reajustados considerando a diferença entre a resposta apresentada pela rede e a resposta realmente almejada. A seguir, o processo de propagação para trás é repetido. Tal procedimento é efetuado iterativamente até que a resposta apresentada pela rede neural produza erro próximo a limites aceitáveis para a respectiva tarefa.

Turcato (2015) apresenta que as duas etapas do algoritmo *backpropagation* são denominadas *forward* (para frente) e *backward* (para trás), respectivamente. O autor ainda menciona que, mediante aplicações sucessivas de tais fases, os limiares e pesos sinápticos dos neurônios pertencentes à rede neural se ajustam no decorrer das iterações, de modo a convergir progressivamente para valores que resultem em menor erro das respostas produzidas perante as que são realmente desejadas. Ademais, Lima (2014) cita que, durante o processo de aprendizagem supervisionada utilizando *backpropagation*, os erros são computados sucessivamente, até que se alcance um resultado aceitável definido a *priori*.

Resumidamente, conforme salienta Disconzi (2018), o algoritmo *backpropagation* atua de modo a ajustar os valores dos pesos sinápticos consoante o erro médio quadrático. Felizardo (2017, p. 23) corrobora citando que o mesmo busca uma “minimização dos erros quadráticos pelo método do gradiente”, sendo que o erro “é definido pela diferença entre a resposta desejada e a saída obtida a partir de uma saída originada por um neurônio não treinado”. Uma síntese da execução do algoritmo *backpropagation* é mostrada no Quadro 3.

Quadro 3 - Síntese da execução do algoritmo *backpropagation*.

Inicialização

Inicializar os pesos sinápticos com valores aleatórios e pequenos

Treinamento

Repita até que o erro de saída da rede seja \leq tolerante, para todos os padrões do conjunto de entrada para treinamento

1. Entrada de padrão na rede com as saídas esperadas
2. Calcula saída dos neurônios a partir da primeira camada até a última
3. Calcula o erro na saída da rede. Se o erro \leq tolerante, volta ao passo 1
4. Atualiza os pesos de cada neurônio, começando da camada de saída até a primeira camada
5. Volta ao passo 1 caso a diferença entre a saída da rede e a resposta desejada seja maior que um determinado limite especificado pelo usuário

Fonte: Lima (2014).

Entretanto, conforme Araújo e Lotufo (2009), a utilização do método *backpropagation* apresenta um grande esforço computacional, pois ajusta os valores das matrizes de pesos considerando as derivadas de primeira ordem. Analogamente, Disconzi (2018) menciona que uma grande desvantagem proveniente da utilização desse algoritmo é a sua lenta convergência, o que resulta num grande consumo de recursos computacionais.

Nesse sentido, na busca de contornar o principal problema do algoritmo *backpropagation*, várias técnicas de otimização foram incorporadas visando melhorar o desempenho do seu tempo de convergência e esforço computacional. Dentre elas, um destaque é o método de Levenberg-Marquardt (LM) (TURCATO, 2015).

Silva (2012) apresenta que o algoritmo LM faz uso de gradiente de segunda ordem, acelerando o processo de treinamento da rede neural baseado na determinação de derivadas de segunda ordem do erro quadrático com relação aos pesos. A autora ainda menciona que o método LM é considerado o mais rápido para o treinamento das RNA do tipo *feedforward* quando há um número criterioso de parâmetros na rede, pois, uma vez que tal número seja grande, a utilização do algoritmo se torna inadequada.

Ademais, segundo Finocchio (2010), em alguns problemas, a incorporação do método LM ao algoritmo de treinamento *backpropagation* assegura uma melhora na rapidez de 10 a 100 vezes. Laboissiere, Fernandes e Lage (2015) ainda acrescentam que a utilização de um processo iterativo otimizado de ajuste dos pesos sinápticos no método LM fornece uma convergência mais rápida na comparação com a retropropagação convencional.

Além disso, Defilippo (2017) agrega que análises empíricas demonstram que o LM apresenta convergência mais acelerada do que os métodos fundamentados na descida de gradiente. Devido a isso, conforme salienta o autor, é o método comumente mais utilizado em aplicações práticas, como, por exemplo, na *toolbox* de RNA do ambiente MATLAB.

2.4 Pesquisas empíricas relacionadas

Nesta seção, são apresentados estudos empíricos realizados utilizando RNA. Primeiramente, uma síntese de trabalhos pioneiros é mostrada conforme descrito em Haykin (2001), abrangendo o período de 1943 a 1995, o qual alavancou as pesquisas científicas utilizando redes neurais como objetos de aprendizagem. Em seguida, são apontados estudos atuais que empregam RNA no campo das finanças e nas mais diversas áreas do conhecimento científico.

2.4.1 Estado da Arte

Em sua obra, Haykin (2001) destaca autores que realizaram pesquisas pioneiras com redes neurais: McCulloch e Pitts (1943), com a introdução do conceito de redes neurais como máquinas computacionais; Hebb (1949), que demonstrou o primeiro princípio de aprendizagem auto-organizada e Rosenblatt (1958), que propôs o *perceptron* como modelo inicial para o aprendizado supervisionado.

O artigo de McCulloch e Pitts em 1943 é considerado um clássico no contexto de redes neurais. Nele, os autores apresentam um modelo formal de neurônio e defendem que uma rede de tais unidades com conexões sinápticas estabelecidas de modo apropriado e operando sincronamente podem realizar o cômputo de qualquer função calculável (HAYKIN, 2001).

A seguir, Haykin (2001) apresenta o trabalho de Hebb (1949) como um marco significativo para o desenvolvimento dos estudos com redes neurais. Nele, pela primeira vez, foi apresentada uma elaboração explícita de uma regra de aprendizado fisiológica para a mudança sináptica. Hebb (1949) indicou que as conexões cerebrais são constantemente modificadas à medida que o organismo aprende novas tarefas, resultando na criação de grupos neurais. O autor também apresentou sua hipótese de aprendizagem, afirmando que a ativação repetida de um neurônio causada por outro neurônio aumenta a eficiência de uma sinapse mutável entre dois neurônios.

Baseado no postulado de Hebb (1949), Haykin (2001) menciona que o artigo de Rochester et al. (1956) provavelmente foi a primeira tentativa de simulação computacional para teste de uma teoria em rede neural bem formulada. No mesmo ano, Uttley (1956) comprovou que “uma rede neural com sinapses modificáveis pode aprender a classificar conjuntos simples de padrões binários em classes correspondentes” (HAYKIN, 2001, p. 64).

Ashby (1952) publicou um livro apontando que o comportamento adaptável não é natural, mas sim assimilado. O autor indica que é por meio da aprendizagem que o comportamento de um sistema progride de maneira dinâmica (HAYKIN, 2001).

Em seguida, Haykin (2001) menciona a tese de doutorado de Minsky (1954) e um artigo do mesmo autor, referenciado em Minsky (1961). No artigo, o autor apresenta uma importante seção sobre a denominação das redes neurais. Minsky (1967) ainda escreve um livro estendendo os resultados de McCulloch e Pitts (1943), inserindo-os no campo da teoria da computação e dos autômatos.

Rosenblatt (1958) apresenta o *perceptron*, um procedimento inédito de aprendizagem supervisionada. O ponto alto do seu trabalho é o teorema da convergência do *perceptron*. Baseados nessa teoria, Widrow e Hoff (1960) introduzem o algoritmo do mínimo quadrado médio (LMS, em inglês *Least Mean-Square*) e o utilizam na formulação do ADALINE (*adaptive linear element*). O diferencial entre o ADALINE e o *perceptron* é o processo de aprendizagem (HAYKIN, 2001).

Haykin (2001) também cita que Widrow e alguns associados ainda propões no ano de 1962 a estrutura MADALINE (*Multiple-adaline*), a qual é considerada como um dos primeiros tipos de redes neurais multicamadas treináveis com diversos elementos adaptativos (WIDROW, 1962).

Ademais, Haykin (2001) menciona que durante a década de 1960, considerada como o período clássico do *perceptron*, havia a expectativa de que as redes neurais poderiam efetuar qualquer trabalho. No entanto, Minsky e Papert (1969) utilizaram a matemática em seu livro “para demonstrar que existem limites fundamentais para aquilo que os *perceptrons* de camada única podem calcular” (HAYKIN, 2001, p. 65).

Ainda na década de 1960, Haykin (2001) indica que surgiu um importante problema no projeto do *perceptron* de múltiplas camadas: o chamado “problema de atribuição de crédito”, ou seja, “o problema de atribuir crédito a neurônios ocultos da rede” (HAYKIN, 2001, p. 65). O autor sustenta que tal obstáculo foi um dos fatores que contribuíram para o declínio do interesse dos pesquisadores nas RNA durante a década de 1970, considerada como uma década de sono para as redes neurais.

Já na década de 1980, contribuições importantes para o projeto e teoria de redes neurais reavivaram o interesse dos pesquisadores. Por exemplo, Hopfield (1982) realizou estudos que resultaram numa classe particular de RNA com realimentação, chamadas de redes de Hopfield. Tais resultados, conforme cita Haykin (2001), provocaram um intenso interesse dos físicos pela modelagem com redes neurais.

Kirkpatrick, Gelatt e Vecchi (1983) descreveram um novo método que ficou conhecido como recozimento simulado, que resultou na criação de uma máquina estocástica denominada de máquina de Boltzmann, considerada a primeira execução com êxito de uma rede neural multicamadas. Haykin (2001) menciona que o algoritmo de aprendizagem utilizado na máquina de Boltzmann não se mostrou tão eficiente computacionalmente quanto o algoritmo de retropropagação (*backpropagation*).

Haykin (2001) relata que Rumelhart e McClelland (1986) publicaram um livro em dois volumes que influenciou bastante a utilização da aprendizagem empregando a retropropagação. O autor aponta que tal obra ajudou a tornar o algoritmo *backpropagation* o mais popular no treinamento de *perceptrons* multicamadas.

Linsker (1988) apresentou uma nova base para a auto-organização. Conforme cita Haykin (2001, p. 68), o “princípio é concebido para preservar o máximo de informação sobre os padrões de atividade das entradas, sujeito a limitações como as conexões sinápticas e o intervalo dinâmico das sinapses”. Tal artigo reavivou o interesse pelo emprego da teoria da informação às RNA.

Ademais, Broomhead e Lowe (1988) descrevem em seu trabalho um método para o projeto de redes neurais *feedforward* em camadas empregando funções de base radial, fornecendo uma opção aos *perceptrons* multicamadas. Conforme menciona Haykin (2001, p. 69), o artigo desses dois autores "levou a um grande esforço em pesquisa para ligar o projeto de redes neurais a uma importante área de análise numérica".

Já na década de 1990, Haykin (2001, p. 69) cita o trabalho de Freeman (1995), que apresenta que "os padrões de atividade neural não são impostos de fora do cérebro", mas sim, concebidos a partir do seu interior. Sua contribuição principal é indicar que "a dinâmica caótica oferece uma base para descrever as condições que são requeridas para a emergência de padrões auto-organizados em populações de neurônios e entre estas populações".

Outrossim, na opinião de Haykin (2001), o artigo de Hopfield (1982) e os dois volumes do livro de Rumelhart e McClelland (1986) são as publicações que mais influenciaram o retorno do interesse pelas redes neurais a partir da década de 1980. Conforme aponta, desde o trabalho

de McCulloch e Pitts (1943), as RNA se efetivaram como tema interdisciplinar, sendo utilizadas na psicologia, engenharia, matemática, neurociências, ciências físicas, etc.

De forma esquemática, o Quadro 4 apresenta os trabalhos históricos expostos nessa seção, elencando os autores e suas contribuições para a área das RNA.

Quadro 4 – Estudos históricos realizados no contexto das RNA.

Autor (a/es)	Contribuição
McCulloch e Pitts (1943)	Apresentam um modelo formal de neurônio e defendem que uma rede neural com conexões bem ajustadas e operando sincronamente podem realizar a computação de qualquer função computável.
Hebb (1949)	Apresenta, pela primeira vez, uma formulação explícita de uma regra de aprendizagem fisiológica para a modificação sináptica.
Rochester et al. (1956)	Primeira tentativa de simulação computacional para teste de uma teoria em rede neural bem formulada.
Uttley (1956)	Comprova que uma rede neural com sinapses modificáveis pode aprender a classificar conjuntos simples de padrões binários em classes correspondentes.
Ashby (1952)	Demonstra que por intermédio da aprendizagem, o comportamento de um sistema progride de forma dinâmica.
Minsky (1961)	Apresenta uma importante definição das redes neurais.
Minsky (1967)	Estende os resultados de McCulloch e Pitts (1943), inserindo-os no campo da teoria da computação e dos autômatos.
Rosenblatt (1958)	Apresenta o <i>perceptron</i> como um procedimento inédito de aprendizagem supervisionada. Postula o teorema da convergência do <i>perceptron</i> .
Widrow e Hoff (1960)	Introduzem o algoritmo do mínimo quadrado médio (LMS).

(continua)

(conclusão)

Widrow (1962)	Propõe a estrutura MADALINE, considerada como um dos primeiros tipos de redes neurais multicamadas treináveis com diversos elementos adaptativos.
Minsky e Papert (1969)	Demonstram, matematicamente, que existem limites fundamentais para aquilo que os <i>perceptrons</i> de camada única podem calcular.
Hopfield (1982)	Apresenta uma classe particular de RNA com realimentação, chamadas de redes de Hopfield.
Kirkpatrick, Gelatt e Vecchi (1983)	Descrevem um novo método, conhecido como recozimento simulado, que resultou na criação de uma máquina estocástica denominada de máquina de Boltzmann, considerada a primeira execução com êxito de uma rede neural multicamadas.
Rumelhart e McClelland (1986)	O livro em dois volumes influenciou bastante a utilização da aprendizagem empregando a retropropagação.
Linsker (1988)	Apresentou um novo princípio para a auto-organização.
Broomhead e Lowe (1988)	Descrevem em seu trabalho um método para o projeto de redes neurais <i>feedforward</i> em camadas, fornecendo uma opção aos <i>perceptrons</i> multicamadas.
Freeman (1995)	Apresenta que a dinâmica caótica oferece uma base para descrever as condições que são requeridas para a emergência de padrões auto-organizados em populações de neurônios.

Fonte: Elaborado pelo autor baseado em Haykin (2001).

2.4.2 Pesquisas recentes

O avanço tecnológico atual, tanto na área de hardware, quanto na de software, contribuiu muito para o crescente número de estudos e pesquisas envolvendo RNA. A evolução do potencial computacional tem colaborado diretamente para a implementação de modelos que utilizam RNA como base, principalmente para os que visam criar modelos preditivos, como é o caso da presente pesquisa.

No intuito de conhecer as abordagens e metodologias utilizadas por autores recentes em pesquisas utilizando RNA, principalmente nos estudos alinhados aos objetivos deste trabalho, diferentes bases de dados públicas foram consultadas, considerando o período de 2013 a 2018. Sendo o recorte temporal desta pesquisa o período compreendido entre 2013 a 2017, alguns estudos no ano de 2018 foram inseridos a fim de aumentar o número de trabalhos encontrados, uma vez que o poder computacional em termos de memória, processamento e armazenamento tem progredido constantemente.

A análise bibliométrica foi realizada nas bases de dados Google *Scholar* e IBICT (Instituto Brasileiro de Informação em Ciência e Tecnologia), buscando artigos, dissertações e teses. Foram selecionados artigos já aceitos e publicados em periódicos, revistas e afins, enquanto que as dissertações e teses selecionadas, já se encontram disponíveis nos repositórios institucionais correspondentes. Os resultados selecionados estão elencados no Quadro 5 em ordem cronológica crescente, sendo mais detalhados nos parágrafos seguintes.

Quadro 5 – Estudos empíricos recentes utilizando RNA como base metodológica.

	Autor (es)	Título	Objetivo geral	Resultado (s)
1	Arantes (2013)	Previsão da estrutura a termo da taxa de juros brasileira usando redes neurais artificiais.	Avaliar as previsões fora da amostra da curva de juros utilizando o arcabouço de RNA.	Os modelos estimados através de RNA conseguiram superar as previsões realizadas por <i>random walk</i> e foram capazes de realizar boas previsões para todos os horizontes testados.
2	Ferro (2013)	Aplicação da rede neural MLP (<i>Multilayer Perceptron</i>) em indústria de pisos e revestimentos do polo cerâmico de Santa Gertrudes – SP.	Encontrar uma rede neural artificial que melhor se adapta para maximizar o aproveitamento das argilas na indústria cerâmica, bem como a qualidade dos pisos e revestimentos cerâmicos produzidos.	Os modelos construídos com RNA forneceram boas soluções com pequenos desvios com relação ao padrão de saída previamente estabelecido.

(continua)

3	Gambogi (2013)	Aplicação de redes neurais na tomada de decisão no mercado de ações.	Propor um sistema de <i>trading</i> seguidor de tendência de curto prazo que apresente boas métricas de desempenho financeiro, mediante o emprego de RNA multicamadas.	O modelo preditivo baseado em RNA obteve uma boa taxa de acerto considerando-se o índice <i>Standard & Poor's 500</i> , utilizado no mercado de ações estadunidense.
4	Piccoli (2014)	Aplicação de redes neurais para previsão de contrato de dólar futuro no mercado brasileiro.	Propor uma rede neural para prever a direção do movimento do contrato de dólar futuro em um horizonte de um mês.	O modelo proposto identificou variáveis que ajudam a prever o movimento do câmbio futuro, fornecendo evidências de que é possível prever com uma taxa razoável de acerto (superior a 60%) o movimento do contrato de dólar futuro negociado na BM&FBovespa.
5	Miranda (2015)	Modelos de regressão e de redes neurais artificiais na quantificação de carbono e biomassa lenhosa em floresta estacional decidual no Brasil Central.	Avaliar a eficiência do uso da modelagem por rede neural artificial e por modelos de regressão na quantificação dos estoques de biomassa seca e carbono.	A utilização de RNA na estimativa de estoques de biomassa seca e carbono de árvores individuais foi considerada eficiente, apresentando estimativas bastante precisas.
6	Turcato (2015)	Desenvolvimento de uma metodologia baseada em redes neurais artificiais para identificação de anomalias em redes de comunicação Profinet.	Desenvolver e avaliar uma metodologia com o propósito de identificar anomalias no tráfego de redes Profinet.	A metodologia utilizada obteve êxito na identificação da presença ou ausência de anomalias no tipo de rede pesquisado.

(continua)

7	Laboissiere, Fernandes e Lage (2015)	Previsão máxima e mínima do preço da ação de empresas de distribuição de energia brasileiras baseadas em redes neurais artificiais.	Propor uma metodologia que preveja os preços das cotações máxima e mínima de três empresas brasileiras de distribuição de energia, negociadas na BM&FBovespa.	A preparação e análise preliminar de dados para as RNA podem ser consideradas como uma metodologia eficaz para estimar a faixa de variação dos preços de ações.
8	Medeiros (2016)	Previsão de demanda no médio prazo utilizando redes neurais artificiais em sistemas de distribuição de energia elétrica.	Desenvolver uma ferramenta computacional de apoio aos especialistas na área de planejamento estratégico em sistemas de distribuição de energia elétrica, utilizando RNA para previsão de demanda.	O modelo baseado em RNA possibilitou a previsão da demanda de energia elétrica para um ano à frente, bem como estimou o crescimento de demanda da região.
9	Lui (2016)	Previsão de material particulado a curto e médio prazos com o uso de redes neurais artificiais.	Avaliar as características do material particulado da cidade de São Carlos/SP e criar modelos de previsão da concentração desse material utilizando como ferramenta as RNA.	Os modelos baseados em RNA obtiveram bons resultados na previsão da concentração de material particulado presente no ar.
10	Chaves (2016)	Monitoramento e classificação de falhas em estruturas utilizando redes neurais artificiais.	Apresentar um sistema baseado em RNA, aplicando-o na identificação de falhas estruturais em um edifício de dois andares.	O modelo baseado em rede neural artificial demonstrou precisão, robustez e um bom desempenho para o problema proposto.

(continua)

11	Vale (2016)	Reconstrução e reconhecimento de imagens binárias utilizando o algoritmo máquina de Boltzmann.	Utilizar algoritmos conhecidos como Máquina de Boltzmann para reconstruir e classificar padrões como de imagens.	Os algoritmos Máquina de Boltzmann foram capazes de classificar padrões treinados e apresentaram ótimos resultados na reconstrução dos padrões com um rápido tempo de execução.
12	Maia (2016)	Detecção de dano estrutural em estruturas planas utilizando redes neurais.	Criar um modelo baseado em RNA para detectar danos em estruturas de vigas e pórticos planos.	Os modelos baseados em RNA construídos apresentaram bons resultados nas fases de treinamento, validação e generalização.
13	Tavares (2016)	Níveis de governança corporativa e desempenho: uma validação por meio de redes neurais artificiais.	Desenvolver um modelo de rede neural para reconhecer o padrão de governança corporativa do mercado de ações brasileiro e classificar as empresas que não aderiram voluntariamente aos segmentos da BM&FBovespa.	O modelo baseado em rede neural artificial verificou que as empresas dos níveis de governança corporativa não tiveram nenhuma relação positiva e estatisticamente significativa com qualquer uma das medidas de desempenho utilizadas.
14	Felizardo (2017)	Um estudo sobre arquitetura de redes neurais aplicado a previsão do retorno de ações brasileiras.	Prover percepções e considerações para que futuras aplicações de redes neurais em finanças tenham uma boa base de referência para a escolha e seleção de suas arquiteturas.	A arquitetura influencia no desempenho de uma rede neural artificial, mostrando-se um fator de grande impacto na assertividade.

(continua)

15	Bezerra (2017)	Uma abordagem computacional para previsão de demanda de energia elétrica e apoio à tomada de decisão no mercado de curto prazo no Brasil.	Propor uma abordagem computacional para previsão de demanda de energia elétrica por classe de consumo para servir de apoio à tomada de decisão no mercado de curto prazo no Brasil.	O modelo baseado em rede neural artificial conseguiu aprender o comportamento dos dados de todas as classes de consumo, demonstrando a sua eficiência quando comparadas com a demanda real da distribuidora.
16	Defilippo (2017)	Previsão da demanda de energia elétrica por combinações de modelos lineares e de inteligência computacional.	Utilizar RNA e algoritmos genéticos para modelar dados históricos de carga e de clima.	O modelo combinado de rede neural artificial, algoritmos genéticos e métodos lineares tradicionais obteve bons resultados termos médios de acurácia e sensibilidade a erros de medição.
17	Muntaser, Da Silva e Penedo (2017)	Aplicação de Redes Neurais na Previsão das Ações do Setor de Petróleo e Gás da Bm&FBovespa.	Desenvolver um modelo de RNA para previsão de preços das empresas brasileiras que atuam no setor de petróleo e gás da bolsa de valores.	O modelo de rede neural artificial proposto obteve resultados satisfatórios, com erros ínfimos, mostrando que as RNA são uma ferramenta eficaz na previsão do comportamento do mercado de ações brasileiro para o setor analisado.

(continua)

(conclusão)

18	Lanzetta (2018)	Uma comparação entre modelos de previsão de preços do boi gordo paulista.	Verificar se para o caso específico da arroba do boi gordo no estado de São Paulo, modelos de previsão de constituição mais complexa superam os modelos mais simples em horizontes diversos.	Modelos relativamente mais complexos como RNA não necessariamente apresentam melhor desempenho se comparados a modelos mais simples; a classificação relativa muda conforme variam as medidas de ajuste e/ou horizonte de previsão além de vantagens associadas a combinação de diversos modelos.
19	Bessa (2018)	Previsão de vendas no varejo de moda com modelos de redes neurais.	Aplicar técnicas de previsão e verificar suas respectivas acuracidades por meio de redes neurais, tanto diretas e não recorrentes.	A análise dos diversos métodos de previsão para cada série de produto mostrou que os métodos avançados superaram os métodos estatísticos clássicos.
20	Disconzi (2018)	Previsão dos preços de <i>commodities</i> agrícolas brasileiras no mercado futuro utilizando redes neurais artificiais.	Analisar a contribuição das RNA para a previsão de preços de <i>commodities</i> agrícolas no mercado futuro, avaliando o ajuste das redes como ferramenta de estratégia no processo de tomada de decisão.	Foram desenvolvidas RNA com desempenho classificados como ótimos para todas as <i>commodities</i> consideradas, o que demonstrou sua alta previsibilidade.

Fonte: Elaborado pelo autor.

Da análise do Quadro 5, é possível perceber que os modelos preditivos baseados em RNA têm sido bastante explorados atualmente. Nesse sentido, Oliveira, Nobre e Zárte (2013)

apontam que, comparada às técnicas padrões, as RNA têm se destacado por mostrarem mais eficiência nas previsões de tendências e comportamentos. Dessa forma, é interessante destacar algumas características dos estudos elencados no Quadro 5.

A dissertação de Arantes (2013) investigou as previsões fora da amostra da curva de juros utilizando as RNA. Tais previsões geradas por modelos baseados em redes neurais foram comparadas com modelos produzidos utilizando técnicas estatísticas convencionais. Os dados utilizados na pesquisa foram observações diárias das taxas de contratos de depósitos interbancários, coletados na plataforma da BM&FBovespa. O autor conclui sua pesquisa afirmando que os modelos estimados através de RNA conseguiram superar as previsões realizadas por *random walk* e foram capazes de realizar boas previsões para todos os horizontes testados.

Por sua vez, a tese de doutorado de Ferro (2013) buscou encontrar uma rede neural artificial que melhor se aplicasse à maximização do aproveitamento dos tipos de argilas utilizados num polo industrial cerâmico e no aumento da qualidade dos pisos e revestimentos cerâmicos ali produzidos. Os dados utilizados na pesquisa foram obtidos dos proprietários das indústrias pertencente ao polo cerâmico, de modo que o autor criou um conjunto de variáveis físicas a partir de tais dados. O autor conclui seu estudo sustentando que os modelos construídos com RNA forneceram boas soluções com pequenos desvios em relação ao padrão de saída previamente estabelecido.

A dissertação de Gambogi (2013) objetivou criar um modelo de predição de preços de ativos financeiros e sistemas de *trading* para orientar a tomada de decisão no mercado de ações. O objetivo principal foi propor um sistema de *trading* seguidor de tendência de curto prazo que apresentasse boas métricas de desempenho financeiro, mediante o emprego de RNA multicamadas. Os dados utilizados foram um conjunto de regras utilizadas para a obtenção de lucros nas negociações de um ativo financeiro, denominado *trading*, e o índice mais representativo do mercado de ações estadunidense, chamado de *Standard & Poor's*. O autor finaliza sua pesquisa concluindo que o modelo preditivo baseado em rede neural artificial obteve uma boa taxa de acerto considerando-se os dados utilizados.

O estudo de Piccoli (2014) buscou propor uma rede neural para prever a direção do movimento do contrato de dólar futuro num horizonte de um mês. Os dados utilizados no trabalho foram ativos do mercado financeiro no período de janeiro de 2001 a setembro de 2013. Para o cálculo dos resultados financeiros das estratégias foram empregados dados de preços referenciais disponibilizados pela BM&FBovespa. O autor conclui mostrando que o modelo proposto baseado em rede neural artificial identificou variáveis que ajudam a prever o

movimento do câmbio futuro, fornecendo evidências de que é possível prever com uma taxa razoável de acerto (superior a 60%) o movimento do contrato de dólar futuro negociado na BM&FBovespa.

Na área da Engenharia Florestal, a dissertação de Miranda (2015) buscou avaliar a eficiência do uso da modelagem através de RNA e por modelos de regressão na quantificação dos estoques de biomassa seca e carbono. O estudo utilizou um total de 74 árvores pertencentes a diferentes espécies registradas, sendo treinadas 300 RNA do tipo MLP para cada variável dependente. As 10 redes com melhores resultados foram retidas para a análise das medidas de precisão. O autor conclui a pesquisa afirmando que a utilização de RNA na estimativa de estoques de biomassa seca e carbono de árvores individuais foi considerada eficiente, apresentando estimativas bastante precisas.

Turcato (2015) utilizou as RNA em sua dissertação para desenvolver e avaliar uma metodologia com o propósito de identificar anomalias no tráfego de redes Profinet, as quais são bastante utilizadas na automação de plantas industriais. A metodologia desenvolvida foi fundamentada na análise das características de comunicação do protocolo Profinet e na identificação e classificação de padrões, sendo composta por seis fases: coleta de dados do tráfego da rede, extração dos atributos do tráfego da rede, análise e seleção dos principais atributos, preparação dos dados para o treinamento das RNA, treinamento das RNA e análise dos resultados (TURCATO, 2015, p. 95). O autor conclui seu trabalho afirmando que a metodologia utilizada obteve êxito na identificação da presença ou ausência de anomalias no tipo de rede pesquisado.

Em seu artigo, Laboissiere, Fernandes e Lage (2015) propõem um modelo preditivo para os preços das cotações máxima e mínima de rês empresas brasileiras de distribuição de energia – CPFL Energia (Companhia Paulista de Força e Luz), CEB (Companhia Energética de Brasília) e COSERN (Companhia Energética do Rio Grande do Norte) -, que são negociadas na bolsa de valores oficial brasileira. Os dados utilizados foram informações históricas provenientes das negociações realizadas na BM&FBovespa no período de janeiro de 2008 a setembro de 2013, as quais geraram um banco de dados. Tais dados também incluíram o IBovespa e o IEE (Índice de Energia Elétrica) no recorte temporal da pesquisa. Como resultado, os autores concluíram que a preparação e análise preliminar de dados para as RNA podem ser consideradas como uma metodologia eficaz para estimar a faixa de variação dos preços de ações, de modo a orientarem a tomada de decisões e os investimentos no setor de energia elétrica.

Por sua vez, a dissertação de Medeiros (2016) relata a construção de um modelo baseado em RNA para a previsão da demanda de energia elétrica no médio prazo de uma região alimentada por três subestações reais. Os dados da pesquisa foram coletados de um banco de dados de potência ativa, no período de 2008 a 2013. O modelo computacional gerado utilizou RNA do tipo MLP implementadas no ambiente MATLAB. Segundo o autor, o resultado obtido possibilitou a previsão da demanda de energia elétrica para um ano à frente (52 semanas), bem como estimou o crescimento de demanda de energia elétrica da região.

Na área ambiental, a tese de Lui (2016) objetivou avaliar as características do material particulado da cidade de São Carlos/SP e criar modelos de previsão da concentração desse material utilizando como ferramenta as RNA. Foram coletados dados diários de material particulado no período de 2014 a 2015, os quais foram comparados com uma série de dados de quase dez anos de coleta disponíveis em um banco de dados, compreendendo o período de 1997 a 2006. Os modelos utilizaram RNA implementadas no ambiente MATLAB e, segundo a autora, apresentaram bons resultados na previsão da concentração de material particulado presente no ar.

A dissertação de Chaves (2016) objetivou a criação de uma ferramenta para o monitoramento e classificação de falhas estruturais em um edifício de dois andares utilizando RNA. Os dados da pesquisa foram obtidos a partir de um modelo matemático que utiliza um sistema de equações diferenciais ordinárias para modelar uma estrutura predial. A autora conclui seu trabalho indicando que o modelo baseado em rede neural artificial demonstrou precisão, robustez e um bom desempenho para o problema proposto.

Vale (2016), em sua dissertação, utiliza o algoritmo máquina de Boltzmann para a reconstrução e classificação de padrões de imagens. O autor realiza simulações computacionais que comparam RNA com a máquina de Boltzmann, analisando os tempos de execuções e as taxas de acertos de bits. Como resultado, o autor afirma que os algoritmos máquina de Boltzmann foram capazes de classificar padrões treinados e apresentaram ótimos resultados na reconstrução dos padrões com um rápido tempo de execução.

Em sua dissertação, Maia (2016) propôs a criação de um modelo baseado em RNA para detectar danos em estruturas de vigas e pórticos planos. Para a fase de treinamento, o autor utilizou dados provenientes de modelos numéricos das estruturas estudadas e suas propriedades dinâmicas. Para a fase de teste, foram utilizados dados advindos tanto de modelos numéricos quanto de estruturas ensaiadas experimentalmente. Como resultado, o autor afirma que os modelos baseados em RNA construídos apresentaram bons resultados nas fases de treinamento, validação e generalização.

A dissertação de Tavares (2016) relata o desenvolvimento de um modelo de rede neural para reconhecer o padrão de governança corporativa do mercado de ações brasileiro e classificação das empresas que não aderiram voluntariamente aos segmentos da BM&FBovespa. A pesquisa utilizou uma amostra de 572 empresas e o recorte temporal considerado foi o período de 2001 a 2015. Os resultados da rede neural artificial para 2015 foram comparados com os resultados conforme classificados na bolsa de valores oficial brasileira. Como conclusão, o autor indica que o modelo baseado em rede neural verificou que as empresas dos níveis de governança corporativa não tiveram nenhuma relação positiva e estatisticamente significativa com qualquer uma das medidas de desempenho utilizadas.

O estudo de Felizardo (2017) investigou o impacto da escolha de arquiteturas de RNA para a resolução de problemas na área de finanças. O autor apresenta uma análise estatística sobre as características que influenciam o desempenho das RNA em termos de assertividade, objetivando determinar a melhor arquitetura para a previsão do retorno de ações financeiras de alguns bancos negociadas na bolsa de valores oficial brasileira. Dados históricos de 2013 e 2014 foram utilizados para o treinamento das redes, enquanto que os de 2015 foram empregados para a validação dos resultados e cálculo de erros. O autor conclui sua pesquisa afirmando que a arquitetura influencia diretamente no desempenho de uma rede neural artificial, mostrando-se um fator de grande impacto na assertividade.

Análogo ao trabalho de Medeiros (2016), a dissertação de Bezerra (2017) propôs uma abordagem computacional para a previsão da demanda de energia elétrica por classe de consumo para servir de apoio à tomada de decisão no mercado de curto prazo no Brasil. O trabalho utilizou dados históricos de uma distribuidora de energia elétrica, sendo escolhidas como variáveis de entrada da rede neural artificial a receita do fornecimento de energia, o número de unidades consumidoras e a tarifa média de fornecimento de energia. A rede neural empregada no modelo foi do tipo MLP com algoritmo *backpropagation*, com duas camadas ocultas, contendo cada uma, 32 e 22 neurônios, respectivamente. O resultado alcançado foi um modelo baseado em rede neural artificial que conseguiu aprender o comportamento dos dados de todas as classes de consumo, demonstrando a sua eficiência quando comparadas com a demanda real da distribuidora considerada na pesquisa.

Também, a tese de doutorado de Defilippo (2017) utilizou RNA e algoritmos genéticos para a criação de um modelo preditivo de demanda de energia elétrica. Foram utilizados dados históricos de três bases de dados, sendo uma brasileira, uma estadunidense e uma do leste europeu. Ao todo, o autor implementou um conjunto contendo 24 RNA em paralelo. A conclusão aponta que a modelo combinado de rede neural artificial, algoritmos genéticos e

métodos lineares tradicionais obteve bons resultados em termos médios de acurácia e sensibilidade a erros de medição.

O trabalho de Muntaser, Da Silva e Penedo (2017) desenvolveu um modelo de rede neural artificial para a previsão de preços de todas as empresas brasileiras que atuam no setor de petróleo e gás da bolsa de valores. Os dados utilizados na pesquisa foram coletados de bases de dados específicas, sendo considerados os dentro do período de janeiro de 2010 a dezembro de 2015. Os autores trabalharam com um conjunto de 24 variáveis definidas, sendo o modelo de rede neural escolhido o do tipo *feedforward* multicamadas, contendo uma camada de entrada, uma camada oculta e uma camada de saída. A conclusão indicou que o modelo de rede neural artificial proposto obteve resultados satisfatórios, com erros ínfimos, mostrando que as RNA são uma ferramenta eficaz na previsão do comportamento do mercado de ações brasileiro para o setor analisado.

A dissertação de Lanzetta (2018) realizou uma comparação do desempenho de modelos de previsão de RNA e de suavização exponencial. O objetivo foi verificar se, para o caso específico da arroba do boi gordo no estado de São Paulo, modelos de previsão de constituição mais complexa superam os modelos mais simples em horizontes diversos. O estudo utilizou dados históricos do preço da arroba do boi gordo negociados na bolsa de valores oficial brasileira no período de janeiro de 2010 a dezembro de 2015, sendo o algoritmo *backpropagation* utilizado para o treinamento dos sistemas de redes neurais construído. O autor conclui seu trabalho apontando que modelos relativamente mais complexos como RNA não necessariamente apresentam melhor desempenho se comparados a modelos mais simples e que a classificação relativa muda conforme variam as medidas de ajuste e/ou horizonte de previsão além de vantagens associadas a combinação de diversos modelos.

Na área das ciências econômicas, a dissertação de Bessa (2018) avaliou dez métodos para a previsão de vendas semanais de uma empresa de vestuário, a fim de determinar o mais eficiente entre eles. Entre os métodos comparados, haviam modelos estatísticos clássicos e modelos baseados em RNA. Os dados utilizados na pesquisa foram dados históricos de vendas semanais compreendidos entre janeiro de 2007 a dezembro de 2016. A autora finaliza seu trabalho afirmando que a análise dos diversos métodos de previsão para cada série de produto mostrou que os métodos avançados superaram os métodos estatísticos clássicos.

Por sua vez, o estudo de Disconzi (2018) analisou a contribuição das RNA para a previsão de preços de *commodities* agrícolas no mercado futuro, avaliando o ajuste das redes como ferramenta de estratégia no processo de tomada de decisão. Os dados utilizados na pesquisa foram coletados de um banco de dados público, sendo considerados apenas os

referentes às commodities açúcar, algodão, arroz, café, milho, soja e trigo, no período compreendido entre junho de 1996 a setembro de 2017. As RNA testadas foram do tipo MLP com algoritmo de treinamento *backpropagation* e a técnica de otimização Levenberg-Marquardt. A autora conclui seu trabalho indicando que foram desenvolvidas RNA com desempenho classificados como ótimos para todas as *commodities* consideradas, demonstrando, portanto, sua alta previsibilidade. Outra conclusão importante foi que as RNA demonstraram ser uma ferramenta eficaz que pode auxiliar com bastante sucesso os interessados em investir no mercado de *commodities* através da simulação do comportamento dos preços.

3 METODOLOGIA

Este capítulo apresenta e detalha a metodologia utilizada no desenvolvimento da presente pesquisa. Em destaque, as seções seguintes mostram os critérios de escolha de variáveis, topologias, algoritmo de treinamento, funções de ativação, quantidade de camadas e neurônios utilizados nas RNA do tipo MLP e quantidade de células nas RNA do tipo LSTM empregadas na criação do modelo preditivo proposto. Em seguida, apresentam-se as fontes de dados utilizadas, a técnica de coleta de dados e os critérios de organização de tais informações para a construção do modelo de predição baseado em RNA.

3.1 Classificação da pesquisa

Referente à forma de abordagem, esta pesquisa é classificada como quantitativa-descritiva, uma vez que dados secundários são utilizados como fonte de informações. Conforme citado em Fontelles et al. (2009), a pesquisa quantitativa trabalha com variáveis retratadas como dados numéricos e utiliza recursos rígidos e procedimentos estatísticos para a sua classificação e análise. Já a pesquisa descritiva, apresenta o objetivo de somente observar, registrar e caracterizar certo fenômeno que ocorre em uma população ou amostra. Gil (2008) complementa dizendo que os estudos descritivos são os que buscam criar associações entre determinadas variáveis.

Por conseguinte, vários testes empíricos foram realizados a fim de determinar o conjunto de variáveis e o melhor tipo de rede neural artificial encontrado para a criação do modelo preditivo proposto para a cotação dos preços máximos e mínimos das ações das empresas escolhidas. Tais aspectos são detalhadamente apresentados na próxima seção.

3.2 Aspectos metodológicos

Como apresentado no capítulo introdutório, o presente estudo visa descrever uma metodologia fundamentada em RNA que possibilite a construção de um modelo preditivo para a estimação dos preços máximos e mínimos de ações das empresas estatais brasileiras previamente selecionadas para a pesquisa. Para tanto, torna-se necessário definir as variáveis mais relevantes para o processo de construção do modelo.

Dessa forma, as variáveis de entrada elegidas são: preços históricos de abertura e fechamento das ações, preços máximos históricos, preços mínimos históricos, índice histórico da BOVESPA - Bolsa de Valores de São Paulo, agora chamada de B3 - (IBOVESPA) e cotação histórica do dólar americano no período temporal pesquisado, que compreende janeiro de 2013 a dezembro de 2017, perfazendo, portanto, um período de 5 anos de negociações financeiras realizadas na B3. Esquemáticamente, tais variáveis são mostradas no Quadro 6, bem como a fonte de coleta de cada uma delas.

Quadro 6 – Variáveis de entrada das RNA utilizadas na construção do modelo preditivo.

Variável	Fonte de coleta
Preço de abertura	Site oficial da B3 (Brasil, Bolsa, Balcão) ¹
Preço de fechamento	
Preço máximo	
Preço mínimo	
Índice BOVESPA (IBOVESPA)	Site Yahoo! Finanças ²
Cotação do dólar americano	Site oficial do Banco Central do Brasil ³

Fonte: Elaborado pelo autor.

¹ Brasil, Bolsa, Balcão (2019).

² Yahoo! Finanças (2019).

³ Banco Central do Brasil (2019).

Como salientam Laboissiere, Fernandes e Lage (2015), o IBOVESPA é o índice mais significativo do mercado de ações brasileiro, incluindo a oscilação de todos os preços das ações das organizações listadas na B3, atual bolsa de valores oficial do Brasil, de modo a fornecer uma visão integral do mercado acionário nacional. De maneira geral, um índice tem por função indicar se uma ação específica ou conjunto de ações está se desvalorizando ou valorizando no decorrer do tempo.

Ademais, conforme indicam Laboissiere, Fernandes e Lage (2015), a escolha do dólar americano como variável de entrada para o modelo preditivo é interessante devido à grande presença de investidores estrangeiros nas negociações que envolvem as ações de empresas brasileiras listadas na B3.

Dessa maneira, determinados os atributos de entrada para o modelo de predição a ser construído, as duas saídas buscadas identificadas são, obviamente, os preços máximos e mínimos das ações financeiras escolhidas das empresas estatais selecionadas para o estudo.

Assim, a Figura 16 apresenta, esquematicamente, o fluxograma da metodologia aplicada nesta pesquisa. Nele, é possível observar os passos percorridos, cujo início se dá na coleta dos dados e finaliza no alcance dos resultados obtidos pelo modelo preditivo baseado em RNA.

Figura 16 – Fluxograma da metodologia proposta para a construção do modelo preditivo.



Fonte: Adaptado de Laboissiere, Fernandes e Lage (2015).

Na Figura 16, o bloco de dados históricos indica que foram obtidas as cotações históricas das ações das empresas estatais brasileiras escolhidas, os valores históricos do IBOVESPA e as cotações históricas do dólar americano. Os valores históricos das ações selecionadas foram obtidos em Brasil, Bolsa, Balcão (2019), site oficial da B3. Por sua vez, os registros anteriores do IBOVESPA foram conseguidos em Yahoo! Finanças (2019) e os valores históricos do dólar americano em Banco Central do Brasil (2019), site oficial do Banco Central do Brasil.

Ademais, os dados obtidos foram armazenados em planilhas, sendo dispostos em ordem cronológica crescente. Como citado anteriormente, tais dados armazenados referem-se ao período de janeiro de 2013 a dezembro de 2017.

A etapa de preparação dos dados mostrada no fluxograma da Figura 16 indica a separação e organização das informações obtidas em dois subconjuntos. O primeiro subconjunto contém os dados para treinamento das RNA, de modo a gerar o padrão de aprendizagem das mesmas. O segundo subconjunto de dados é utilizado na validação/testes das redes neurais, sendo composto por dados que ainda não foram utilizados, objetivando determinar o grau de desempenho das redes (FINOCCHIO, 2010).

Nesse sentido, para a escolha do tamanho do subconjunto de treinamento, Finocchio (2010) indica uma variação de 60% a 90% do conjunto original de dados. Para o tamanho do subconjunto de validação/testes, o mesmo autor indica entre 10% a 40% da massa total de dados colhidos. Já Turcato (2015) menciona que, geralmente, 80% a 90% dos dados coletados são utilizados para o treinamento da rede, sendo os 10% a 20% que sobram utilizados para validação e verificação. Para este trabalho, 85% dos dados originais foram escolhidos para compor o subconjunto de treinamento, enquanto que os 15% restantes compõem o subconjunto de validação/testes.

3.3 RNA escolhidas e parâmetros de configuração

Na Figura 16, o bloco referente às RNA indica a configuração das redes neurais construídas para o desenvolvimento do modelo proposto. Tal etapa inclui a escolha de topologia, quantidade de camadas e neurônios, algoritmo de treinamento e função de ativação. Por fim, finalizados os testes de treinamento e validação, essa etapa indica também a escolha da rede neural artificial que apresentou os melhores resultados na previsão dos preços máximos e mínimos de cada ação considerada.

Nesse contexto, a presente pesquisa utilizou RNA com arquitetura *feedforward* do tipo MLP, com algoritmo de treinamento *backpropagation* utilizando a técnica de otimização de Levenberg-Marquardt. Cada uma delas foi configurada de modo a atingir um erro quadrático médio (10^{-12}) ou um número máximo de 250 épocas. Como mencionado por Turcato (2015), uma época corresponde à apresentação à rede neural de todos os pares do tipo (entrada, saída) do conjunto de treinamento durante o processo de aprendizagem.

Também foram utilizadas RNA do tipo LSTM, as quais foram configuradas de maneira análoga às RNA do tipo MLP e submetidas aos mesmos critérios de treinamento, número máximo de épocas, limite de erro máximo permitido e métricas de desempenho. O treinamento de tais redes utilizou o método de otimização ADAM (*Adaptive Moment Estimation*), cujo algoritmo melhora funções estocásticas. Resultados empíricos demonstraram que tal otimização apresenta índices satisfatórios de desempenho e performance (DAMETTO, 2018).

Ademais, foram testadas RNA do tipo MLP com topologias contendo uma ou duas camadas ocultas. As redes contendo apenas uma camada intermediária foram configuradas com 3 a 30 neurônios. Já as redes neurais com duas camadas ocultas, foram configuradas com 3 a 15 neurônios na primeira camada e 3 a 27 na segunda. O número de neurônios em cada camada varia de 3 em 3 em todas as topologias testadas. É importante destacar que as RNA do tipo LSTM utilizadas foram configuradas com 10 células e com o algoritmo de otimização ADAM.

Além disso, outro critério fundamental na configuração de RNA é a escolha das funções de ativação dos neurônios em cada camada. Neste trabalho, para as RNA com arquitetura MLP, a função de ativação escolhida para os neurônios das camadas ocultas foi do tipo sigmóide. Já para os neurônios da camada de saída, a função de ativação é do tipo linear. Todas as RNA com arquitetura LSTM também utilizaram a função de ativação do tipo sigmóide.

Determinados todos os parâmetros das RNA a serem treinadas, foi necessário o estabelecimento de critérios para o julgamento do desempenho de cada rede. Dessa forma, foram executados cálculos da Raiz do Erro Médio Quadrático (RMSE – *Root Mean Square Error*), Erro Absoluto Médio (MAE - *Mean Absolute Error*) e Erro Absoluto Percentual Médio (MAPE - *Mean Absolute Percentual Error*), cujas equações são apresentadas abaixo:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |P_i - \hat{P}_i| \quad (3.1)$$

$$\text{MAPE} = \frac{100}{N} \sum_{i=1}^N \frac{|P_i - \hat{P}_i|}{P_i} \quad (3.2)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - \hat{P}_i)^2} \quad (3.3)$$

Nas equações 3.1 a 3.3, os parâmetros presentes são:

- P_i : preço real;
- \hat{P}_i : preço estimado pela rede neural artificial;
- N : número de amostras utilizadas para a validação da rede neural artificial.

A fim de melhorar o processo de previsão, uma rede neural artificial foi treinada para cada ação individual. Após a seleção das RNA do tipo MLP que apresentaram os melhores desempenhos, as mesmas foram submetidas novamente a 5 treinamentos, de modo a se efetuar a verificação da repetição ou melhora dos resultados anteriormente obtidos. O mesmo procedimento foi realizado com as RNA do tipo LSTM, as quais foram configuradas com características mais próximas possíveis das RNA do tipo MLP. É importante ressaltar que todas as RNA com arquitetura MLP utilizadas foram configuradas utilizando-se a *NNTOOL* do MATLAB, versão 8.5.0.19 (R2015a).

Por sua vez, as RNA do tipo LSTM foram desenvolvidas no ambiente RStudio⁴, versão 1.2.1335. A implementação dos seus *scripts* utilizou a linguagem de programação orientada a objetos Python 3⁵, cujo modelo foi projetado utilizando a especificação de redes neurais já presente na biblioteca TensorFlow⁶ sob a interface da biblioteca Keras⁷. O pacote *replicate*⁸ foi instalado no RStudio®, de modo a permitir a utilização da referida linguagem de programação. É muito importante ressaltar que tais componentes devem ser previamente instalados e configurados adequadamente no ambiente RStudio® para a execução e funcionamento do modelo baseado em redes neurais do tipo LSTM.

⁴ <https://www.rstudio.com/products/rstudio/download/>

⁵ <https://www.python.org/downloads/>

⁶ <https://www.tensorflow.org>

⁷ <https://keras.io>

⁸ https://rstudio.github.io/reticulate/articles/python_packages.html

4 RESULTADOS

Este capítulo apresenta os resultados obtidos pelo modelo preditivo proposto construído baseado em RNA, tanto as do tipo MLP quanto as do tipo LSTM. Cada seção apresenta os resultados alcançados pelas melhores redes neurais treinadas e validadas, conforme os parâmetros de configurações apresentados no capítulo anterior, separados para cada ação individual. Para melhor apresentação, tais resultados foram tabulados em planilhas, sendo os gráficos associados também gerados nessa ferramenta computacional.

Nas tabelas de resultados apresentadas nas próximas seções, para as RNA do tipo MLP treinadas, o par presente na coluna rotulada de “Número de neurônios” representa a quantidade de neurônios presentes na primeira e segunda camadas ocultas, respectivamente. Por exemplo, o par (6, 9) indica que a rede neural artificial MLP utilizada possui 6 neurônios na primeira camada oculta e 9 neurônios na segunda camada também oculta. Já um par (15, -), indica uma rede neural artificial MLP contendo apenas uma camada intermediária com 15 neurônios presentes. Para favorecer a visualização dos resultados, os menores valores de erros (MAE, MAPE e RMSE) apresentados pelas RNA empregadas nas simulações aparecem destacados em negrito.

4.1 Resultados obtidos para a previsão da ação BBAS3

Conforme mencionado anteriormente, a efetividade das previsões realizadas pelas RNA utilizadas na criação do modelo proposto foi analisada considerando-se os cálculos das métricas MAE, MAPE e RMSE. Dessa maneira, os resultados das RNA do tipo MLP com uma e duas camadas intermediárias que apresentaram os melhores valores para a ação BBAS3 (Banco do Brasil S. A.) são mostrados na Tabela 2. Por sua vez, os melhores resultados obtidos pelas RNA recorrentes do tipo LSTM são apresentados na Tabela 3. As respectivas tabelas mostram os resultados para as previsões dos preços máximos e mínimos diários, as topologias utilizadas e os valores de MAE, MAPE e RMSE obtidos durante os processos de treinamento e validação das 5 melhores RNA testadas.

Tabela 2 – Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação BBAS3.

Número de neurônios	Preço máximo			Número de neurônios	Preço mínimo		
	MAE	MAPE (%)	RMSE		MAE	MAPE (%)	RMSE
(10, -)	0,364	1,155	0,509	(4, -)	0,374	1,169	0,482
(3, 3)	0,284	0,891	0,479	(3, 6)	0,478	1,529	0,592
(6, 9)	0,356	1,101	0,486	(6, 6)	0,717	2,317	0,865
(9, 9)	0,773	2,440	1,001	(12, 18)	0,568	1,809	0,738
(15, 9)	0,699	2,145	0,863	(15, 9)	0,725	2,359	0,849

Fonte: Adaptado de Laboissiere, Fernandes e Lage (2015).

Tabela 3 – Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação BBAS3.

Número de células		MAE	MAPE (%)	RMSE
10	Preço máximo	0.084	0.280	0.092
	Preço mínimo	0.079	0.267	0.084

Fonte: Elaborada pelo autor.

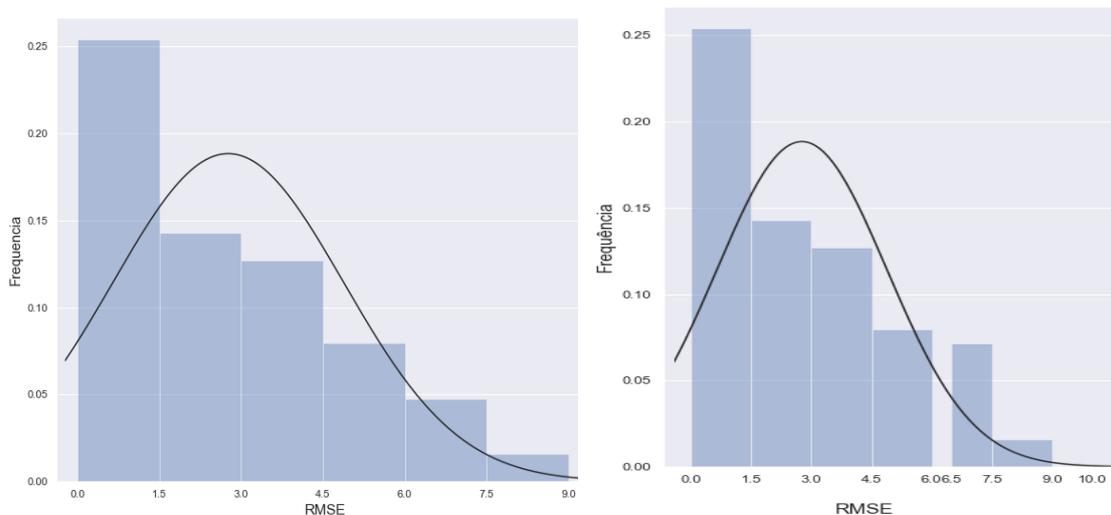
De todos os valores de RMSE apresentados pelas melhores redes neurais do tipo MLP, foi possível gerar os histogramas apresentados na Figura 17. A utilização de histogramas é interessante a fim de representar graficamente a distribuição das frequências absolutas ou relativas de um determinado conjunto de valores quantitativos (FREUND, 2006). Tais gráficos, comumente, são considerados como uma das principais ferramentas de qualidade em análises estatísticas, uma vez que geram informações visuais úteis sobre o comportamento de atividades e processos (CORRÊA, 2012).

Um ponto importante a salientar, é que a escolha dos valores de RMSE para a geração dos histogramas das frequências dos erros das ações utilizadas na pesquisa se deu porque, conforme citado por Faceli et al. (2011), tal métrica de erro é a mais frequentemente utilizada em modelos para avaliação de métodos de regressão. Nesse sentido, Chai e Draxler (2014) também reforçam que o RMSE geralmente apresenta melhores resultados na revelação das diferenças de desempenho do modelo construído e, ainda afirmam que, o RMSE é mais apropriado para retratar o desempenho do modelo do que a métrica MAE quando se espera que a distribuição dos erros seja gaussiana. No entanto, uma combinação de métricas de

desempenho, incluindo, mas não se limitando ao RMSE, frequentemente é necessária para avaliar a performance do modelo proposto (CHAI; DRAXLER, 2014).

Assim, a Figura 17 (a) exibe o histograma dos erros na previsão dos preços máximos de BBAS3, enquanto a Figura 17 (b) mostra o histograma referente aos erros resultantes na previsão dos preços mínimos diários da mesma ação.

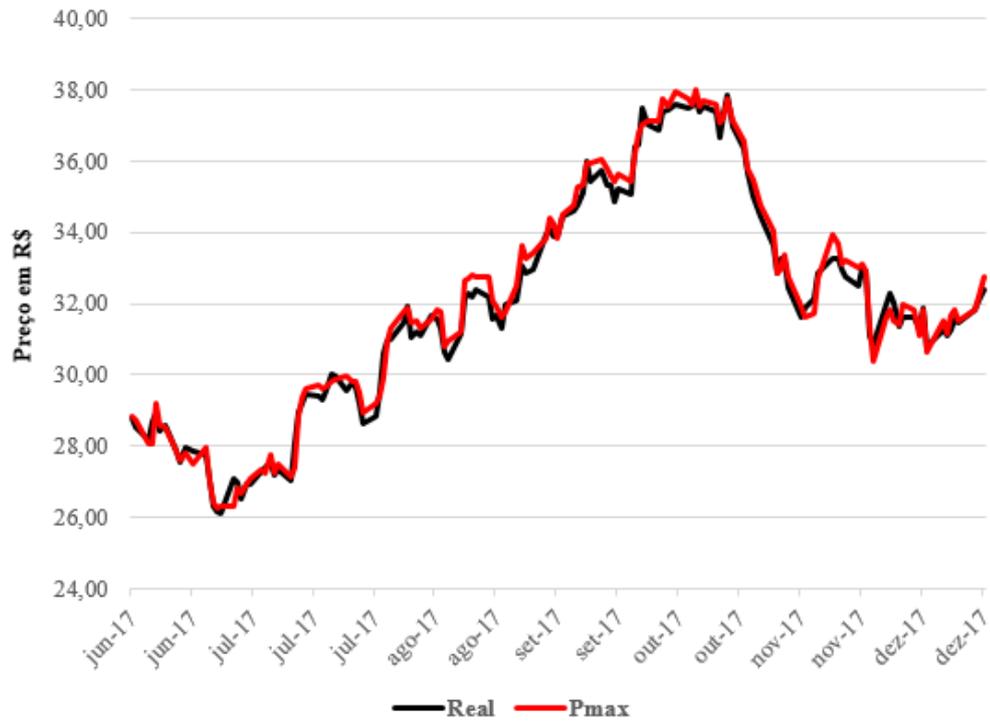
Figura 17 – Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de BBAS3.



Fonte: O autor.

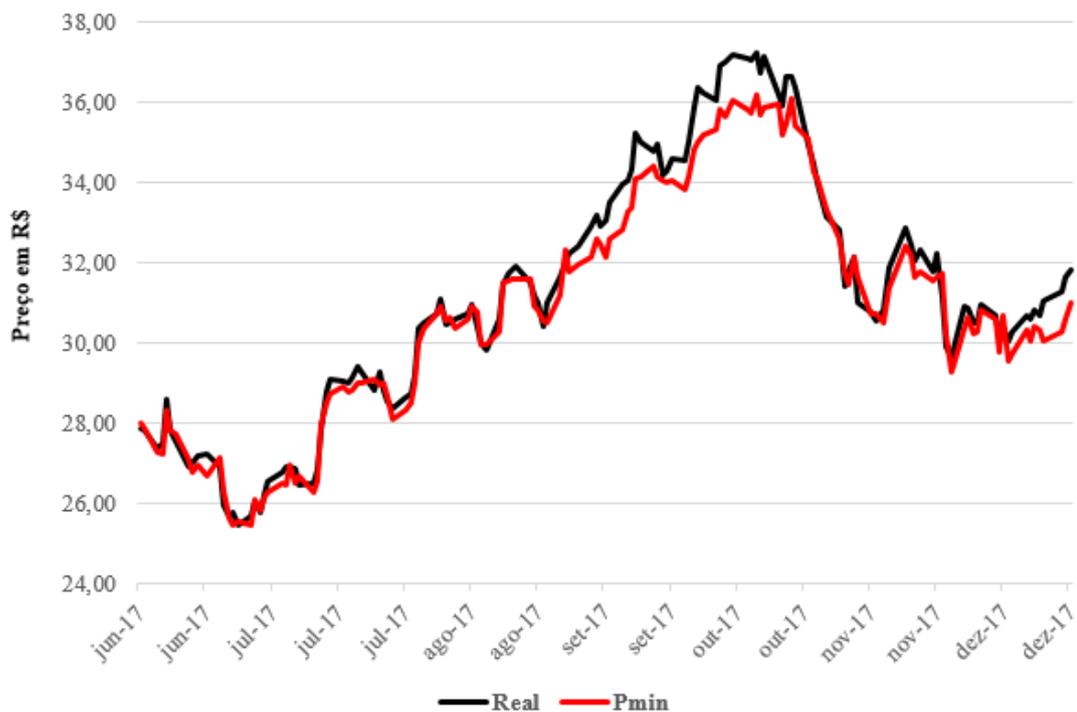
Ademais, dos resultados apresentados nas tabelas 2 e 3, foi possível gerar os gráficos que mostram os valores de predição para os preços máximos e mínimos da ação BBAS3 do Banco do Brasil S. A. As figuras 18 e 20 explicitam os gráficos dos melhores resultados obtidos para a estimação dos preços máximos da referida ação. As figuras 19 e 21 apresentam os gráficos dos melhores resultados alcançados para a previsão dos preços mínimos. As topologias das RNA utilizadas são citadas nas respectivas figuras.

Figura 18 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de BBAS3.



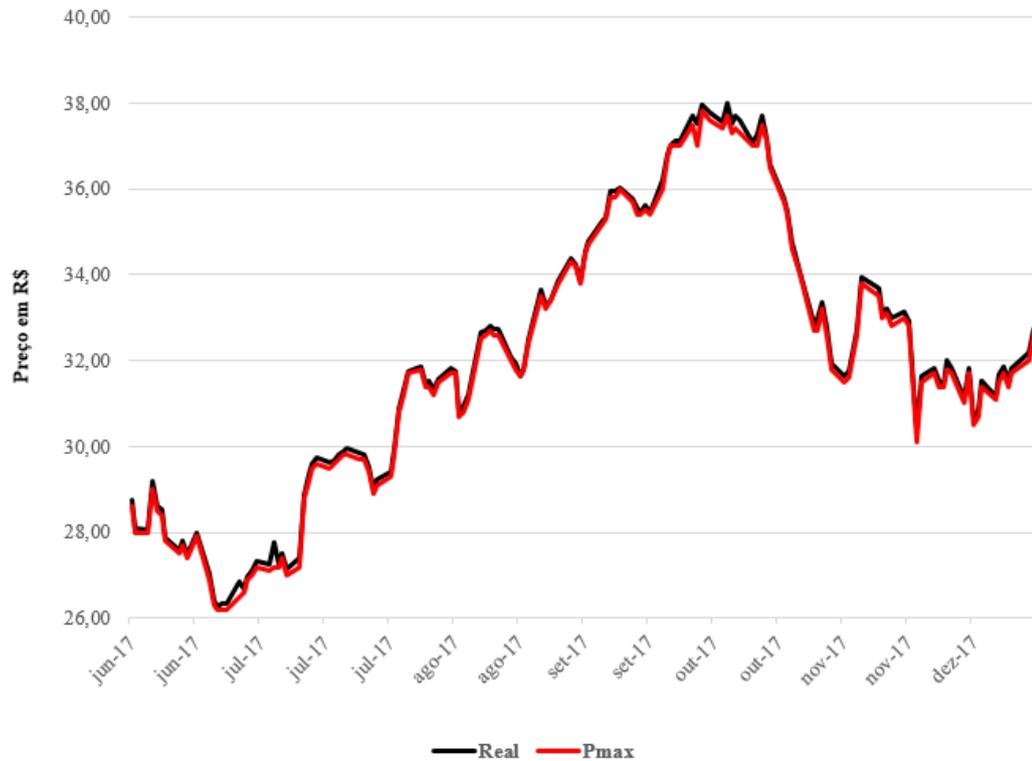
Fonte: O autor.

Figura 19 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de BBAS3.



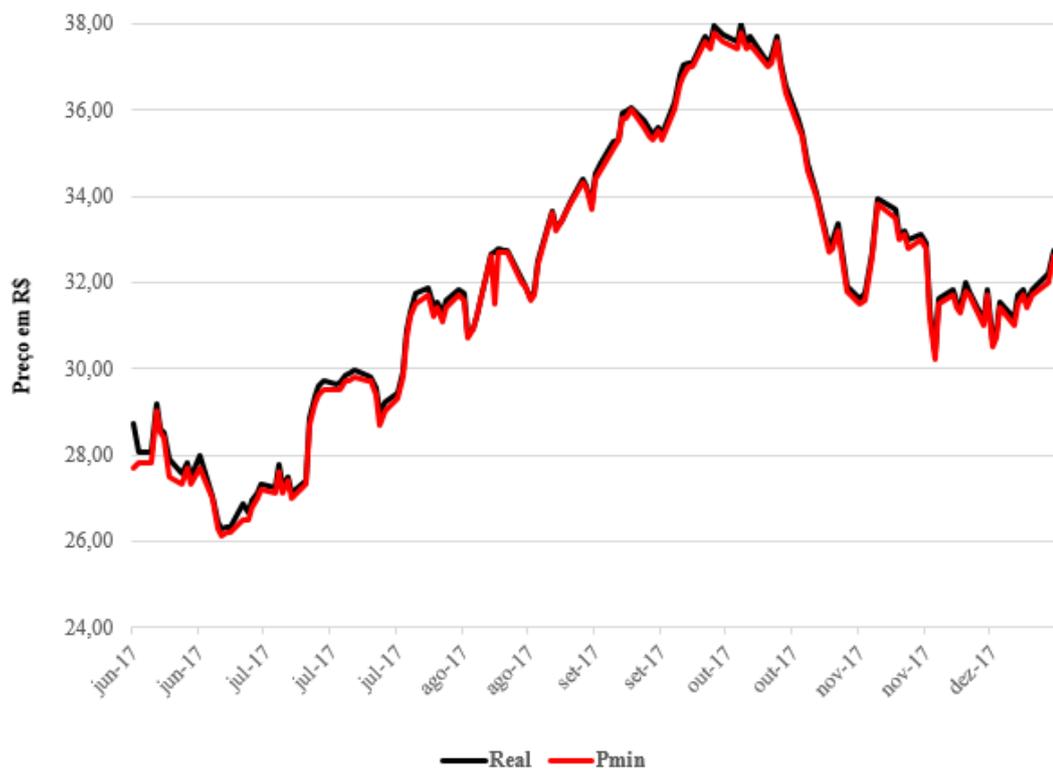
Fonte: O autor.

Figura 20 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de BBAS3.



Fonte: O autor.

Figura 21 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de BBAS3.



Fonte: O autor.

Da análise dos gráficos apresentados nas figuras 18 a 21, é possível observar que o modelo baseado em RNA do tipo MLP apresentou uma melhor previsão dos valores de preços máximos diários da ação BBAS3. Conforme exibido na Tabela 2, a rede neural artificial MLP que obteve os melhores valores de previsão para os preços máximos dessa ação possui duas camadas intermediárias, cada uma com 3 neurônios, representado por (3, 3) na quarta linha, primeira coluna. Tal rede apresentou o valor 0,891% para MAPE, o que demonstra que tal modelo foi capaz de prever 99,109% do comportamento real da ação. Das 5 melhores RNA do tipo MLP treinadas e validadas, mesmo a última colocada, previu 97,56% do comportamento real de BBAS3, como pode ser visto na sexta linha, terceira coluna da Tabela 2, cujo MAPE é 2,440%. Ademais, para a previsão dos preços mínimos de BBAS3, o modelo baseado na melhor rede neural artificial MLP construída apresentou MAPE igual a 1,169%. Tal resultado demonstra a capacidade de previsão em 98,831%.

Por sua vez, o modelo baseado em RNA do tipo LSTM exibiu valores melhores para a previsão dos preços mínimos diários da ação BBAS3. Conforme apresentado na Tabela 3, o menor valor de MAPE obtido para a previsão de tais preços foi 0,267%, representando a capacidade de previsão do modelo proposto em 99,72%. Para a previsão dos preços máximos diários da mesma ação, o menor valor de MAPE foi 0,280%, mostrando que o modelo baseado em RNA LSTM também conseguiu prever mais de 99% do comportamento real desse ativo. Dessa forma, como pode ser visto na Tabela 3, os valores dos erros apresentados pelas redes LSTM ficaram bem próximos para as duas previsões.

É importante destacar que, apesar de as RNA do tipo LSTM apresentarem melhores previsões para os preços máximos e mínimos diários de BBAS3, foi possível observar, a partir dos resultados elencados na Tabela 2, que o modelo proposto baseado em RNA do tipo MLP também obteve eficiência no poder de previsão do comportamento real da ação. Tal conclusão corrobora os resultados apresentados por Muntaser, Da Silva e Penedo (2017), os quais demonstraram que as RNA MLP são ferramentas eficazes na previsão das cotações de ações no mercado de ações brasileiro.

4.2 Resultados obtidos para a previsão da ação CSMG3

Os resultados das RNA do tipo MLP com uma e duas camadas intermediárias que apresentaram os melhores valores para as previsões dos preços máximos e mínimos da ação CSMG3 (Companhia de Saneamento de Minas Gerais - COPASA) são mostrados na Tabela 4. Por sua vez, os melhores resultados obtidos pelas RNA do tipo LSTM são apresentados na

Tabela 5. Nelas, é importante observar os menores valores de MAE, MAPE e RMSE destacados em negrito, conforme enfatizado anteriormente.

Tabela 4 - Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação CSMG3.

Número de neurônios	Preço máximo			Número de neurônios	Preço mínimo		
	MAE	MAPE (%)	RMSE		MAE	MAPE (%)	RMSE
(3, -)	0,583	1,344	0,813	(3, 21)	0,761	1,843	0,924
(3, 3)	0,573	1,322	0,762	(6, -)	0,814	1,960	0,980
(6, 9)	0,860	1,913	1,218	(6, 24)	2,050	4,946	2,501
(9, 21)	2,519	5,883	3,089	(9, 9)	2,490	5,815	3,021
(12, 12)	3,962	9,622	4,565	(15, 18)	2,870	6,614	3,826

Fonte: Adaptado de Laboissiere, Fernandes e Lage (2015).

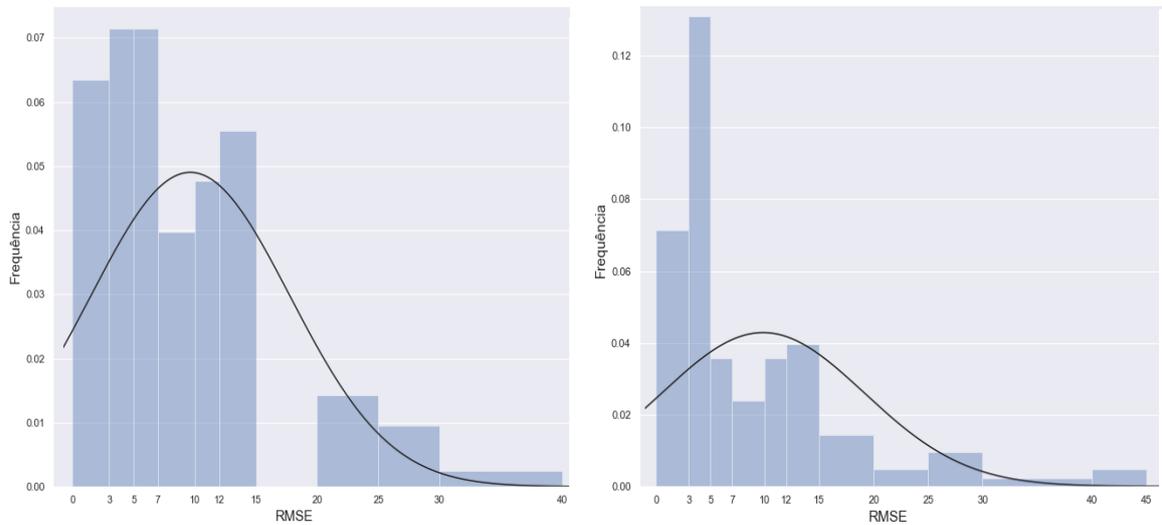
Tabela 5 – Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação CSMG3.

Número de células		MAE	MAPE (%)	RMSE
10	Preço máximo	0.061	0.142	0.069
	Preço mínimo	0.043	0.107	0.055

Fonte: Elaborada pelo autor.

A partir dos coeficientes de RMSE apresentados pelas melhores RNA do tipo MLP, foi possível gerar os histogramas apresentados na Figura 22, que exibem as frequências relativas dos erros na previsão dos preços máximos (a) e mínimos (b), respectivamente, da ação financeira CSMG3.

Figura 22 – Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de CSMG3.



Fonte: O autor.

Na Tabela 4, é possível observar que a rede neural artificial do tipo MLP que apresentou os melhores resultados para a previsão dos preços máximos de CSMG3 possui duas camadas intermediárias, cada uma contendo 3 neurônios, representado por (3, 3). Tal rede obteve o menor nível de MAPE com coeficiente igual a 1,322%, representando uma capacidade de previsão de 98,678% do comportamento real da ação. Mesmo a pior dentre as 5 RNA MLP elencadas na Tabela, gerou um MAPE de 9,622%, o que representa a estimativa de 90,378% de acertos na previsão de tais preços.

Por sua vez, a Tabela 4 também mostra que a rede neural artificial MLP que gerou os melhores resultados na previsão dos preços mínimos diários de CSMG3 igualmente possui duas camadas intermediárias, sendo a primeira delas contendo 3 neurônios e a segunda com 21 neurônios. Tal rede apresentou um MAPE de 1,843%, demonstrando a capacidade de 98,157% de acerto na previsão dos referidos preços. Dessa maneira, é possível perceber que o modelo preditivo baseado em RNA do tipo MLP obteve valores bem semelhantes na previsão dos preços máximos e mínimos da ação CSMG3.

Ademais, a Tabela 5 mostra que o modelo preditivo baseado em RNA do tipo LSTM conseguiu melhores previsões para os preços mínimos diários de CSMG3. Nesse processo, o MAPE gerado foi 0,107%, representando um poder de previsão de 99,893% desses valores. Para a previsão dos preços máximos dessa ação, a melhor rede neural artificial LSTM apresentou um MAPE de 0,142%, de modo a também representar a capacidade de mais de 99% de acurácia na previsão de tais valores. Assim, é possível observar que o modelo baseado em

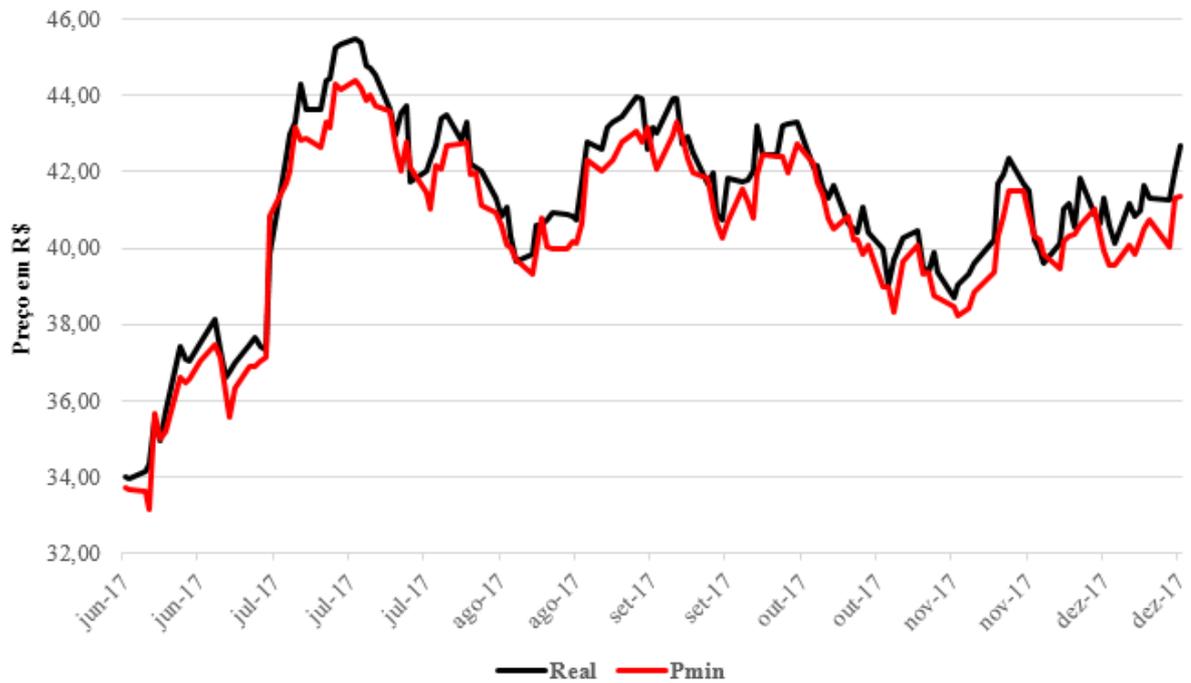
RNA LSTM apresentou precisões semelhantes na previsão dos preços máximos e mínimos diários de CSMG3.

Adicionalmente, dos resultados apresentados nas tabelas 4 e 5, foram gerados os gráficos que mostram os valores de previsão para os preços máximos e mínimos da ação CSMG3 apresentados pelas RNA do tipo MLP e LSTM. As figuras 23 e 25 exibem os gráficos dos melhores resultados obtidos para a estimação dos preços máximos e as figuras 24 e 26 apresentam os gráficos dos melhores resultados alcançados para a previsão dos preços mínimos diários.

Figura 23 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de CSMG3.



Figura 24 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de CSMG3.



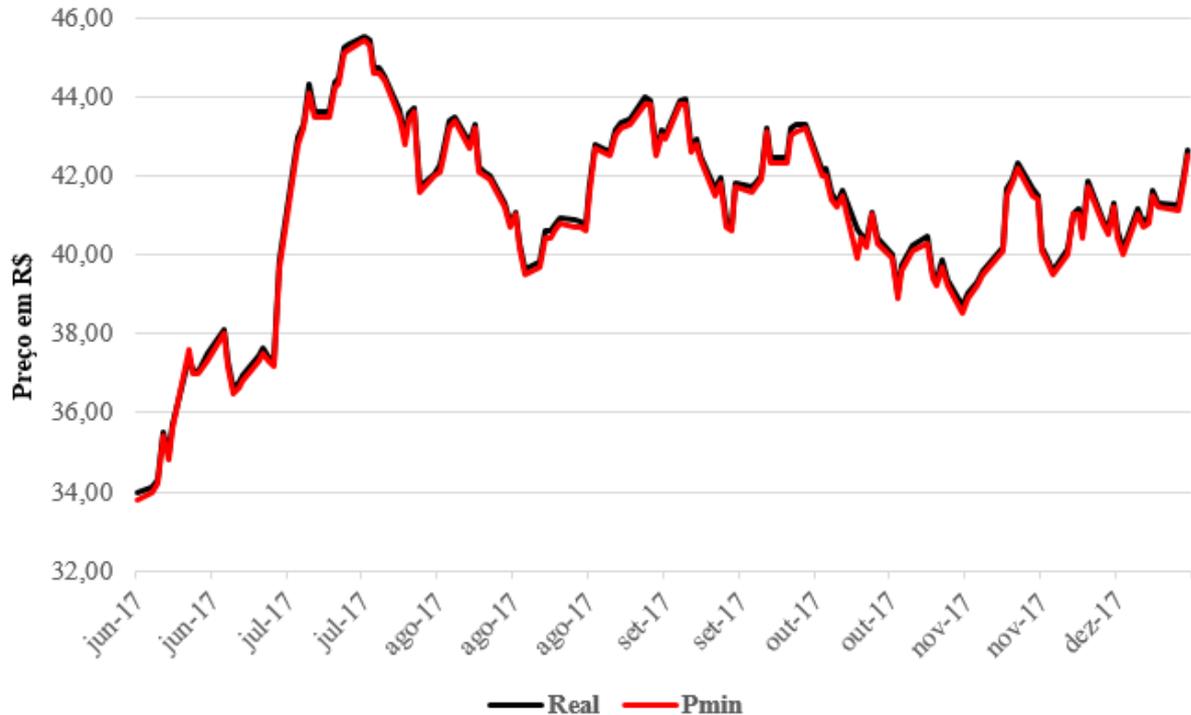
Fonte: O autor.

Figura 25 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de CSMG3.



Fonte: O autor.

Figura 26 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de CSMG3.



Fonte: O autor.

A análise dos gráficos apresentados nas figuras 23 a 26 possibilita observar que o modelo baseado em RNA do tipo LSTM apresentou os melhores resultados para as previsões dos valores de preços máximos e mínimos diários da ação CSMG3, com a curva dos dados de validação das RNA coincidindo em vários pontos com a curva que representa os dados reais históricos utilizados na fase de validação. Tais resultados são semelhantes aos apresentados por Bessa (2018), que demonstrou que as RNA recorrentes do tipo LSTM superaram alguns métodos estatísticos clássicos testados em seu trabalho, exibindo maior precisão na previsão da maioria dos valores almejados. A autora demonstra a maior acurácia dos modelos baseados em RNA LSTM em três das quatro séries modeladas em sua pesquisa.

4.3 Resultados obtidos para a previsão da ação ELET6

Os resultados das RNA do tipo MLP com uma e duas camadas intermediárias que apresentaram os melhores valores para a ação ELET6 (Centrais Elétricas Brasileiras S. A. - ELETROBRÁS) são mostrados na Tabela 6, enquanto a Tabela 7 exhibe os melhores resultados obtidos pelas RNA do tipo LSTM. Mais uma vez, os menores valores de MAE, MAPE e RMSE estão destacados em negrito.

Tabela 6 - Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação ELET6.

Número de neurônios	Preço máximo			Número de neurônios	Preço mínimo		
	MAE	MAPE (%)	RMSE		MAE	MAPE (%)	RMSE
(6, -)	1,219	5,763	1,366	(27, -)	1,791	8,334	2,115
(3, 9)	1,092	4,744	1,337	(3, 3)	4,376	19,45	4,922
(6, 21)	1,969	8,537	2,484	(6, 12)	1,514	6,574	1,846
(9, 21)	1,084	4,531	1,391	(9, 12)	1,163	5,952	1,322
(12, 21)	1,072	4,845	1,280	(12, 21)	1,665	7,360	2,327

Fonte: Adaptado de Laboissiere, Fernandes e Lage (2015).

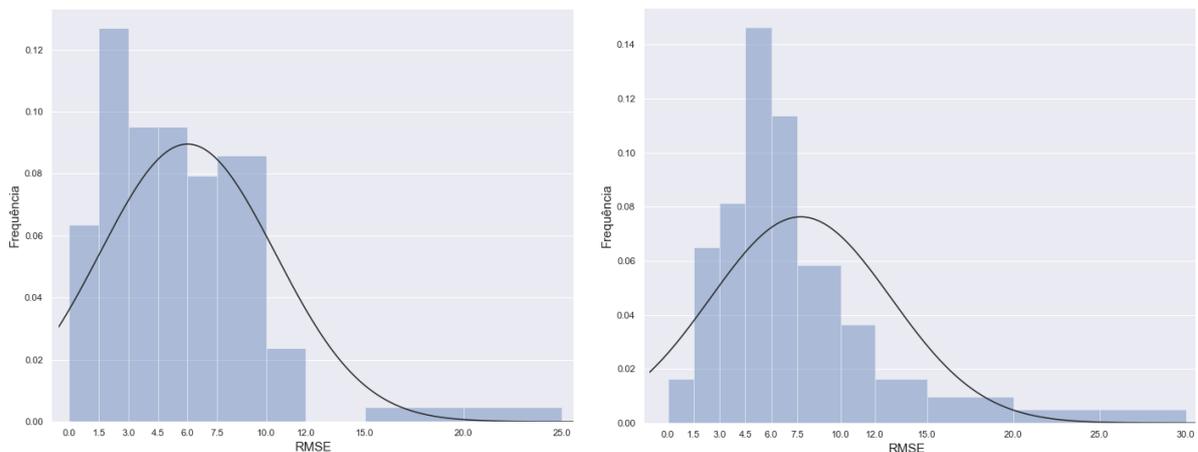
Tabela 7 – Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação ELET6.

Número de células		MAE	MAPE (%)	RMSE
10	Preço máximo	0.064	0.291	0.070
	Preço mínimo	0.054	0.284	0.055

Fonte: Elaborada pelo autor.

Analogamente, dos valores de erros obtidos por todas as configurações das 5 melhores redes neurais do tipo MLP treinadas e validadas, foi possível gerar os histogramas apresentados na Figura 27. Dessa forma, a Figura 27 (a) exibe o histograma dos erros na previsão dos preços máximos diários de ELET6, enquanto a Figura 27 (b) mostra o histograma referente aos erros resultantes na previsão dos preços mínimos diários da mesma ação.

Figura 27 – Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de ELET6.



Fonte: O autor.

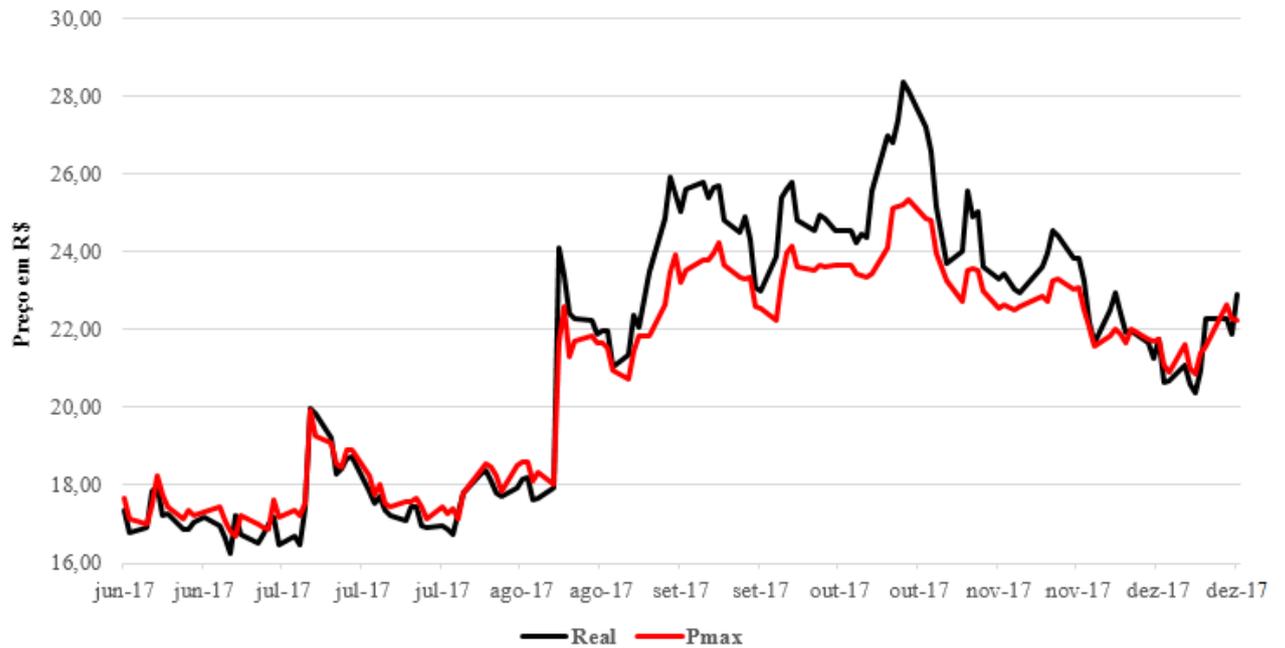
Conforme observado na Tabela 6, os resultados apresentados pelas RNA do tipo MLP apresentaram previsões melhores para os preços máximos diários da ação ELET6. Nesse cenário, a melhor rede neural possui duas camadas ocultas, sendo uma com 12 neurônios e a outra com 21 neurônios, respectivamente. Tal configuração obteve o menor valor de MAPE, a saber, 4,845%, alcançando a capacidade de acerto de 95,155% na previsão dos preços máximos.

Na previsão dos valores dos preços mínimos diários de ELET6, a melhor rede neural MLP também possui duas camadas intermediárias, sendo uma com 9 neurônios e a outra com 12, respectivamente. Esse cenário apresentou um MAPE de 5,952%, demonstrando um poder de previsão de 94,08%. Tal resultado se assemelha ao obtido no trabalho de Oliveira, Nobre e Zárate (2013) num panorama que alcançou o valor de 5,45% para MAPE na previsão do comportamento da ação PETR4.

Da Tabela 7, é possível inferir que as RNA do tipo LSTM geraram resultados mais corretos para as previsões dos preços mínimos diários de ELET6, porém, com métricas de erros bastante próximas entre si. Na melhor previsão para os preços mínimos, o MAPE obtido foi 0,284%, demonstrando a capacidade de 99,716% de precisão ao prever tais valores. Para a previsão dos preços máximos diários da ação, o melhor modelo baseado em RNA recorrentes do tipo LSTM apresentou um MAPE de 0,291%, alcançando um poder de previsão de 99,709% desses valores.

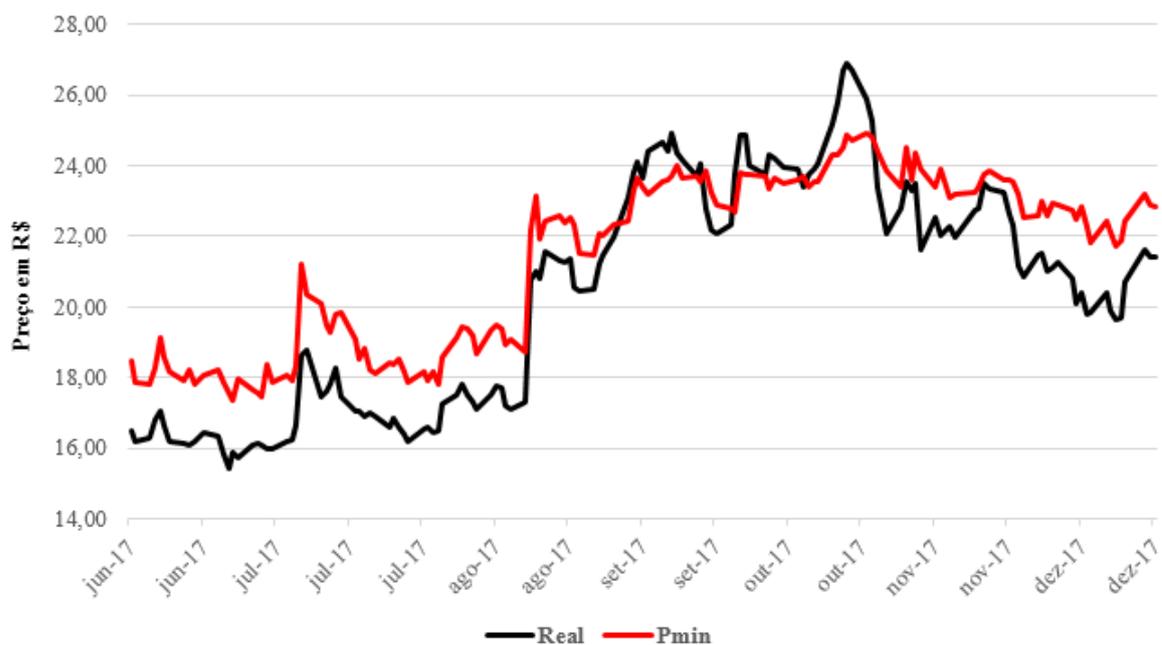
Além disso, a partir das tabelas 6 e 7, foi possível gerar a representação gráfica das previsões para os preços máximos e mínimos da ação ELET6 obtidos pelas RNA do tipo MLP e LSTM. As figuras 28 e 30 exibem os gráficos dos melhores resultados gerados para a estimação dos preços máximos diários e as figuras 29 e 31 apresentam os gráficos dos melhores resultados alcançados para a previsão dos preços mínimos diários. Visualmente, é possível conferir a maior precisão dos modelos preditivos baseados em RNA LSTM quando comparados como os modelos baseados em RNA MLP. Todavia, é importante salientar que os cenários que utilizaram RNA MLP também apresentaram resultados satisfatórios nas estimativas dos preços de ELET6, conforme apresentados anteriormente.

Figura 28 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de ELET6.



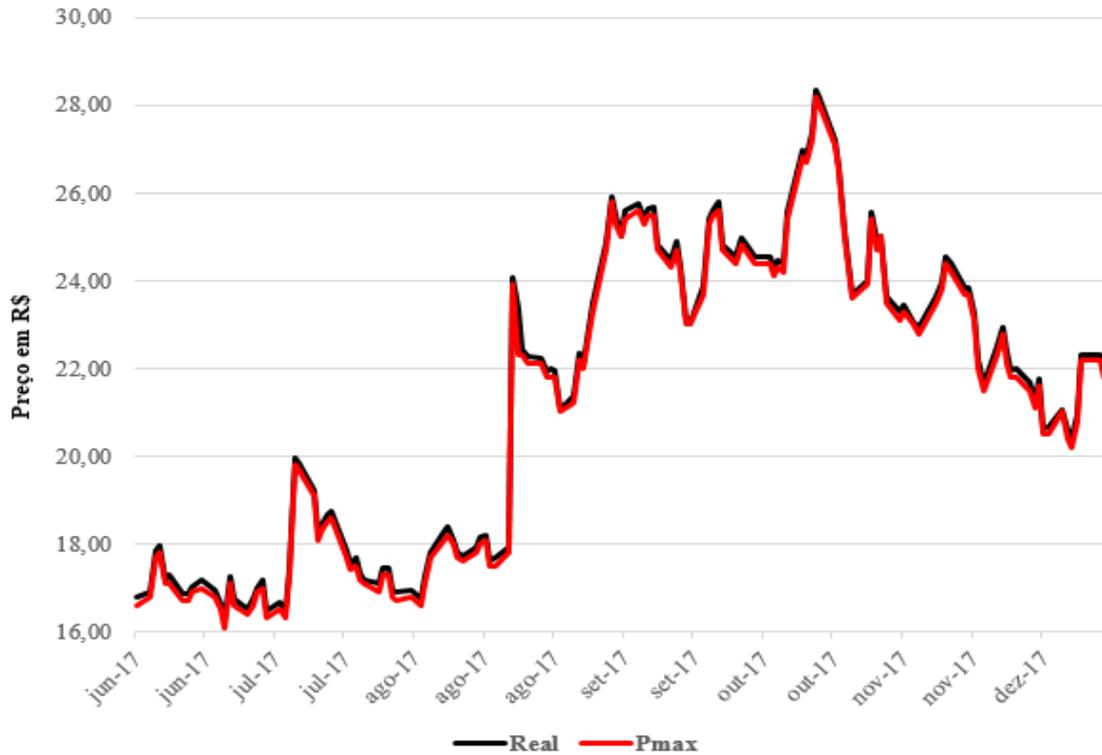
Fonte: O autor.

Figura 29 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de ELET6.



Fonte: O autor.

Figura 30 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de ELET6.



Fonte: O autor.

Figura 31 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de ELET6.



Fonte: O autor.

Novamente, é interessante citar Muntaser, Da Silva e Penedo (2017), que apresentaram resultados satisfatórios ao utilizarem RNA do tipo MLP para a previsão do comportamento do mercado acionário brasileiro num determinado setor. Ainda, Dametto (2018) demonstra em seu trabalho um cenário em que um modelo preditivo baseado em RNA recorrentes do tipo LSTM obteve resultados inferiores a um modelo que utilizou uma combinação de alguns tipos de RNA criadas pelo autor.

4.4 Resultados obtidos para a previsão da ação PETR4

A seguir, os resultados das melhores RNA do tipo MLP com uma e duas camadas intermediárias que apresentaram os valores mais acertados para a ação PETR4 (Petróleo Brasileiro S. A. - PETROBRÁS) são mostrados na Tabela 8. Por sua vez, a Tabela 9 exibe os melhores resultados obtidos pelas RNA do tipo LSTM. Nelas, os menores valores de MAE, MAPE e RMSE estão destacados em negrito. A análise comparativa de tais resultados e da performance das RNA utilizadas é realizada a seguir.

Tabela 8 - Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação PETR4.

Número de neurônios	Preço máximo			Número de neurônios	Preço mínimo		
	MAE	MAPE (%)	RMSE		MAE	MAPE (%)	RMSE
(3, -)	0,179	1,213	0,213	(3, 6)	0,495	3,360	0,587
(3, 24)	0,223	1,529	0,258	(6, -)	0,461	3,299	0,526
(6, 9)	1,289	9,232	1,485	(6, 12)	0,962	6,598	1,015
(9, 6)	0,593	4,034	0,726	(9, 12)	1,371	9,299	1,605
(12, 9)	1,062	6,951	1,303	(15, 9)	1,209	8,219	1,313

Fonte: Adaptado de Laboissiere, Fernandes e Lage (2015).

Tabela 9 – Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação PETR4.

Número de células		MAE	MAPE (%)	RMSE
10	Preço máximo	0.063	0.447	0.064
	Preço mínimo	0.027	0.193	0.027

Fonte: Elaborada pelo autor.

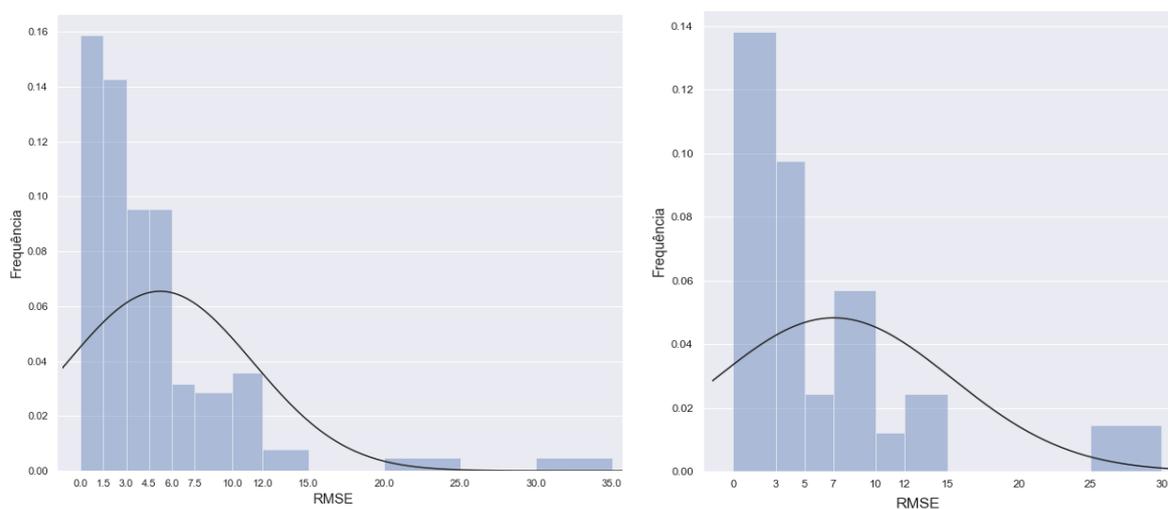
Os resultados apresentados na Tabela 8 demonstram que o modelo baseado em RNA do tipo MLP conseguiram melhores previsões para os valores dos preços máximos diários de PETR4. É possível perceber que a melhor rede neural artificial utilizando essa arquitetura foi configurada com apenas uma camada intermediária contendo 3 neurônios. Tal rede obteve um MAPE de 1,213%, certificando a capacidade de uma previsão correta em 98,787%. É interessante observar que Oliveira, Nobre e Zárata (2013) obtiveram um acerto de 94,55% na previsão do comportamento de PETR4.

Para a predição dos preços mínimos diários da ação, a melhor rede neural artificial MLP foi configurada também com somente uma camada oculta, possuindo nela 6 neurônios. Essa rede exibiu o menor MAPE com valor 3,299%, alcançando, assim, um poder de previsão de 96,701% para tais valores.

Dos valores da Tabela 9, é possível inferir que o modelo preditivo baseado em RNA do tipo LSTM apresentaram maior assertividade na previsão dos preços mínimos de PETR4, obtendo o menor MAPE de 0,193%. Na previsão dos valores dos preços máximos diários da ação, o menor MAPE alcançado possui o valor de 0,447%. Porém, percebe-se que a capacidade de previsão para os dois casos excede 99% de precisão.

Ademais, de todos os valores de erros obtidos por todas as configurações das melhores RNA do tipo MLP treinadas e validadas, foi possível gerar os histogramas apresentados na Figura 32. Assim, a Figura 32 (a) exhibe o histograma dos erros na previsão dos preços máximos diários de PETR4, enquanto a Figura 32 (b) mostra o histograma referente aos erros resultantes na previsão dos preços mínimos diários da mesma ação.

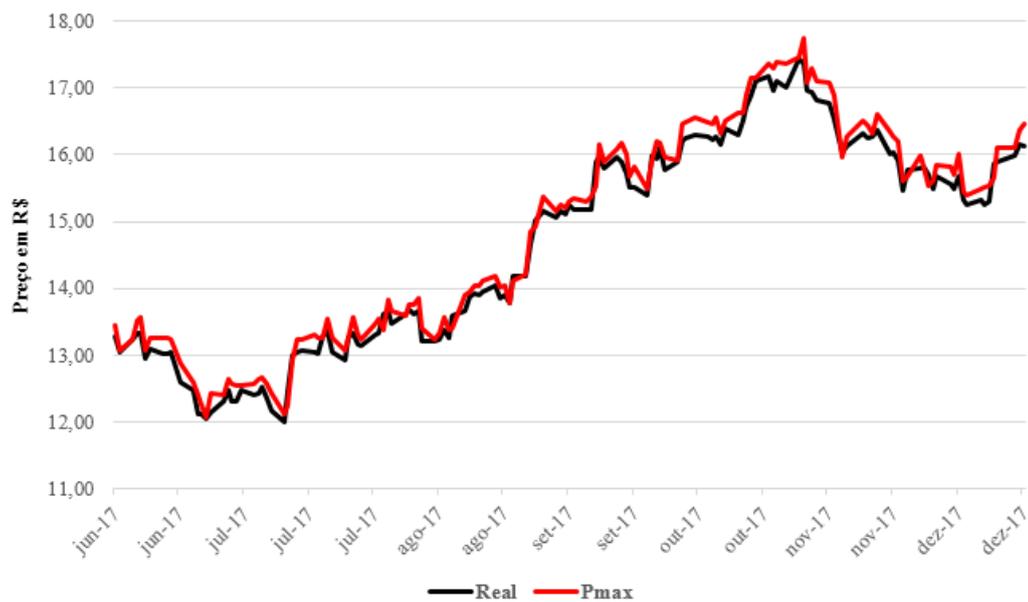
Figura 32 – Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de PETR4.



Fonte: O autor.

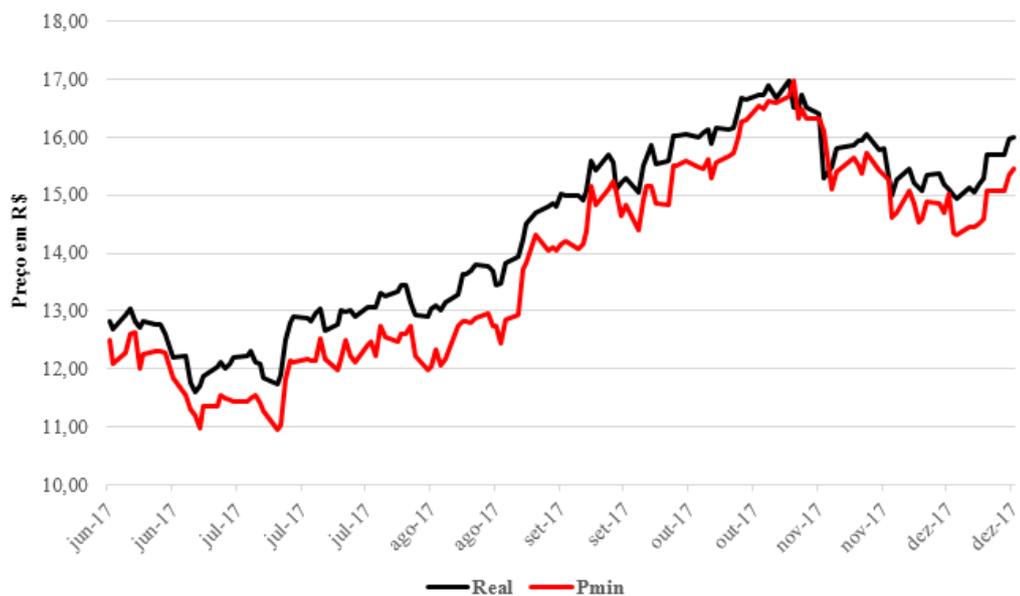
Os gráficos obtidos a partir dos resultados apresentados nas tabelas 8 e 9 são mostrados nas figuras 33 a 36. As figuras 33 e 35 exibem os gráficos dos melhores resultados gerados para a estimação dos preços máximos diários de PETR4 e as figuras 34 e 36 apresentam os gráficos dos melhores resultados alcançados para a previsão dos preços mínimos diários da mesma ação.

Figura 33 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de PETR4.



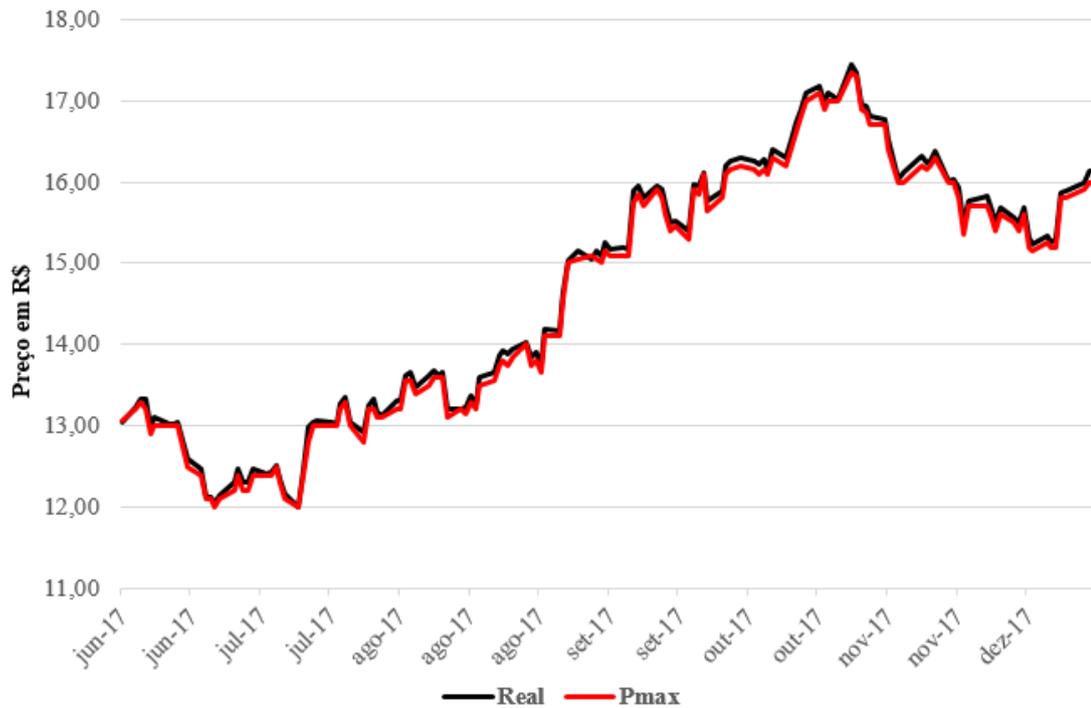
Fonte: O autor.

Figura 34 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de PETR4.



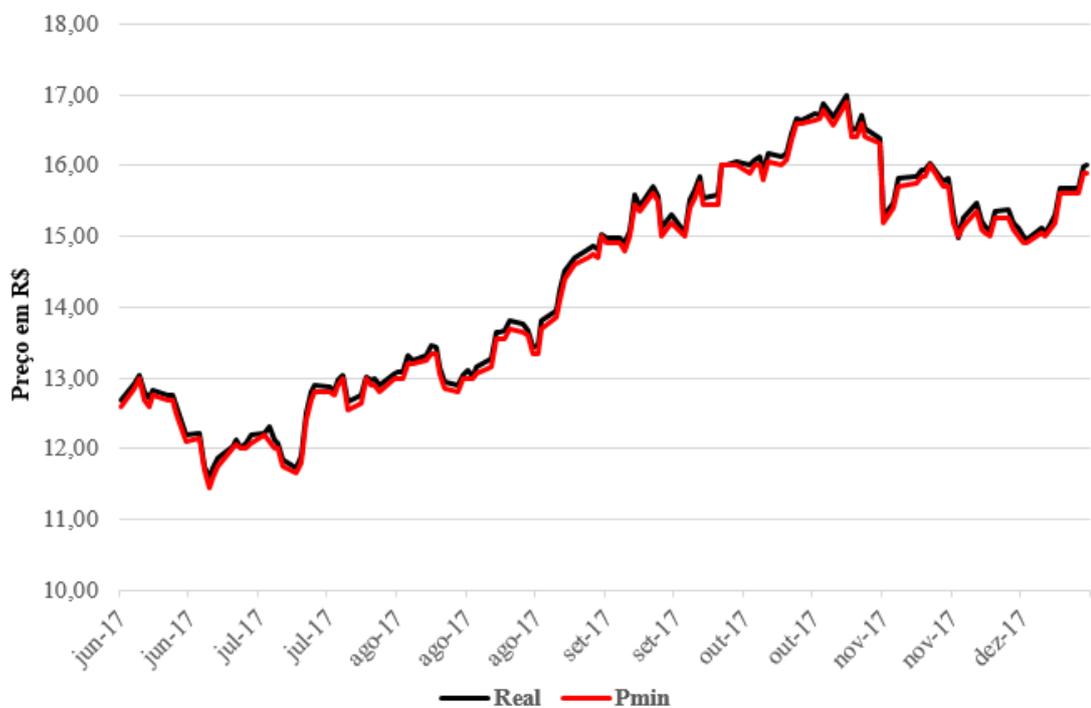
Fonte: O autor.

Figura 35 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de PETR4.



Fonte: O autor.

Figura 36 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de PETR4.



Fonte: O autor.

Da análise dos gráficos apresentados nas figuras 33 e 34, é possível inferir que as RNA do tipo MLP não apresentaram previsões tão precisas para os valores dos preços mínimos da ação PETR4. Como visto, as previsões para os preços máximos diários da ação apresentaram melhores métricas de erros, gerando uma melhor estimativa de tais coeficientes. Nesse sentido, Felizardo (2017) aponta que a arquitetura da rede exerce significativa influência no seu desempenho, sendo um fator que predominantemente impacta a assertividade do modelo preditivo desenvolvido. Também é importante a citação de Turcato (2015) ao indicar que o processo de aprendizagem e treinamento de uma rede neural artificial está intimamente relacionado com o tipo de algoritmo escolhido.

4.5 Resultados obtidos para a previsão da ação TELB4

Os resultados das melhores RNA do tipo MLP com uma e duas camadas intermediárias que apresentaram os melhores valores para a ação TELB4 (Telecomunicações Brasileiras S. A. - TELEBRÁS) são mostrados na Tabela 10. Por sua vez, a Tabela 11 exibe os melhores resultados obtidos pelas RNA do tipo LSTM. Novamente, estão destacadas as características referentes às configurações arquiteturais das RNA utilizadas e os menores valores de MAE, MAPE e RMSE.

Tabela 10 - Melhores resultados obtidos pelas RNA do tipo MLP para a previsão dos preços máximos e mínimos diários da ação TELB4.

Número de neurônios	Preço máximo			Número de neurônios	Preço mínimo		
	MAE	MAPE (%)	RMSE		MAE	MAPE (%)	RMSE
(6, -)	2,010	6,409	2,645	(27, -)	4,930	18,284	5,998
(3, 12)	4,602	13,830	5,305	(3, 3)	1,880	5,947	2,607
(6, 3)	4,099	12,013	5,396	(6, 12)	2,521	7,668	3,701
(12, 15)	10,158	36,504	12,649	(12, 21)	5,119	17,284	5,621
(15, 12)	8,174	28,421	10,309	(15, 18)	6,690	21,063	7,983

Fonte: Adaptado de Laboissiere, Fernandes e Lage (2015).

Tabela 11 – Melhores resultados obtidos pelas RNA do tipo LSTM para a previsão dos preços máximos e mínimos diários da ação TELB4.

Número de células		MAE	MAPE (%)	RMSE
10	Preço máximo	0.151	0.542	0.152
	Preço mínimo	0.079	0.282	0.085

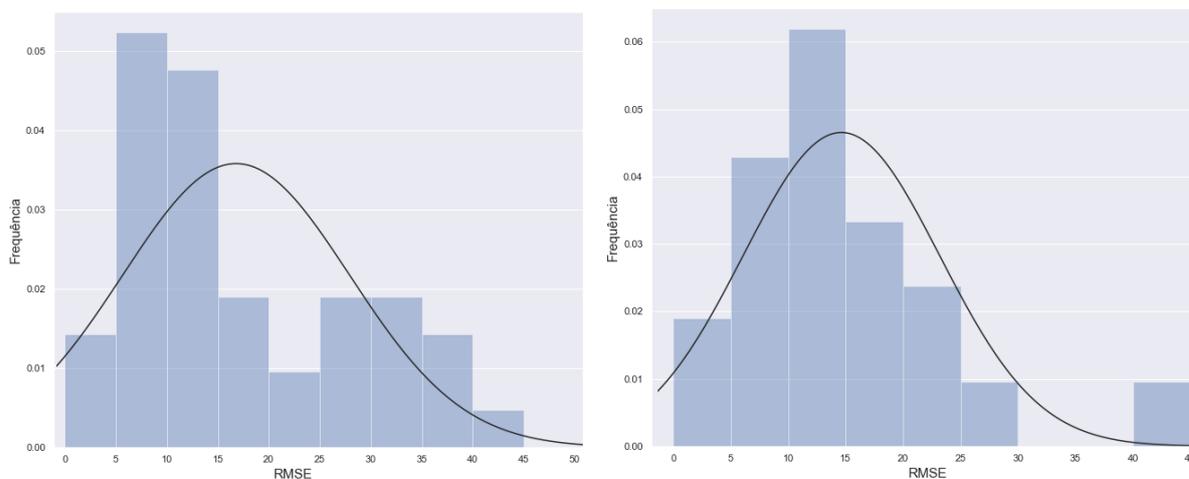
Fonte: Elaborada pelo autor.

Os valores apresentados na Tabela 10 demonstram que os valores dos preços máximos e mínimos diários de TELB4 foram os que obtiveram as piores previsões pelas RNA do tipo MLP. Para as estimativas dos preços máximos, a melhor rede neural artificial desse tipo apresentou um MAPE de 6,409%, demonstrando a capacidade de 93,591% de assertividade nas previsões. Por outro lado, o menor valor de MAPE obtido na previsão dos preços mínimos foi de 5,947%, alcançando um poder preditivo de 94,053%. É possível perceber, então, que as estimativas ficaram bem próximas em relação aos seus coeficientes.

Na Tabela 11, os valores mostrados revelam que o modelo preditivo baseado em RNA do tipo LSTM apresentaram maior precisão na previsão dos preços mínimos diários de TELB4. O menor valor de MAPE obtido nas 5 seções de treinamento e validação foi de 0,282%, enquanto que, na previsão dos preços máximos diários, o menor MAPE alcançado foi de 0,542%. Mais uma vez, a capacidade de assertividade nas previsões dos valores nos dois cenários excedeu 99%.

Ademais, a partir dos coeficientes de todos os erros apresentados por todas as configurações das melhores RNA do tipo MLP, foi possível gerar os histogramas apresentados na Figura 37. Dessa forma, a Figura 37 (a) exibe o histograma dos erros na previsão dos preços máximos de TELB4, enquanto a Figura 37 (b) mostra o histograma referente aos erros resultantes na previsão dos preços mínimos diários da mesma ação.

Figura 37 – Histogramas dos erros (RMSE) apresentados pelas RNA do tipo MLP para a previsão dos preços máximos (a) e mínimos (b), respectivamente, de TELB4.

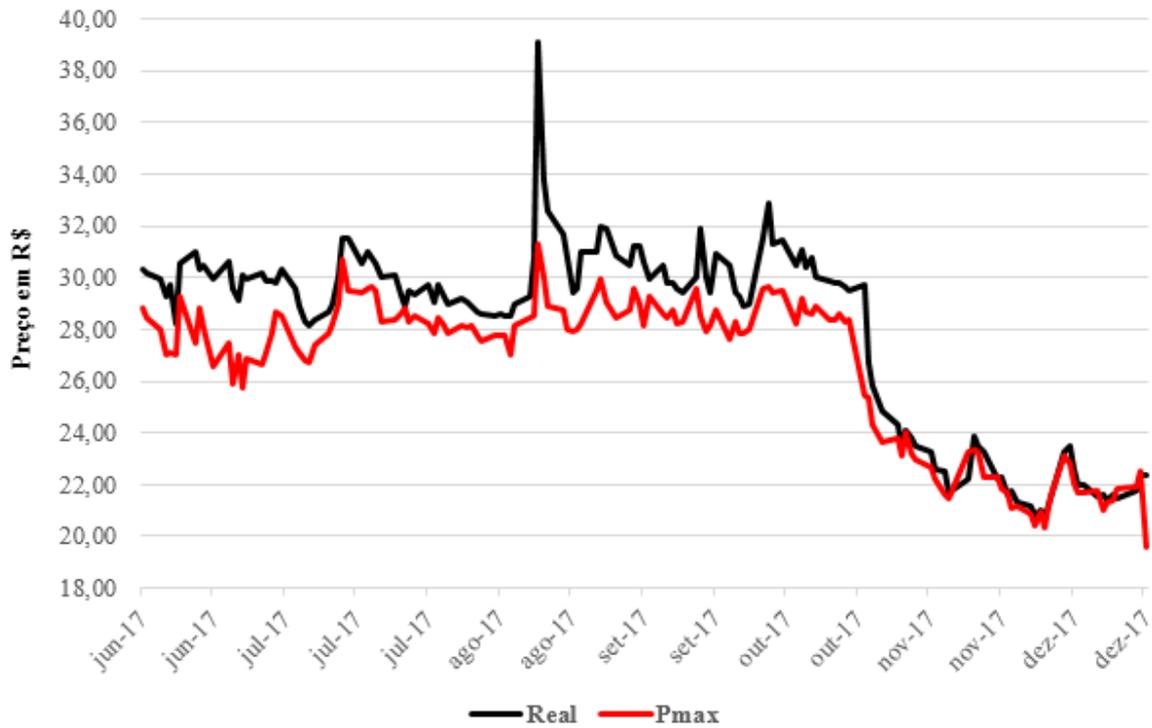


Fonte: O autor.

Ainda, na Tabela 10 é possível observar que a rede neural artificial MLP que apresentou as melhores previsões para os valores dos preços máximos diários de TELB4 possui apenas uma camada intermediária com 6 neurônios presentes. Por sua vez, na previsão dos preços mínimos dessa ação, a melhor rede foi configurada com duas camadas intermediárias, contendo 3 neurônios em cada uma delas.

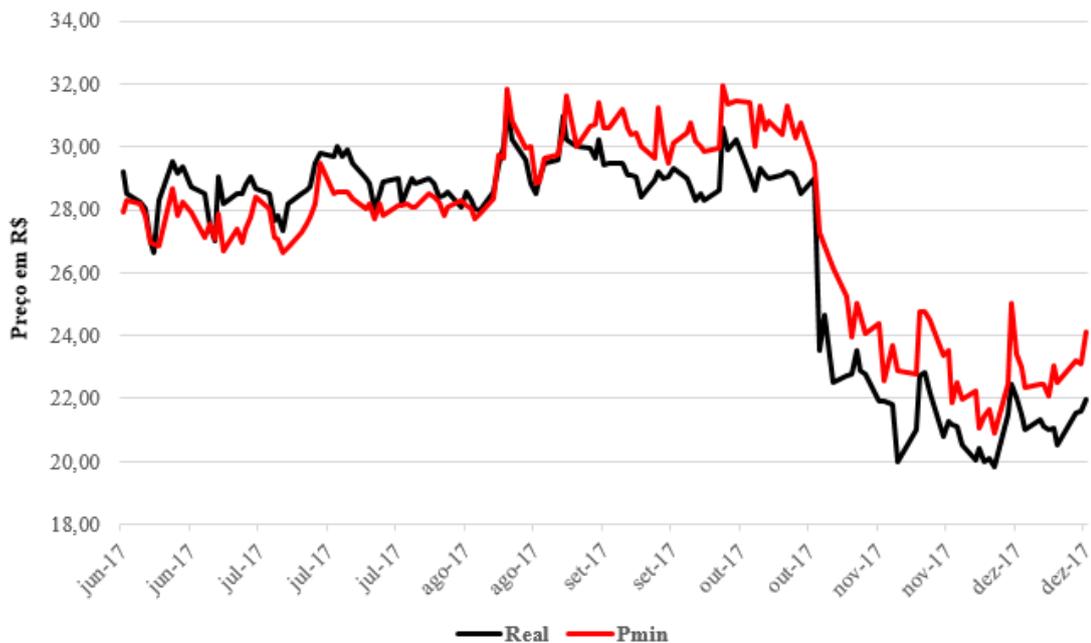
Os gráficos obtidos a partir dos resultados apresentados nas tabelas 10 e 11 são mostrados nas figuras 38 a 41. As figuras 38 e 40 exibem os gráficos dos melhores resultados gerados para a estimação dos preços máximos diários de TELB4 e as figuras 39 e 41 apresentam os gráficos dos melhores resultados alcançados para a previsão dos preços mínimos diários da mesma ação. Novamente, as topologias das RNA utilizadas em cada cenário estão descritas nas legendas das respectivas figuras.

Figura 38 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço máximo de TELB4.



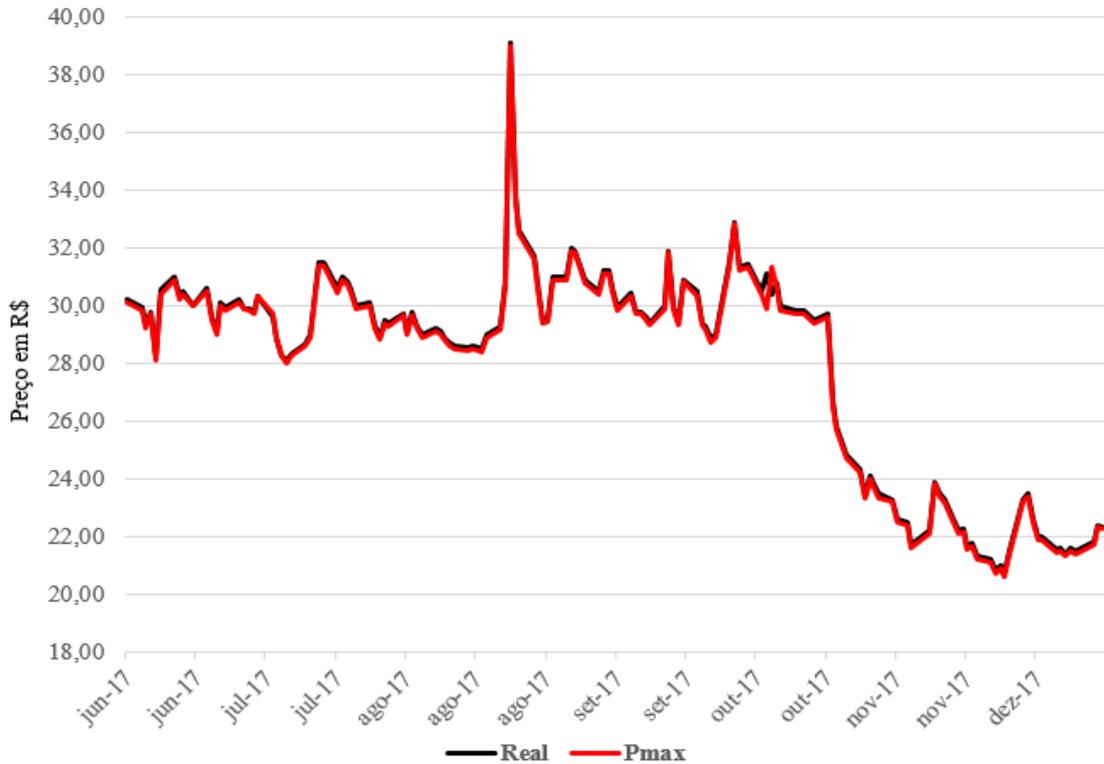
Fonte: O autor.

Figura 39 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo MLP para a previsão do preço mínimo de TELB4.



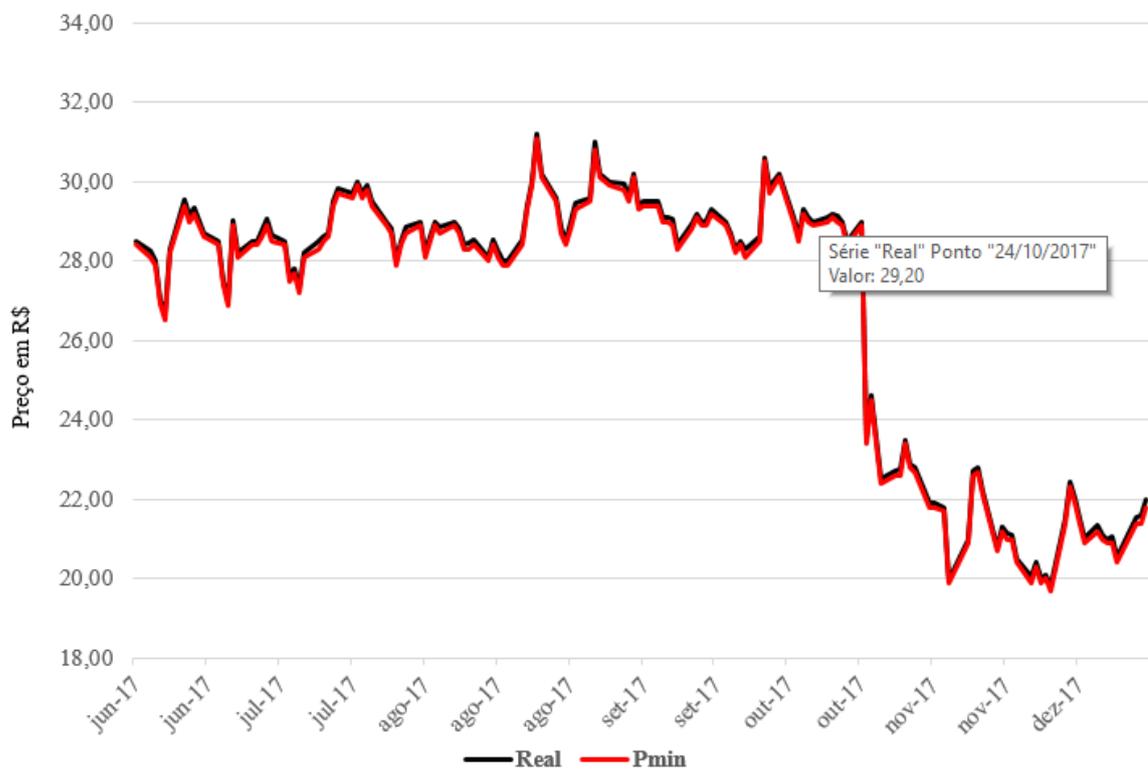
Fonte: O autor.

Figura 40 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço máximo de TELB4.



Fonte: O autor.

Figura 41 – Representação gráfica dos melhores resultados obtidos pelas RNA do tipo LSTM para a previsão do preço mínimo de TELB4.



Fonte: O autor.

Analogamente aos casos anteriores, os gráficos mostrados nas figuras 38 a 41 apresentam uma maior precisão das RNA do tipo recorrente LSTM nas previsões dos preços máximos e mínimos diários, corroborando os resultados expostos no trabalho de Bessa (2018). Entretanto, a capacidade de previsão de modelos baseados em RNA do tipo MLP no mercado de ações financeiras não deve ser minimizada, conforme Laboissiere, Fernandes e Lage (2015), Gambogi (2013), Disconzi (2018) e Muntaser, Da Silva e Penedo (2017) apresentaram nos resultados obtidos em suas respectivas pesquisas.

5 CONCLUSÃO

Conforme o objetivo geral deste trabalho, o desenvolvimento de um modelo preditivo de cotação de ações de empresas públicas previamente selecionadas foi realizado utilizando-se RNA com duas diferentes arquiteturas escolhidas: MLP e LSTM. A análise comparativa dos resultados alcançados gerou conclusões interessantes no contexto da utilização das RNA para a previsão de preços de ações no mercado financeiro.

Das RNA do tipo MLP, os melhores resultados para as 5 execuções de treinamento e validação com uma ou duas camadas intermediárias e variações de neurônios de 3 em 3, foi possível concluir que os dados de entrada influenciam fortemente o treinamento das redes construídas. Conforme demonstrado no trabalho de Laboissiere, Fernandes e Lage (2015), melhores resultados utilizando-se tal topologia podem ser alcançados através de seleção de atributos e pré-processamento de dados que serão utilizados como *inputs* das redes neurais do modelo preditivo desenvolvido.

De modo geral, foi possível observar que o aumento do número de neurônios presentes nas camadas ocultas das RNA do tipo MLP utilizadas não implicou na geração de resultados mais eficientes para as previsões. Durante os testes, de acordo com os números resultantes apresentados, várias previsões mostraram-se melhores empregando RNA MLP com uma ou duas camadas intermediárias com poucos neurônios presentes em cada uma delas.

Por outro lado, as RNA recorrentes do tipo LSTM apresentaram resultados satisfatórios nas previsões dos preços máximos e mínimos diários das ações utilizadas na pesquisa. Como visto no capítulo 4, as métricas de erros MAE, MAPE e RMSE mostraram a acurácia das previsões e os gráficos associados gerados permitiram visualizar, para a maioria das ações empregadas, a coincidência entre as curvas reais dos dados históricos e as curvas dos preços máximos e mínimos previstas.

Dessa maneira, o modelo baseado em RNA LSTM apresentou maior precisão nas previsões almejadas. Embora sua implementação seja mais complexa e o esforço computacional de execução seja bem custoso, sua performance tem atingido resultados bastante satisfatórios na construção de modelos preditivos para diversas áreas.

Uma limitação encontrada durante a pesquisa foi a fase de coleta de dados históricos na B3 e a preparação dos mesmos para se tornarem variáveis de entrada para as RNA treinadas e validadas. A manipulação da enorme massa de dados referentes às negociações das cinco ações escolhidas para o trabalho, no período temporal de 2013 a 2017, requereu considerável quantidade de tempo e esforço. Outra limitação importante foi a grande quantidade de tempo despendida para o treinamento e validação das RNA utilizadas. Considerando-se o hardware utilizado na implementação do modelo proposto, tal tempo foi consideravelmente alto.

Como propostas de trabalhos futuros, sugere-se a construção de modelos preditivos híbridos baseados em RNA recorrentes do tipo LSTM associados com algoritmos genéticos, por exemplo (DEFILIPPO, 2017; BESSA, 2018, p. 234). Ademais, recomenda-se fortemente o tratamento dos dados de entradas das RNA do tipo MLP, como, por exemplo, a seleção de atributos e o pré-processamento dos dados. Tais métodos, como pode ser observado no trabalho de Laboissiere, Fernandes e Lage (2015), diminuí consideravelmente os conjuntos de dados que serão manipulados pelas RNA do tipo MLP empregadas nas construções das soluções. Conseqüentemente, haverá a diminuição do esforço computacional demandado e economia de tempo gasto no projeto.

Finalmente, o modelo preditivo desenvolvido nesta pesquisa, utilizando principalmente RNA recorrentes do tipo LSTM, comprovou que pode ser utilizado como apoio à tomada de decisões por investidores, gestores e semelhantes que realizam atividades inerentes ao contexto das negociações financeiras que envolvem capitais nos mercados de ações.

REFERÊNCIAS

- ALMEIDA, Rafael Luís Ferreira de. **Aplicação de redes neuronais artificiais para aproximar o comportamento de estruturas**. 2012. 115 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Departamento de Engenharia Mecânica e Industrial, Universidade Nova de Lisboa, Lisboa, 2012. Disponível em: <<http://hdl.handle.net/10362/7726>>. Acesso em: 02 jan. 2019.
- ARANTES, Breno de Oliveira. **Previsão da estrutura a termo da taxa de juros brasileira usando redes neurais artificiais**. 2013. 41 f. Dissertação (Mestrado) - Curso de Pós-graduação em Economia, Faculdade de Ciências Econômicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013. Disponível em: <<http://hdl.handle.net/10183/79126>>. Acesso em: 20 out. 2018.
- ARAUJO, Ana Claudia Henriques de. **A gestão da informação nos acervos de artes visuais em instituições públicas que integram o Sistema Financeiro Nacional**. 2017. 269 f., il. Tese (Doutorado em Ciência da Informação) - Universidade de Brasília, Brasília, 2017. Disponível em: <<http://repositorio.unb.br/handle/10482/24229>>. Acesso em: 17 out. 2018.
- ARAÚJO, Klayton Antônio Moreira e LOTUFO, Anna Diva Plasencia. 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.
- ASHBY, William Ross. **Design for a brain**. Chapman and Hall, 1952.
- BANCO CENTRAL DO BRASIL. **Cotações e boletins**, 2019. Disponível em: <<http://www4.bcb.gov.br/pec/taxas/port/ptaxnpsq.asp?id=txcotacao>>. Acesso em: 20 fev. 2019.
- BRASIL, BOLSA, BALCÃO. **Séries históricas**, 2019. Disponível em: <http://www.bmfbovespa.com.br/pt_br/servicos/market-data/historico/mercado-a-vista/series-historicas/>. Acesso em: 20 fev. 2019.
- BESSA, Adriana Bezerra. **Previsão de vendas no varejo de moda com modelos de redes neurais**. 2018. 256 f. Dissertação (Mestrado) - Curso de Pós-graduação em Finanças e Economia Empresarial, Escola de Economia de São Paulo, Fundação Getúlio Vargas, São Paulo, 2018. Disponível em: <<http://hdl.handle.net/10438/23890>>. Acesso em: 19 dez. 2018.
- BEZERRA, Francisco Elânio. **Uma abordagem computacional para previsão de demanda de energia elétrica e apoio à tomada de decisão no mercado de curto prazo no Brasil**. 2017. 96 f. Dissertação (Programa de Mestrado em Engenharia de Produção) - Universidade Nove de Julho, São Paulo. Disponível em: <<http://bibliotecatede.uninove.br/handle/tede/1615>>. Acesso em: 18 out. 2018.
- BISETTO, Cíntia de Jesus Soares. **As relações entre Brasil e Uruguai no alvorecer do século XXI**. 2018. 118 f. Dissertação (Mestrado) - Curso de Geografia, Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2018. Disponível em: <<https://repositorio.unesp.br/handle/11449/154250>>. Acesso em: 17 out. 2018.
- BROOMHEAD, David S.; LOWE, David. Multivariable functional interpolation and adaptative networks. **Complex Systems**, v. 2, n. 3, p. 321-355, 1988.

CARVALHO, Larissa de Souza et al. Internacionalização e earnings management: uma aplicação de redes neurais artificiais. **Revista GEPROS. Gestão da Produção, Operações e Sistemas**, Bauru, Ano 13, nº 1, jan-mar/2018, p. 240-262.
<https://doi.org/10.15675/gepros.v13i1.2032>

CARVALHO FILHO, José dos Santos. **Manual de Direito Administrativo**. 28. ed. São Paulo: Atlas, 2015.

CHAI, Tianfeng; DRAXLER, Roland R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, v. 7, n.3, p. 1247-1250, 2014.
<https://doi.org/10.5194/gmd-7-1247-2014>

CHAPMAN, Stephen J. **Programação em MATLAB para Engenheiros**. São Paulo: Pioneira Thomson Learning. 2003.

CHAVES, Jacqueline Santos. **Monitoramento e classificação de falhas em estruturas utilizando redes neurais artificiais**. 2016. 77 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Engenharia Mecânica, Departamento de Engenharia Mecânica, Universidade Estadual Paulista, Ilha Solteira, 2016. Disponível em:
<<http://hdl.handle.net/11449/143116>>. Acesso em: 18 dez. 2018.

CHEVARRIA, Diego Gonzales. **O investimento externo direto das maiores multinacionais brasileiras como função de vantagens específicas**. 2007. 146 f. Dissertação (Mestrado) - Curso de Pós-graduação em Administração, Universidade do Vale dos Sinos, São Leopoldo, 2007. Disponível em:
<<http://www.repositorio.jesuita.org.br/handle/UNISINOS/2706>>. Acesso em: 17 out. 2018.

CORRÊA, Henrique Luiz; CORRÊA, Carlos Alberto. **Administração de produção e operações: Manufatura e serviços, uma abordagem estratégica**. 3. ed. São Paulo: Atlas, 2012.

CUNHA, Tatiana Fontes. **Avaliação do timing da abertura de capital: Uma abordagem pela Teoria de Opções Reais e simulação**. 2012. 154 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Engenharia de Produção, Engenharia Industrial, PUC-Rio, Rio de Janeiro, 2012. Disponível em: <https://www.maxwell.vrac.puc-rio.br/Busca_etds.php?strSecao=resultado&nrSeq=21064@1>. Acesso em: 15 out. 2018.

DAMETTO, Ronaldo César. **Estudo da aplicação de redes neurais artificiais para predição de séries temporais financeiras**. 2018. 66 f. Dissertação (Mestrado) - Curso de Pós-graduação em Engenharia de Produção, Faculdade de Engenharia de Bauru, Universidade Estadual Paulista Júlio de Mesquita Filho, Bauru, 2018. Disponível em:
<<http://hdl.handle.net/11449/157058>>. Acesso em: 21 fev. 2019.

DEFILIPPO, Samuel Belini. **Previsão da demanda de energia elétrica por combinações de modelos lineares e de inteligência computacional**. 2017. 109 f. Tese (Doutorado) - Curso de Programa de Pós-graduação em Modelagem Computacional, Instituto de Ciências Exatas, Universidade Federal de Juiz de Fora, Juiz de Fora, 2017. Disponível em:
<<https://repositorio.ufjf.br/jspui/handle/ufjf/6036>>. Acesso em: 15 dez. 2018.

DELGADO NETO, Álvaro Martins. **BEMLAB2D: interface gráfica de modelagem visualização e análise com elementos de contorno: uma aplicação e problemas elastostáticos**. 2017. xviii, 94 f., il. Dissertação (Mestrado em Estruturas e Construção Civil) - Universidade de Brasília, Brasília, 2017.

DEMUTH, Howard; BEALE, Mark; HAGAN, Martin. **Neural Network Toolbox**. 8. ed. Natick: The MathWorks Inc, 2014.

DISCONZI, Claudia Maria Dias Guerra. **Previsão dos preços de commodities agrícolas brasileiras no mercado futuro utilizando redes neurais artificiais**. Dissertação apresentada ao Mestrado em Administração da Unipampa. Santana do Livramento: Unipampa, 2018. Disponível em: <<http://dspace.unipampa.edu.br:8080/jspui/handle/rii/2967>>. Acesso em: 18 out. 2018.

DUTRA, Marcos Galileu Lorena. **As novas estruturas organizacionais das bolsas**. 2008. 226 f. Tese (Doutorado) - Curso de Direito, Direito Comercial, Universidade de São Paulo, São Paulo, 2008. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/2/2132/tde-23052011-115826/pt-br.php>>. Acesso em: 06 out. 2018.

FACELI, Katti; LORENA, Ana Carolina; GAMA, João; CARVALHO, André Carlos Ponce de Leon Ferreira de. **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina**. 1. ed. LTC, 2011. 394 p.

FELIZARDO, Leonardo Kanashiro. **Um estudo sobre arquitetura de redes neurais aplicado a previsão do retorno de ações brasileiras**. Dissertação (Mestrado Profissional em Finanças e Economia) - FGV - Fundação Getúlio Vargas, São Paulo, 2017. Disponível em: <<http://bibliotecadigital.fgv.br/dspace/handle/10438/18042>>. Acesso em: 10 dez. 2018.

FERNANDES, Leonardo Henrique Silva. **Limiarização de retornos para quantificação de riscos em mercados financeiros**. 2018. 147 f. Tese (Programa de Pós-Graduação em Biometria e Estatística Aplicada) - Universidade Federal Rural de Pernambuco, Recife. Disponível em: <<http://www.tede2.ufrpe.br:8080/tede2/handle/tede2/7255>>. Acesso em 12 out. 2018.

FERNANDES, Ricardo Augusto Souza. **Identificação de fontes de correntes harmônicas por redes neurais artificiais**. 2009. 127 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Escola de Engenharia, Universidade de São Paulo, São Carlos, 2009. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18153/tde-27052009-143220/>>. Acesso em: 12 nov. 2018.

FERREIRA, Luciano; MOURA, Gilnei Luiz de; BORENSTEIN, Denis; FISCHMANN, Adalberto Américo. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. **Revista de Administração e Inovação**, v. 8, n. 4, p. 6-26, 2011.

FERRO, Luciano. **Aplicação da rede neural MLP (Multilayer Perceptron) em indústria de pisos e revestimentos do Polo Cerâmico de Santa Gertrudes - SP**. 2013. 143 f. Tese (Doutorado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Instituto de Geociências e Ciências Exatas, 2013. Disponível em: <<http://hdl.handle.net/11449/102925>>. Acesso em: 18 out. 2018.

FINOCCHIO, Marco Antonio Ferreira. **Determinação da temperatura de enrolamentos de transformadores a seco e de suas perdas totais baseado em redes neurais artificiais**. 2010. 101 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Engenharia Elétrica, Centro de Tecnologia e Urbanismo, Comunicação e Letras, Universidade Estadual de Londrina, Londrina, 2010. Disponível em: <<http://www.bibliotecadigital.uel.br/document/?code=vtls000161237>>. Acesso em: 25 nov. 2018.

FONTELLES, Mauro José et al. Metodologia da pesquisa científica: diretrizes para a elaboração de um protocolo de pesquisa. **Revista Paraense de Medicina**, v. 23, n. 3, p. 1-8, 2009.

FREEMAN, Walter Jackson. **Societies of Brains**. Hillsdale, NJ: Lawrence Erlbaum and Associates, 1995.

FREUND, John Ernst. **Estatística Aplicada: Economia, Administração e Contabilidade**. 11. ed. Bookman Editora, 2006.

GAMBOGI, Jarbas Aquiles. **Aplicação de redes neurais na tomada de decisão no mercado de ações**. 2013. 78 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Departamento de Engenharia de Telecomunicações e Controle, Universidade de São Paulo, São Paulo, 2013. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/3/3139/tde-23052014-012156/>>. Acesso em: 15 dez. 2018.

GIACOMEL, Felipe dos Santos. **Um método algorítmico para operações na bolsa de valores baseado em ensembles de redes neurais para modelar e prever os movimentos dos mercados de ações**. 2016. 92 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Computação, Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016. Disponível em: <<https://lume.ufrgs.br/handle/10183/134586>>. Acesso em: 15 out. 2018.

GIL, Antônio Carlos. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Editora Atlas, 2008.

GÓES, Gabriela Andrade. **Obstáculos ao financiamento de pequenas e médias empresas por meio do mercado de ações no Brasil**. 2018. 116 f. Dissertação (Mestrado) - Curso de Direito, Escola de Direito, Fundação Getúlio Vargas, São Paulo, 2018. Disponível em: <<http://hdl.handle.net/10438/24013>>. Acesso em: 18 out. 2018.

GRANATO, Rodrigo de Araújo. **Estudo da concorrência do mercado de telecomunicações em um ambiente de convergência tecnológica**. 2011. xi, 117 f., il. Mestrado profissional em Regulação e Gestão de Negócios) - Universidade de Brasília, Brasília, 2011. Disponível em: <<http://repositorio.unb.br/handle/10482/10170>>. Acesso em: 15 out. 2018.

HAYKIN, Simon S. **Redes neurais**. 2. ed. Porto Alegre: Bookman, 2001.

HEBB, Donald Olding. **The organization of behavior: a neuropsychological theory**. Oxford, England: Wiley, 1949.

HOPFIELD, John Joseph. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the national academy of sciences**, v. 79, n. 8, p. 2554-2558, 1982.
<https://doi.org/10.1073/pnas.79.8.2554>

KIRKPATRICK, Scott; GELATT, Charles Daniel; VECCHI, Mario P. Optimization by simulated annealing. **Science**, v. 220, n. 4598, p. 671-680, 1983.
<https://doi.org/10.1126/science.220.4598.671>

LABOISSIERE, Leonel Alejandro; FERNANDES, Ricardo Augusto Souza; LAGE, Guilherme Guimarães. Maximum and minimum stock price forecasting of Brazilian power distribution companies based on artificial neural networks. **Applied Soft Computing**, v. 35,

p. 66-74, 2015.

<https://doi.org/10.1016/j.asoc.2015.06.005>

LANZETTA, Vitor Bianchi. **Uma comparação entre modelos de previsão de preços do boi gordo paulista**. 2018. 108 f. Dissertação (Mestrado) - Curso de Ciências (Economia Aplicada), Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2018. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/11/11132/tde-17072018-145429/>>. Acesso em: 20 dez. 2018.

LIMA, Ricardo Rodrigues Dias de. **Análise comparativa de previsão por meio de modelos econométricos e redes neurais**. 2014. 75 f. Dissertação (Mestrado) - Curso de Mestrado em Engenharia, Pontifícia Universidade Católica de Goiás, Goiânia, 2014. Disponível em: <<http://localhost:8080/tede/handle/tede/2473>>. Acesso em: 01 nov. 2018.

LINSKER, Ralph. Self-organization in a perceptual network. **Computer**, v. 21, n. 3, p. 105-117, 1988.

<https://doi.org/10.1109/2.36>

LOPES, Alexsandro Broedel et al. **Curso de Mercado Financeiro: Tópicos especiais**. São Paulo: Atlas, 2007. 579 p.

LOPEZ, Cesar. **MATLAB Graphical Programming: Practical hands-on MATLAB solutions**. Apress, 2014.

<https://doi.org/10.1007/978-1-4842-0316-3>

LUI, Elaine Schornobay. **Previsão de material particulado a curto e médio prazos com o uso de redes neurais artificiais**. 2016. 146 f. Tese (Doutorado) - Curso de Programa de Pós-graduação em Engenharia Hidráulica e Saneamento, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016. Disponível em:

<<http://www.teses.usp.br/teses/disponiveis/18/18138/tde-30032017-163007/>>. Acesso em: 18 dez. 2018.

MACHADO, Daniel José. **Comparando modelos alternativos de precificação de ativos: uma análise para o mercado brasileiro**. 2017. 178 f. Tese (Doutorado em Administração de Empresas) - Universidade Presbiteriana Mackenzie, São Paulo, 2017. Disponível em:

<<http://tede.mackenzie.br/jspui/handle/tede/3444>>. Acesso em: 17 out. 2018.

MAIA, Renato Abreu. **Deteção de dano estrutural em estruturas planas utilizando redes neurais**. 2016. xvi, 94 f., il. Dissertação (Mestrado em Estruturas e Construção Civil) - Universidade de Brasília, Brasília, 2016.

MALIK, Farooq; NASEREDDIN, Mahdi. Forecasting output using oil prices: A cascaded artificial neural network approach. **Journal of Economics and Business**, v. 58, n. 2, p. 168-180, 2006.

<https://doi.org/10.1016/j.jeconbus.2005.09.004>

MARCONI, Marina de Andrade; LAKATOS, Eva Maria. **Fundamentos de metodologia científica**. 5. ed. São Paulo: Atlas, 2003.

MATTOS FILHO, Ary Oswaldo. O conceito de valor mobiliário. **Revista de Administração de Empresas**, v. 25, n. 2, p. 37-51, 1985.

<https://doi.org/10.1590/S0034-75901985000200003>

- MCCULLOCH, Warren Sturgis; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943. <https://doi.org/10.1007/BF02478259>
- MEDEIROS, Romero Álamo Oliveira de. **Previsão de demanda no médio prazo utilizando redes neurais artificiais em sistemas de distribuição de energia elétrica**. 2016. 85f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal da Paraíba, João Pessoa, 2016.
- MELO NETO, João Veloso de. **Estudo de caso sobre os desafios da governança corporativa nas empresas públicas federais do Brasil**. Dissertação (Mestrado Profissional em Administração Pública) - FGV - Fundação Getúlio Vargas, Rio de Janeiro, 2016. Disponível em: <<http://bibliotecadigital.fgv.br/dspace/handle/10438/17555>>. Acesso em: 10 out. 2018.
- MINSKY, Marvin Lee. **Theory of neural-analog reinforcement systems and its application to the brain model problem**. Princeton University, 1954.
- MINSKY, Marvin Lee. Steps toward artificial intelligence. **Proceedings of the IRE**, v. 49, n. 1, p. 8-30, 1961. <https://doi.org/10.1109/JRPROC.1961.287775>
- MINSKY, Marvin Lee. **Computation: finite and infinite machines**. Prentice-Hall, Inc., 1967.
- MINSKY, Marvin; PAPERT, Seymour. **Perceptrons**. Cambridge, MA: MIT Press, v. 18, p. 19, 1969.
- MIRANDA, João Felipe Nunes de. **Modelos de regressão e de redes neurais artificiais na quantificação de carbono e biomassa lenhosa em floresta estacional decidual no Brasil Central**. 2015. xii, 76 f., il. Dissertação (Mestrado em Ciências Florestais) - Universidade de Brasília, Brasília, 2015.
- MUNIZ, Gracielle. **Medidas de eficiência energética no sistema de abastecimento de água do Rio das Velhas na região metropolitana de Belo Horizonte**. 2016. 85 f. Dissertação (Mestrado) - Curso de Engenharia Ambiental, Universidade Federal de Santa Catarina, Florianópolis, 2016. Disponível em: <<https://repositorio.ufsc.br/xmlui/handle/123456789/177337>>. Acesso em: 17 out. 2018.
- MUNTASER, João Gonçalves Silva; DA SILVA, Valter Pereira; PENEDO, Antônio Sérgio Torres. Aplicação de Redes Neurais na Previsão das Ações do Setor de Petróleo e Gás da Bm&FBovespa/Application of Neural Networks in Forecasting the Shares of the Oil and Gas Sector of Bm&FBovespa. **Revista FSA (Centro Universitário Santo Agostinho)**, v. 14, n. 6, p. 49-71, 2017. <https://doi.org/10.12819/2017.14.6.3>
- NOGUEIRA JUNIOR, Edgard. **Fundos de investimento imobiliário: uma contribuição ao estudo das práticas contábeis adotadas no Brasil**. 2008. 113 f. Dissertação (Mestrado em Ciências Cont. Atuariais) - Pontifícia Universidade Católica de São Paulo, São Paulo, 2008. Disponível em: <<https://tede2.pucsp.br/handle/handle/1693>>. Acesso em 15 out. 2018.
- OLIVEIRA, Fagner Andrade; NOBRE, Cristiane Neri; ZÁRATE, Luis Enrique. Applying Artificial Neural Networks to prediction of stock price and improvement of the directional

prediction index – Case study of PETR4, Petrobras, Brazil. **Expert Systems with Applications**, v. 40, n. 18, p. 7596-7606, 2013.
<https://doi.org/10.1016/j.eswa.2013.06.071>

OLIVEIRA, Tatianne Cristine Almeida de. **Inovação colaborativa em empresas públicas: estudo de caso da experiência UnB-Correios**. 2017. 132 f. Dissertação (Mestrado) - Curso de Mestrado Profissional em Administração, Universidade de Brasília, Brasília, 2017. Disponível em: <<http://repositorio.unb.br/handle/10482/31992>>. Acesso em: 06 out. 2018.

PAGLIARDI, Odail; DIAS, José Celso Sobreiro. Evolução do Setor Elétrico: uma breve reflexão. **Interciência e Sociedade**, v. 1, n. 1, 2011.

PALIWAL, Mukta; KUMAR, Usha Anantha. Neural networks and statistical techniques: A review of applications. **Expert systems with applications**, v. 36, n. 1, p. 2-17, 2009.
<https://doi.org/10.1016/j.eswa.2007.10.005>

PAVIA, Eduardo Cherez. **Fundos de investimento: estrutura jurídica e agentes de mercado como proteção do investimento privado**. 2015. 183 f. Dissertação (Mestrado em Direito) - Pontifícia Universidade Católica de São Paulo, São Paulo, 2015. Disponível em: <<https://tede2.pucsp.br/handle/handle/6726>>. Acesso em: 17 out. 2018.

PAO, Hsiao-Tien. A comparison of neural network and multiple regression analysis in modeling capital structure. **Expert Systems with Applications**, v. 35, n. 3, p. 720-727, 2008.
<https://doi.org/10.1016/j.eswa.2007.07.018>

PEREIRA, Claudia Catarino. **As empresas estatais e o financiamento do esporte nos governos Lula e Dilma**. 2017. 187 f., il. Dissertação (Mestrado em Educação Física) - Universidade de Brasília, Brasília, 2017. Disponível em: <<http://repositorio.unb.br/handle/10482/25300>>. Acesso em: 17 out. 2018.

PICCOLI, Daniel Madaschi. **Aplicação de redes neurais para previsão de contrato de dólar futuro no mercado brasileiro**. 2014. 51 f. Dissertação (Mestrado) - Curso de Economia e Finanças, Escola de Economia de São Paulo, Fundação Getúlio Vargas, São Paulo, 2014. Disponível em: <<http://hdl.handle.net/10438/11502>>. Acesso em: 25 nov. 2018.

PIETRO, Maria Sylvia Zanella Di. **Direito Administrativo**. 31. ed. Rio de Janeiro: Forense, 2018.

PINTO, Rafaela Inês Pires. **Segmentação Automática de Lesões de Esclerose Múltipla em Imagens de Ressonância Magnética**. 2017. 142 f. Dissertação (Mestrado) - Curso de Engenharia Biomédica, Faculdade de Engenharia, Universidade do Porto, Porto, 2017. Disponível em: <<https://repositorio-aberto.up.pt/handle/10216/105286>>. Acesso em: 02 jan. 2019.

PROVOST, Foster; FAWCETT, Tom. **Data Science for Business: What you need to know about data mining and data-analytic thinking**. O'Reilly Media, Inc., 2013.

REINKE, Meriéle. **Utilização de redes neurais artificiais aplicadas a mapeamentos hidrogeológicos**. 2008. 97 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Geologia, Escola Politécnica, Universidade do Vale do Rio dos Sinos, São Leopoldo, 2008. Disponível em: <<http://www.repositorio.jesuita.org.br/handle/UNISINOS/3099>>. Acesso em: 25 nov. 2018.

RIBAS, Oeslei Tabora. **Classificação de sites a partir das análises estrutural e textual**. 2013. 125 f. Dissertação (Mestrado em Computação Aplicada) - Universidade Tecnológica Federal do Paraná, Curitiba, 2013.

RIBEIRO, Antônio Júnior Alves; DA SILVA, Carlos Augusto Uchôa; DE ARAÚJO BARROSO, Suelly Helena. Metodologia de baixo custo para mapeamento geotécnico aplicado à pavimentação. **TRANSPORTES**, v. 26, n. 2, p. 84-100, 2018.
<https://doi.org/10.14295/transportes.v26i2.1491>

ROCHESTER, Nathaniel et al. Tests on a cell assembly theory of the action of the brain, using a large digital computer. **IRE Transactions on information Theory**, v. 2, n. 3, p. 80-93, 1956.
<https://doi.org/10.1109/TIT.1956.1056810>

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.
<https://doi.org/10.1037/h0042519>

RUMELHART, David Everett; MCCLELLAND, James Lloyd. Parallel Distributed Processing: Explorations in the Microstructure of Cogniton. **Learning internal representations by error propagation**, v. 1, p. 318-362, 1986.

SABINO, João Marcos. **Características Culturais da Petrobrás e da Eletrobrás que Favorecem suas Adaptabilidades**. Dissertação (Mestrado em Administração) - Escola Brasileira de Administração Pública e de Empresas, Fundação Getúlio Vargas - FGV, Rio de Janeiro, 1999. Disponível em: <<http://bibliotecadigital.fgv.br/dspace/handle/10438/3491>>. Acesso em: 17 out. 2018.

SANTOS, Laura Lebos Alemparte Abrantes dos. **Valor público em disputa na administração pública brasileira - o caso do Banco do Brasil: “um banco de mercado com espírito público”**. 2016. 143 f. Dissertação (Mestrado) - Curso de Pós-graduação em Administração, Faculdade de Administração, Ciências Contábeis e Turismo, Universidade Federal Fluminense, Niterói, 2016. Disponível em: <<https://app.uff.br/riuff/handle/1/3808>>. Acesso em: 17 out. 2018.

SANTOS, Murilo Alves et al. Aplicação de redes neurais no Brasil: um estudo bibliométrico. **Biblionline**, v. 12, n. 2, p. 101-116, 2016.

SCHIRATO, Vítor Rhein. Novas anotações sobre as empresas estatais. **Revista de Direito Administrativo**, v. 239, p. 209-240, 2005.
<https://doi.org/10.12660/rda.v239.2005.43868>

SCHMIDT, Cristiane Bohrer. **Petróleo em águas turbulentas: a Petrobrás em tempos de expansão financeira**. 2017. 343 f. Dissertação (Mestrado) - Curso de Pós-graduação em Relações Internacionais, Universidade Federal de Santa Catarina, Florianópolis, 2017. Disponível em: <<https://repositorio.ufsc.br/xmlui/handle/123456789/179667>>. Acesso em: 17 out. 2018.

SILVA, Anderson Rodrigues da. **Aspectos regulatórios da bolsa de valores no Brasil**. 2017. 135 f. Dissertação (Mestrado) - Curso de Direito, Programa de Estudos Pós-graduados em Direito, Pontifícia Universidade Católica de São Paulo, São Paulo, 2017. Disponível em: <<https://tede2.pucsp.br/handle/handle/20876>>. Acesso em: 15 out. 2018.

SILVA, Carlos Alberto de Albuquerque. **Implementação de uma matriz de neurônios dinamicamente reconfigurável para descrição de topologias de redes neurais artificiais multilayer perceptrons**. 2015. 90f. Tese (Doutorado em Engenharia Elétrica e de Computação) - Centro de Tecnologia, Universidade Federal do Rio Grande do Norte, Natal, 2015.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernani; FLAUZINO, Rogério Andrade. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 399 p.

SILVA, Juliana Mendes Nascente. **Redes Neurais Artificiais: Rede Hopfield e Redes Estocásticas**. 2003. Disponível em: <http://www2.ic.uff.br/~jsilva/monografia_RNA.pdf>. Acesso em: 20 out. 2018.

SILVA, Leon Sólton da. **Modelos preditivos para seleção de solicitações de compensação de crédito tributário**. 2016. xi, 62 f., il. Dissertação (Mestrado Profissional em Computação Aplicada) - Universidade de Brasília, Brasília, 2016. Disponível em: <<http://repositorio.unb.br/handle/10482/22127>>. Acesso em: 15 out. 2018.

SILVA, Maria Daniella de Oliveira Pereira da. **O efeito do sentimento das notícias sobre o comportamento dos preços no mercado acionário brasileiro**. 2017. 212 f., il. Tese (Doutorado em Ciências Contábeis) - Programa Multi-Institucional e Inter-Regional de Pós-Graduação em Ciências Contábeis, Universidade de Brasília, Universidade Federal da Paraíba, Universidade Federal do Rio Grande do Norte, João Pessoa, 2017. Disponível em: <<http://repositorio.unb.br/handle/10482/32178>>. Acesso em: 17 out. 2018.

SILVA, Thays Aparecida de Abreu. **Previsão de cargas elétricas através de um modelo híbrido de regressão com redes neurais**. 2012. 62 f. Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, 2012.

SOUZA, Starch Melo de. **Modelo preditivo de mineração de dados para sucesso de redução de peso na cirurgia bariátrica**. 2014. 84 f. Dissertação (Mestrado) - Curso de Pós-graduação em Ciência da Computação, Centro de Informática, Universidade Federal de Pernambuco, Recife, 2014. Disponível em: <<https://repositorio.ufpe.br/handle/123456789/16937>>. Acesso em: 17 out. 2018.

SUZART, Janilson Antônio da Silva. **Informações contábeis governamentais e o mercado secundário de títulos públicos: um estudo sob a ótica da value relevance no Brasil**. 2013. Tese de Doutorado. Universidade de São Paulo. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/12/12136/tde-20012014-164828/pt-br.php>>. Acesso em: 15 out. 2018.

TANCREDI, Pamela Rosa. **Monitoramento do acesso de veículos de carga em vias urbanas**. 2012. 97 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Engenharia de Transportes, Universidade de São Paulo, São Carlos, 2012. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18144/tde-20062013-161631/>>. Acesso em: 20 dez. 2018.

TAVARES, Vitor Borges. **Níveis de governança corporativa e desempenho: uma validação por meio de redes neurais artificiais**. 2016. 92 f. Dissertação (Mestrado em Administração) - Universidade Federal de Uberlândia, Uberlândia, 2016.

TURCATO, Afonso Celso. **Desenvolvimento de uma metodologia baseada em redes neurais artificiais para a identificação de anomalias em redes de comunicação Profinet**.

2015. 218 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2015. Disponível em:
<<http://www.teses.usp.br/teses/disponiveis/18/18153/tde-04082015-112148/>>. Acesso em: 20 dez. 2018.

UTTLEY, Albert Maurel. A theory of the mechanism of learning based on the computation of conditional probabilities. In: **Proceedings of the First International Conference on Cybernetics, Namur, Gauthier-Villars**. 1956.

VALE, Gustavo Bruno do. **Reconstrução e reconhecimento de imagens binárias utilizando o algoritmo máquina de Boltzmann**. 2016. 107 f. Dissertação (Mestrado) - Curso de Pós-graduação em Engenharia Elétrica, Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2016. Disponível em:
<<https://repositorio.ufu.br/handle/123456789/17561>>. Acesso em: 20 out. 2018.

VALENÇA, Mêuser. **Fundamentos das Redes Neurais**. 2. ed. Recife: Livro Rápido, 2010.

VALENTE, Catarina Nunes. **Programação em Excel para Estatística: Modelo Linear e Extensões**. 2017. 113 f. Dissertação (Mestrado) - Curso de Mestrado em Matemática Aplicada à Economia e Gestão, Estatística e Investigação Operacional, Universidade de Lisboa, Lisboa, 2017. Disponível em:
<http://repositorio.ul.pt/bitstream/10451/27659/1/ulfc120785_tm_Catarina_Valente.pdf>. Acesso em: 17 out. 2018.

VIEIRA, Edson Roberto; CORRÊA, Vanessa Petrelli. Mercado de Capitais e Governança Corporativa no Brasil: reflexões sobre os movimentos recentes. **Fórum Banco do Nordeste de Desenvolvimento, VII Encontro Regional de Economia, Fortaleza**, 2002.

WIDROW, Bernard; HOFF, Marcian Edward. **Adaptive switching circuits**. Stanford Univ Ca Stanford Electronics Labs, 1960.
<https://doi.org/10.21236/AD0241531>

WIDROW, Bernard. Generalization and information storage in network of adaline 'neurons'. **Self-Organizing Systems**, p. 435-461, 1962.

YAHOO! FINANÇAS. **IBOVESPA, 2019**. Disponível em:
<<https://br.financas.yahoo.com/quote/%5EBVSP/history?p=%5EBVSP>>. Acesso em: 20 fev. 2019.

ZHANG, Peter Guoqiang; PATUWO, Butje Eddy; HU, Michael Y. Forecasting with artificial neural networks: The state of the art. **International journal of forecasting**, v. 14, n. 1, p. 35-62, 1998.
[https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)

APÊNDICE A - MATLAB

A análise dos trabalhos apresentados no Quadro 5 mostra que a maioria dos estudos recentes com RNA utiliza o ambiente MATLAB para a construção da solução do problema abordado. Sendo assim e, visto que a presente pesquisa também utilizará o referido ambiente computacional, é oportuno apresentá-lo e inserir um breve tutorial sobre a sua utilização básica. Tal manual objetiva capacitar o leitor, caso desejado, a reproduzir o trabalho realizado neste estudo.

A *toolbox* NNTOOL (*Neural Network Tool*) do ambiente MATLAB é apresentada e um passo-a-passo de como criar uma rede neural artificial genérica é mostrado utilizando-se a referida ferramenta, de modo a habilitar o leitor a entender como o modelo baseado em rede neural desta pesquisa foi construído com o auxílio do computador.

AMBIENTE E UTILIZAÇÃO BÁSICA

O MATLAB (*Matrix Laboratory*) é um ambiente computacional específico composto por um conjunto de várias ferramentas, sendo propriedade comercial da Mathworks®. Como o próprio nome sugere – Laboratório de Matrizes -, é um software desenvolvido à base de cálculos matriciais. Foi criado no fim da década de 1970 por Cleve Moler, um dos pioneiros da Mathworks® (DELGADO NETO, 2017).

Atualmente, o MATLAB é utilizado em pesquisas nas mais diversas áreas do conhecimento, como, por exemplo, matemática, engenharias, física e computação. Possuindo uma linguagem de programação nativa integrada, a implementação de soluções pode ser construída rapidamente, devido a presença de funções predefinidas no próprio ambiente. Conforme cita Delgado Neto (2017), o MATLAB é otimizado para a construção de soluções de problemas que envolvam cálculos científicos e numéricos. Sua interface gráfica com o usuário possui um conjunto de *toolboxes* (caixas de ferramentas) que contêm particularidades específicas para o processamento de sinais, criação e manipulação de equações diferenciais, processamento de imagens, etc. “Possui um ambiente genérico de computação científica, apresentando uma linguagem matricial simples, compacta e próxima da matemática” (TANCREDI, 2012, p. 39).

Ademais, a simplicidade para a efetuação de operações matriciais, cálculos numéricos e plotagem de gráficos popularizou a utilização do MATLAB como plataforma. Além dos

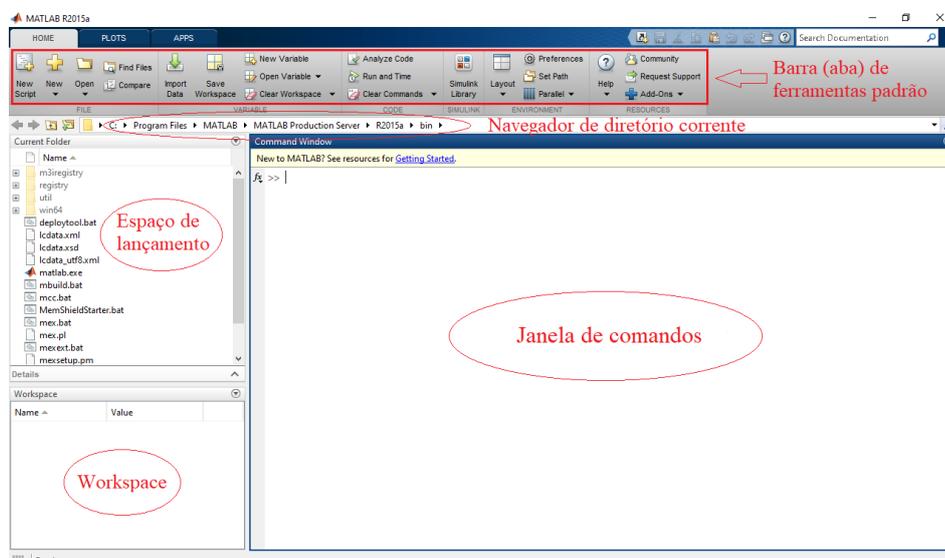
componentes comuns à maioria dos softwares, como menus, barras e caixas de ferramentas, caixas de listagem e botões, o ambiente possui uma interface gráfica que possibilita a realização de tarefas interativas e dinâmicas, como criação, leitura e gravação de arquivos, comunicação direta com outros ambientes específicos e exibição de dados em tabelas e gráficos (DELGADO NETO, 2017).

À época, Chapman (2003) cita em seu livro duas desvantagens principais para a utilização do MATLAB. A primeira é o fato de a plataforma utilizar uma linguagem de programação interpretada, que pode, dependendo do problema abordado, apresentar execução da solução mais lenta quando comparada a soluções construídas com linguagens compiladas. A segunda se refere ao custo financeiro para a obtenção de uma cópia legal do software. Segundo o autor, o preço de uma licença para uso individual costuma ser bem alto. No entanto, a Mathworks® disponibiliza uma versão para estudantes com preço bem mais acessível para aqueles que estão começando a utilizar o ambiente e sua linguagem.

Ademais, convém agora apresentar os principais componentes do ambiente MATLAB e suas funcionalidades fundamentais. Os passos e exposições a seguir assumem que o leitor possui o software devidamente instalado em seu sistema operacional de preferência. A versão utilizada neste trabalho foi a 8.5.0.19 (R2015a), executando num computador pessoal com Windows® 7, 4 gigabytes de memória principal e processador Intel® i5 de 64 bits.

Inicialmente, ao ser aberto, o MATLAB apresenta a sua área de trabalho, conforme mostrado na Figura 42. A aparência exata dela pode apresentar algumas diferenças dependendo da versão instalada e/ou sistema operacional do utilizador.

Figura 42 – Área de trabalho do MATLAB R2015a.



Fonte: Elaborada pelo autor.

As principais ferramentas presentes na área de trabalho do MATLAB estão destacadas na Figura 42. São elas: janela de comandos, janela *Workspace*, navegador de diretório corrente, espaço de lançamento e barra (ou aba) padrão de ferramentas.

A janela de comandos situa-se do lado direito da área de trabalho do ambiente. Sua função é permitir a inserção de comandos interativos pelo utilizador, os quais são imediatamente executados ao se pressionar a tecla *Enter*. À medida que comandos são executados nesta janela, os mesmos são listados na janela *Workspace*, juntamente com as variáveis armazenadas, de modo a manter um histórico de execução. Tais comandos e variáveis permanecem listados até que sejam manualmente apagados através de um clique com o botão direito do mouse, escolhendo-se a opção correspondente à exclusão de um item. Para reexecutar um comando presente na lista, o utilizador deve efetuar duplo clique naquele que escolheu (CHAPMAN, 2003).

Por sua vez, a barra denominada navegador de diretório corrente permite que o utilizador verifique o diretório em que está dentro do sistema operacional. Se desejar mudar tal localização, os botões localizados à esquerda dessa barra devem ser utilizados. Cada projeto construído no MATLAB pode ser armazenado em diretórios distintos, cujo caminho é exibido nessa barra quando o mesmo é o projeto corrente.

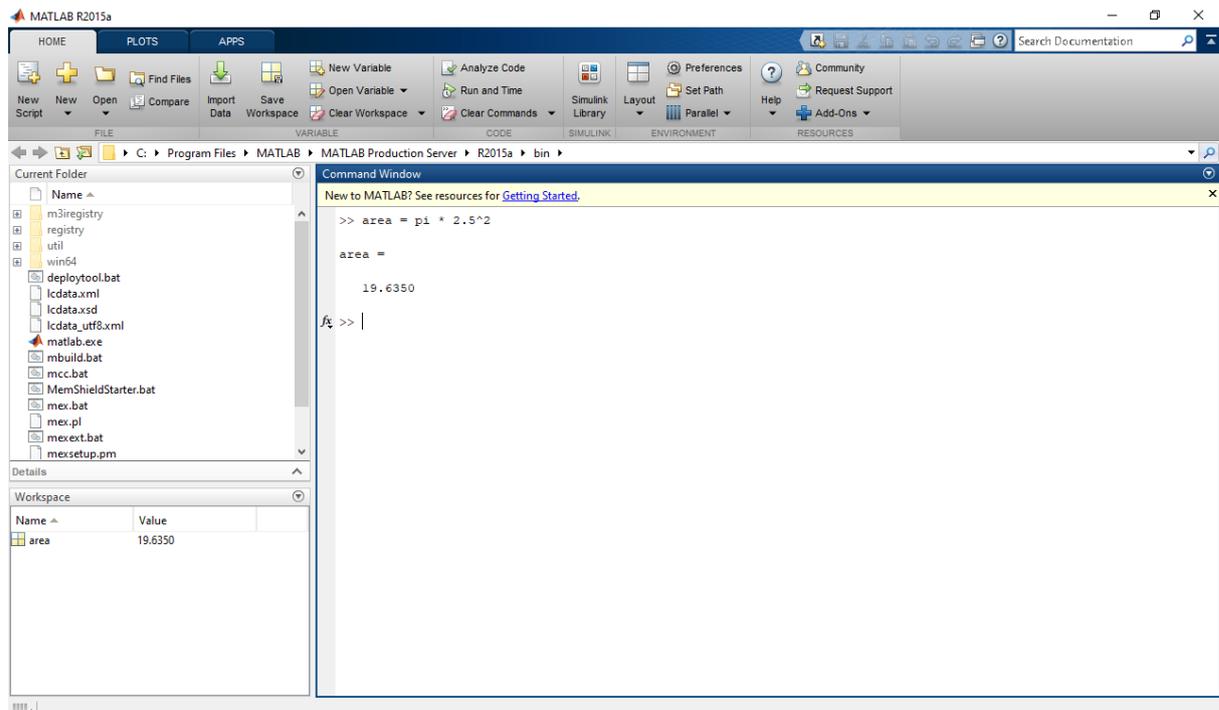
A janela denominada espaço de lançamento apresenta graficamente uma árvore dos itens presentes no diretório do projeto corrente. Caso existam diretórios (subpastas) no diretório corrente, as mesmas são exibidas com um sinal “+” do lado esquerdo, de modo que, quando é clicado, a subpasta expande seu conteúdo na árvore gráfica, exibindo seu conteúdo.

A barra (ou aba) padrão de ferramentas possui os itens mais comumente utilizados em projetos do MATLAB, a saber: novo *script*, abrir projeto ou arquivo, importar dados, salvar *workspace*, nova variável, execução de comandos, mudança de *layout*, análise de código, configuração de preferências, ajuda online, etc. Situa-se no topo do ambiente e possui botões com rótulos correspondentes às ações que realizam, muitos deles possuindo uma seta que indica a presença de subitens.

Um exemplo de execução de um comando do usuário é mostrado na Figura 43. Nele, é solicitado que o MATLAB calcule a área de um círculo cujo raio mede 2,5 unidades. O comando é digitado na janela de comandos, seguido do pressionamento da tecla *Enter*, de modo a apresentar o resultado do cálculo. Após isso, a variável criada contendo o cálculo é armazenada na janela *workspace*, podendo ser utilizada em outros cálculos. Caso seja necessário repetir tal cômputo, basta executar duplo clique no rótulo da variável listada em tal janela. É interessante notar que π já está predefinido no MATLAB, sendo desnecessário digitar

seu valor real ou declarar uma variável para armazená-lo. Além de π , o ambiente possui uma série de constantes e funções matemáticas já predefinidas, facilitando o trabalho do usuário na construção de projetos bem elaborados. Uma listagem completa e extensa pode ser consultada em Chapman (2003).

Figura 43 – Exemplo de execução de uma instrução na janela de comandos do MATLAB.

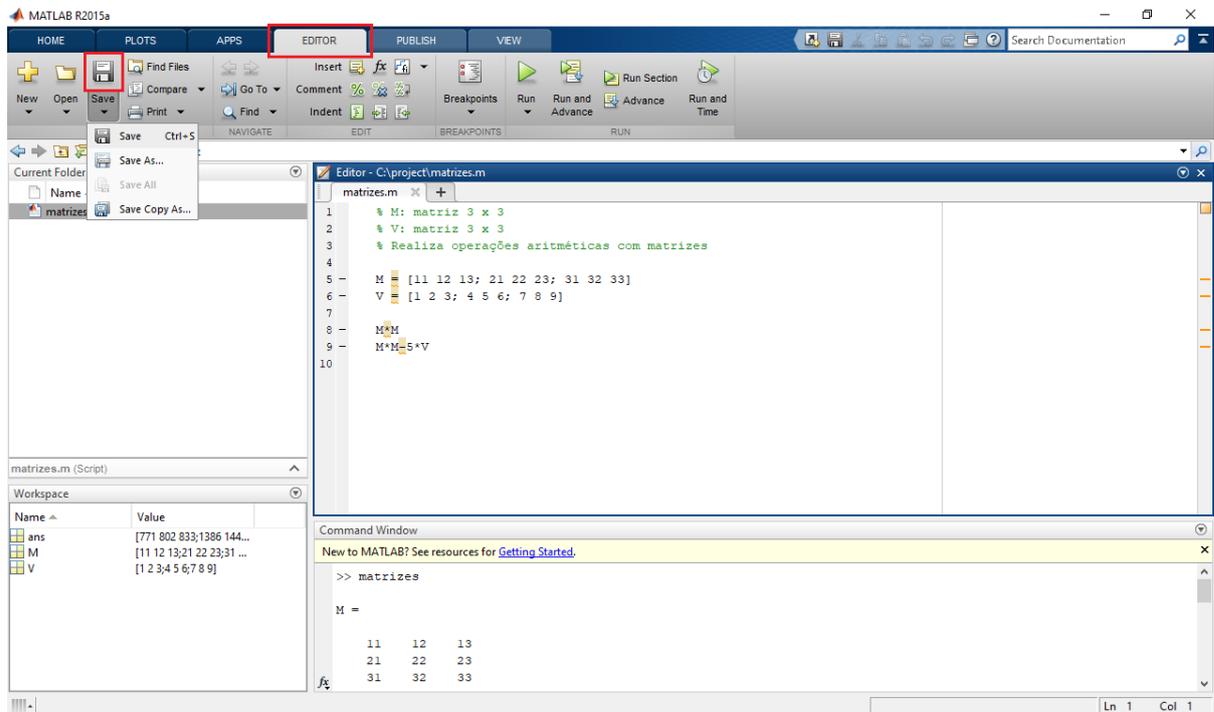


Fonte: Elaborada pelo autor.

Como destaca Chapman (2003), em vez de digitar vários comandos na janela de comandos, é possível armazená-los num arquivo, de modo que o mesmo pode executar todo o seu conteúdo quando apenas seu nome é digitado na janela de comandos do MATLAB. Tais arquivos são chamados de arquivos de *scripts* e possuem a extensão nativa “.m”. A Figura 44 mostra um exemplo de criação de um arquivo de *script* contendo comandos que criam duas matrizes de números inteiros e realizam algumas operações aritméticas com as mesmas. Para criar tal arquivo, o botão “New Script” situado na barra padrão de ferramentas deve ser clicado. Quando acionado, o MATLAB imediatamente abre uma janela de edição para a inserção do conteúdo do *script* numa nova aba intitulada “Editor”, que contém botões específicos para, por exemplo, salvar o *script*, executá-lo, inserir funções nativas do MATLAB, inserir comentários ou formatar o código, etc. Ao solicitar ao ambiente que salve um arquivo de *script*, o usuário deve escolher um nome e o diretório onde o mesmo será salvo. É interessante criar diretórios

únicos para cada projeto individual no MATLAB, de modo a armazenar os arquivos de *scripts* que façam parte do escopo do projeto que está sendo realizado.

Figura 44 – Criação e armazenamento de um arquivo de *script* no MATLAB.

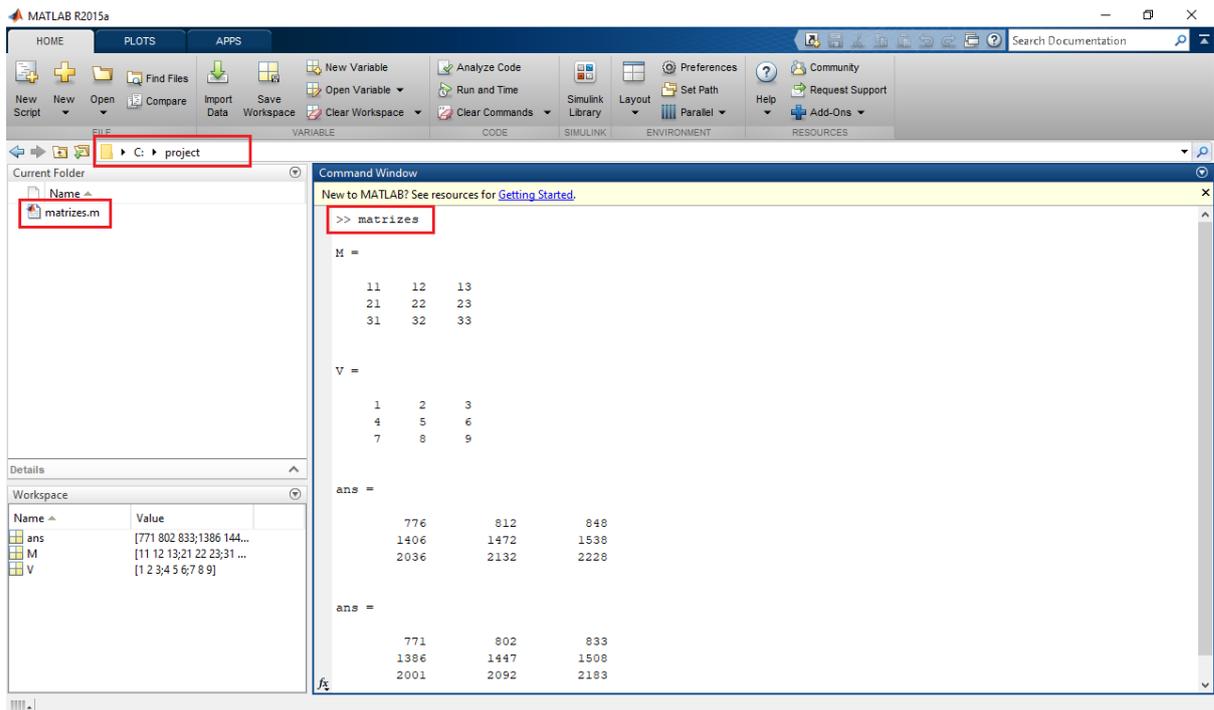


Fonte: Elaborada pelo autor.

O arquivo de *script* criado na Figura 44 foi nomeado como “matrizes.m”. Para executar os comandos inseridos nele, basta digitar o nome do arquivo sem sua extensão na janela de comandos do MATLAB, conforme apresentado na Figura 45. Outra alternativa é clicar no botão “Run” presente na aba “Editor” quando o arquivo de *script* estiver aberto para a edição do seu conteúdo.

Para que a execução das instruções do arquivo de *script* via janela de comandos seja bem-sucedida, o diretório corrente apresentado na barra navegador de diretório corrente deve apontar para onde o arquivo foi armazenado. Caso contrário, o MATLAB exibirá uma mensagem de erro informando que desconhece a função ou variável digitada no *prompt* de comandos do ambiente.

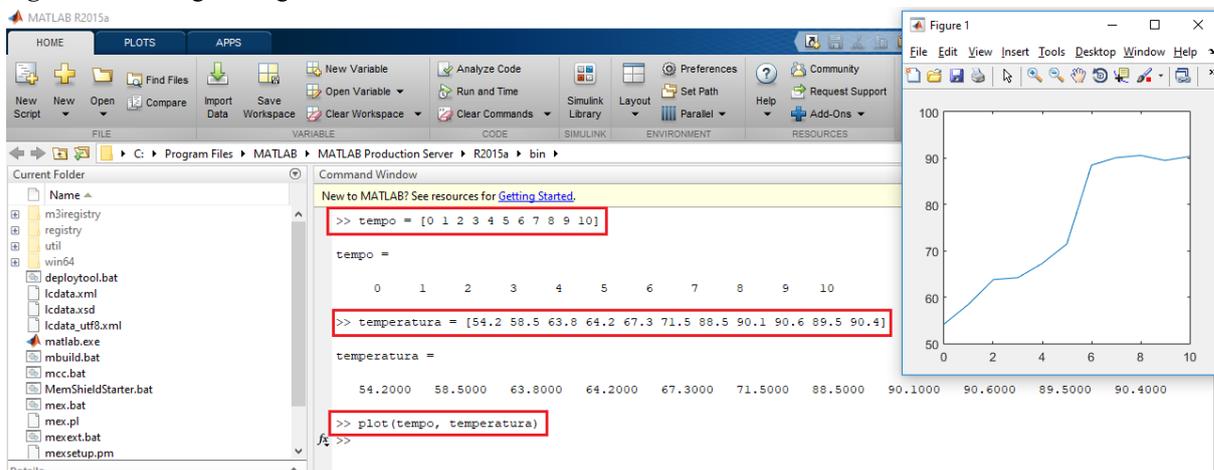
Figura 45 - Execução de um arquivo de *script* via janela de comandos.



Fonte: Elaborada pelo autor.

Ademais, um dos recursos mais importantes do ambiente MATLAB é a janela de figuras. Como explica Chapman (2003), a mesma é responsável pela representação gráfica bidimensional ou tridimensional de informações, conhecida como plotagem. Tal janela, quando apresentada, exibe menus e botões próprios que podem ser utilizados para manipular a figura, como, por exemplo, salvar, imprimir, editar, rotacionar, exportar, etc. A Figura 46 mostra a plotagem de um gráfico que relaciona medidas de tempo e temperatura. Os valores foram armazenados em vetores que, por natureza, são matrizes unidimensionais.

Figura 46 - Plotagem de gráfico bidimensional no MATLAB.



Fonte: Elaborada pelo autor.

A Figura 47 apresenta a plotagem de uma figura bidimensional gerada como resultado da execução dos comandos utilizados conforme mostrados no Quadro 7. Um arquivo de *script* foi gerado, armazenado com o nome “function1.m” e executado via janela de comandos. Tal exemplo é citado por Lopez (2014, p. 23), mostrando que o MATLAB consegue modelar gráficos de funções complexas que utilizem senos, cossenos, tangentes, etc. Para entender a utilização de funções nativas das bibliotecas do ambiente MATLAB, como, por exemplo, “linspace” e “sin” (seno), basta digitar no *prompt* da janela de comandos a palavra *help* seguida do nome da função procurada.

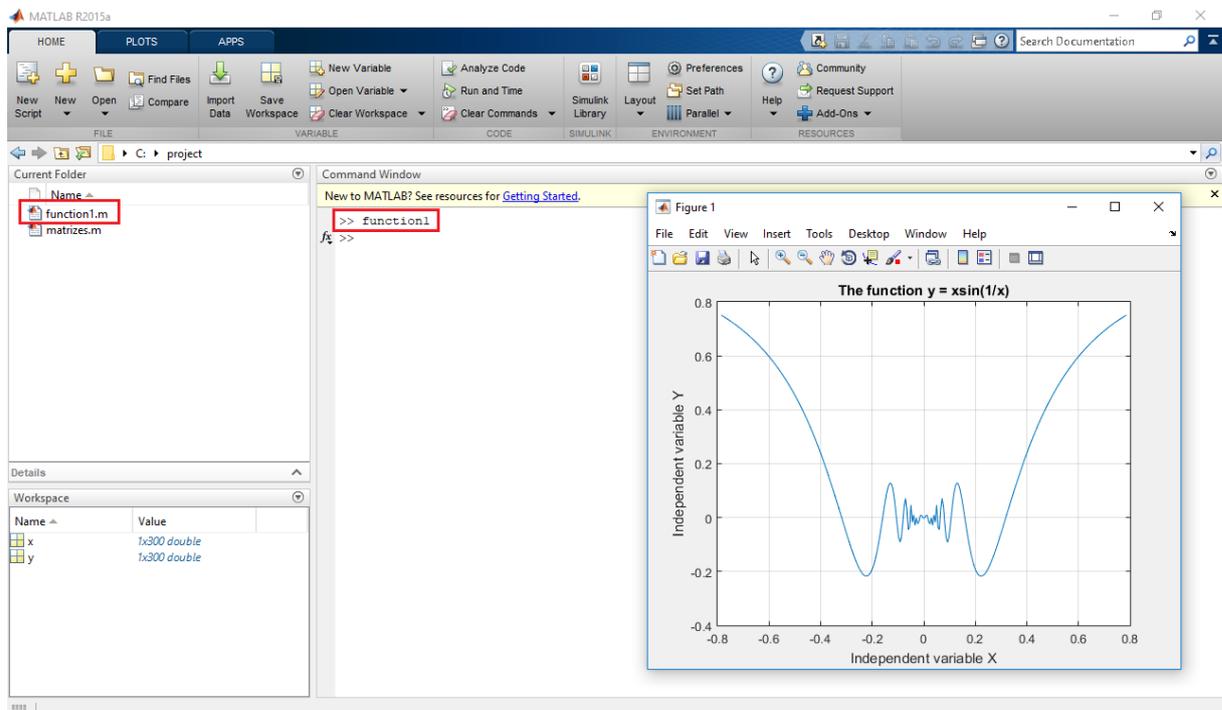
Quadro 7 – Comandos para geração do gráfico bidimensional de uma função.

```
x = linspace(-pi/4, pi/4, 300);
y = x.*sin(1./x);
plot(x,y);
grid;

xlabel('Independent variable X');
ylabel('Independent variable Y');
title('The function y = xsin(1/x)')
```

Fonte: Lopez (2014).

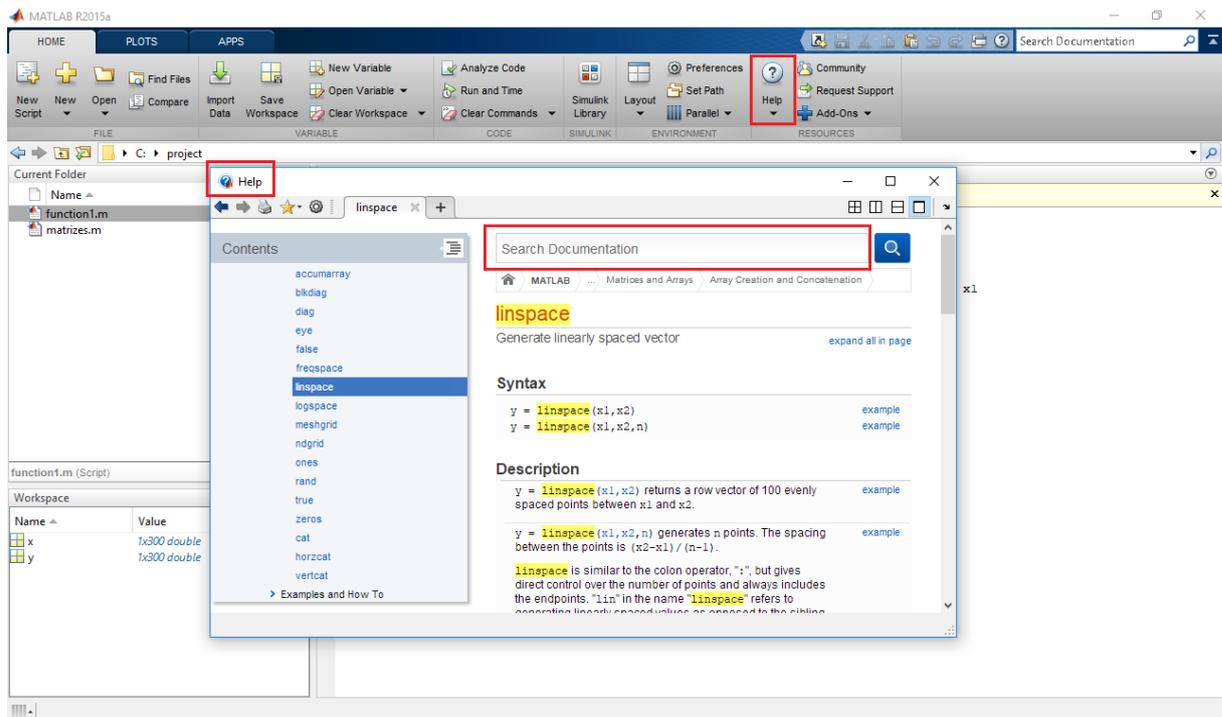
Figura 47 - Plotagem do gráfico bidimensional da função apresentada no Quadro 7.



Fonte: Elaborada pelo autor baseado em Lopez (2014).

Ainda, para visualizar a documentação completa do MATLAB, o usuário pode utilizar o botão “*Help*” localizado na barra padrão de ferramentas do ambiente. Nesse caso, a janela de mesmo nome será aberta, conforme mostra a Figura 48. Nela, há a presença de uma caixa de texto que pode ser utilizada para a busca de informação de funções e recursos da plataforma.

Figura 48 – Acesso à documentação completa do MATLAB.



Fonte: Elaborada pelo autor.

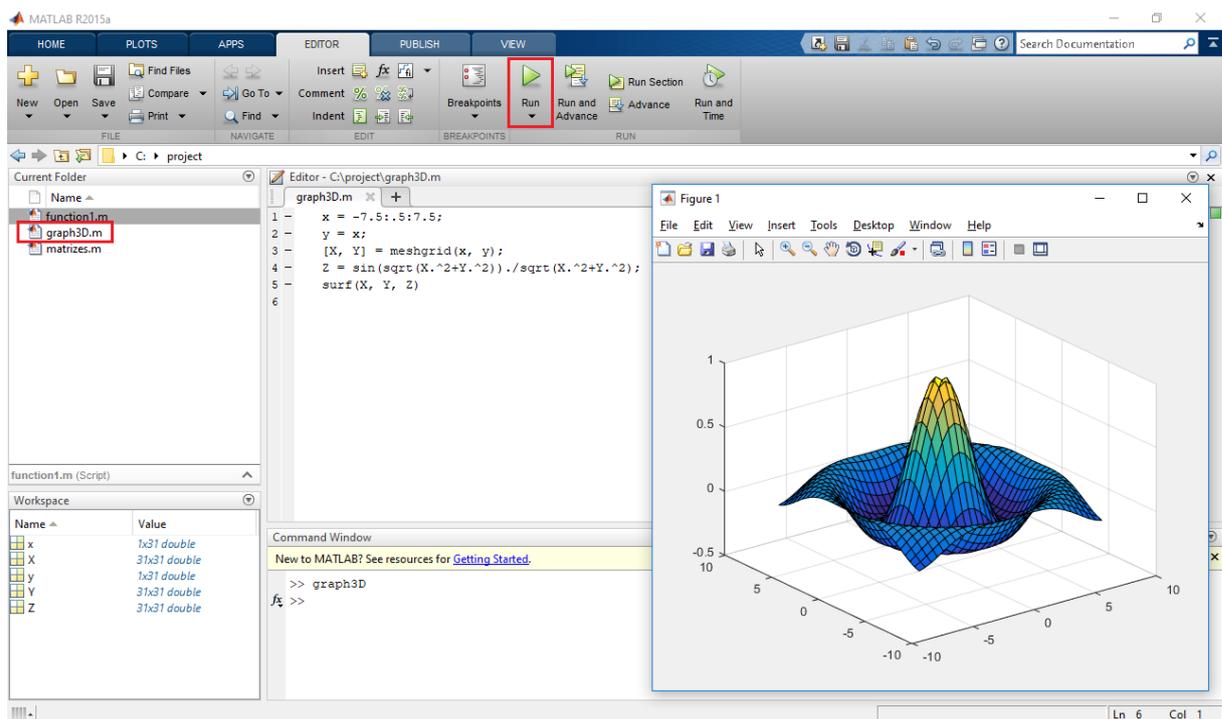
Adicionalmente, o MATLAB possui recursos poderosos para a plotagem de gráficos tridimensionais, como o mostrado na Figura 49. Tal exemplo é indicado em Lopez (2014, p. 24). Os comandos que geram o gráfico são apresentados no Quadro 8. Um arquivo de *script* foi criado, armazenado com o nome “graph3D.m” e executado via janela de comandos. As descrições completas das funções utilizadas no exemplo podem ser encontradas na documentação da plataforma.

Quadro 8 – Comandos para geração do gráfico de uma superfície em 3D.

```
x = -7.5:5:7.5;
y = x;
[X, Y] = meshgrid(x, y);
Z = sin(sqrt(X.^2+Y.^2))./sqrt(X.^2+Y.^2);
surf(X, Y, Z)
```

Fonte: Lopez (2014).

Figura 49 - Plotagem do gráfico tridimensional da função apresentada no Quadro 8.



Fonte: Elaborada pelo autor baseado em Lopez (2014).

Dessa forma, conforme destaca Chapman (2003), é possível observar que o ambiente MATLAB pode ser utilizado desde como uma simples calculadora para a realização de cálculos simples até como uma plataforma completa para a construção de programas complexos. Em seu livro, o autor apresenta de forma abrangente os recursos do MATLAB para programação utilizando sua linguagem nativa, como, por exemplo, estruturas condicionais, laços, funções de entrada/saída, funções definidas pelo usuário, construção de pseudocódigo e manipulação de cadeias de caracteres.

Por sua vez, Lopez (2014) faz uma consideração ampla de recursos gráficos do MATLAB para a construção bem elaborada de diagramas bidimensionais e tridimensionais. São explanados itens como, por exemplo, diagramas de linhas, barras e setores, histogramas, utilização de coordenadas paramétricas e polares, superfícies, malhas, exibição de polígonos e volumes, etc.

Complementarmente, Lopez (2014) apresenta que o ambiente MATLAB possui as chamadas *toolboxes*, que são coleções de funções da plataforma destinadas a propósitos especiais. Tais coleções estendem o software, possibilitando a utilização de ferramentas específicas para a construção de soluções de determinadas classes de problemas.

Nesse contexto, a *toolbox* NNTOOL se destaca para o desenvolvimento de RNA, possuindo uma interface bastante intuitiva, de modo a dispensar a programação manual do

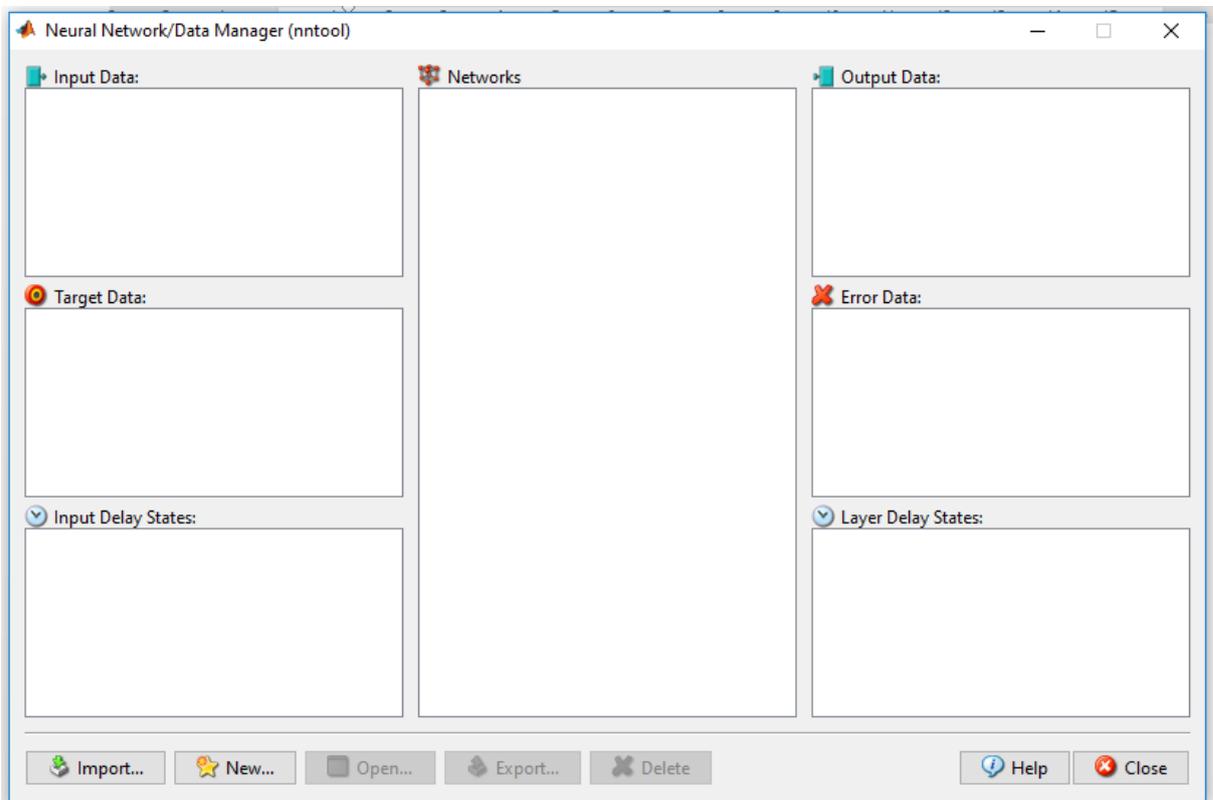
usuário. Tal *toolbox* é utilizada neste trabalho para a construção do modelo preditivo para a cotação dos preços máximos e mínimos de ações financeiras das empresas estatais brasileiras previamente escolhidas.

A TOOLBOX NNTOOL

Conforme mencionado por Pinto (2017), a *toolbox NNTOOL* do ambiente MATLAB se destina especificamente à criação, configuração e manipulação de RNA, possibilitando o projeto, treino, visualização e simulação de tais redes. Sua interface gráfica possui elementos que permitem a importação, criação, utilização e exportação de dados de redes neurais. Além disso, a *NNTOOL* "possibilita a construção de diferentes topologias, com variações de algoritmos e parâmetros de treinamento" das RNA (RIBEIRO, 2018, p. 90).

Para acessá-la, basta digitar na janela de comandos do MATLAB a instrução “*nntool*” e pressionar a tecla *Enter*. Após isso, a interface gráfica da *toolbox* é aberta, conforme mostrado na Figura 50.

Figura 50 - A *toolbox NNTOOL* do MATLAB.



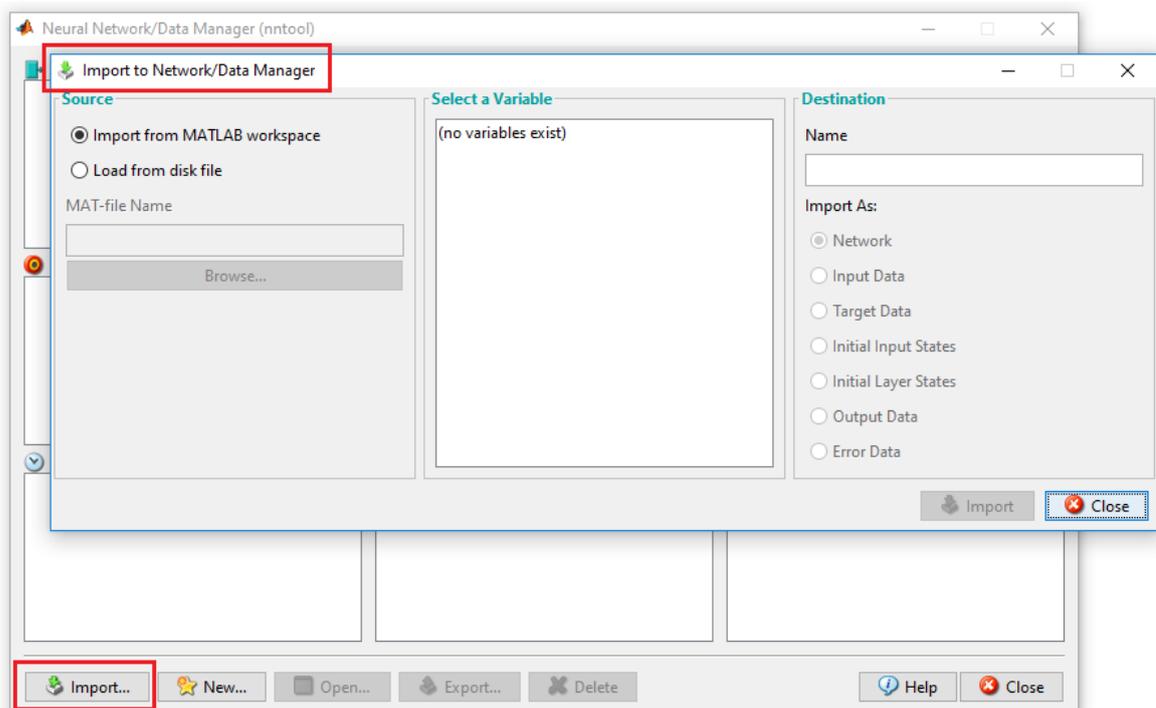
Fonte: Elaborada pelo autor.

É importante salientar que, no ambiente MATLAB, as RNA também podem ser construídas através de instruções de programação na janela de comandos ou através de arquivos de *script* (PINTO, 2017). No entanto, a utilização da interface gráfica da *toolbox* NNTOOL facilita a configuração de parâmetros inerentes às RNA, o que é bem mais complexo quando feito via linguagem do MATLAB por intermédio de arquivos ou via janela de comandos.

Através da janela inicial da NNTOOL, o botão “*Import*” possibilita a importação dos parâmetros da rede neural artificial que será criada. Já o botão “*New*”, permite a inserção manual de tais dados, o que demanda mais atenção do autor do projeto. Como cita Almeida (2012, p. 61), a importação da rede neural viabiliza a definição do “conjunto de valores de treino e valores iniciais dos pesos da rede, ou até mesmo uma rede previamente treinada”. Por sua vez, a criação direta de uma rede neural artificial sem a importação de dados possibilita definir “o tipo de rede, *inputs*, *outputs*, função de ativação, algoritmo de aprendizagem, número de camadas, número de neurônios, havendo várias opções possíveis para cada um dos parâmetros” (ALMEIDA, 2012, p. 61).

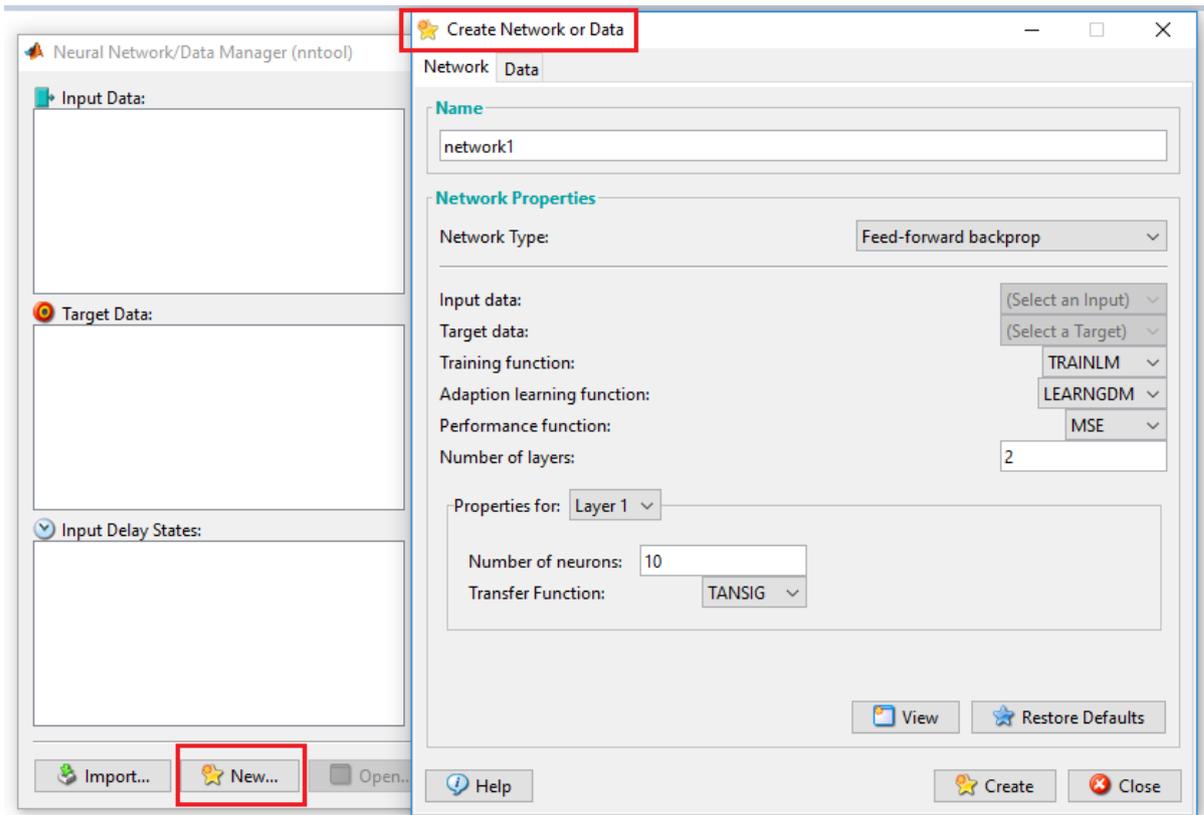
A Figura 51 apresenta a tela que é aberta após a escolha da opção de importação da rede neural artificial na janela principal da *toolbox* NNTOOL. A Figura 52 mostra a janela aberta após a escolha da opção “*New*”. É interessante notar as diversas opções disponíveis nas duas telas para a criação e configuração de RNA.

Figura 51 – Tela de importação de dados da *toolbox* NNTOOL.



Fonte: Elaborada pelo autor.

Figura 52 – Tela de criação de rede neural com a opção “New” da NNTOOL.



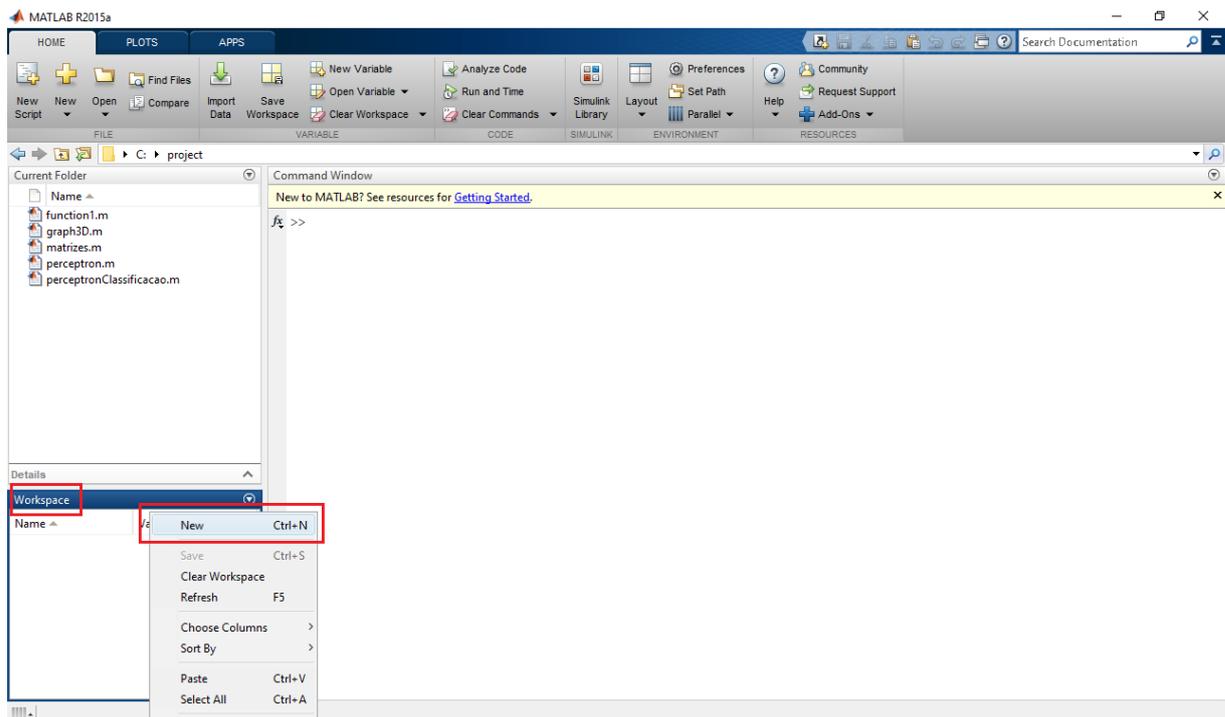
Fonte: Elaborada pelo autor.

Ademais, é interessante demonstrar a criação de uma rede neural artificial utilizando a *toolbox* NNTOOL do ambiente MATLAB. O exemplo a seguir cria um modelo simples de predição baseado em rede neural artificial que utiliza dados externos previamente coletados, contendo as entradas (*inputs*) e as saídas esperadas (*outputs* ou *targets*). É desejado que, a partir dos dados históricos armazenados, a rede aprenda o padrão de comportamento e gere o modelo preditivo. Os dados são genéricos e não representam uma situação real, sendo utilizados a título de exemplificação.

Inicialmente, são criadas as variáveis que armazenam as entradas e saídas da rede neural artificial a ser construída. As mesmas são criadas diretamente no MATLAB e seus conteúdos recebem os dados que foram previamente armazenados no Microsoft® Office Excel. Ressalta-se que qualquer outro software de planilha eletrônica poderia ter sido utilizado, uma vez que a importação de forma tabular no MATLAB é realizada de forma automática.

Para criar as variáveis, utiliza-se o clique com o botão direito do mouse na janela “*Workspace*”. Em seguida, no menu que surge, a opção “*New*” deve ser escolhida. A Figura 53 apresenta tais procedimentos.

Figura 53 – Criação das variáveis de entrada e saída da rede neural artificial.



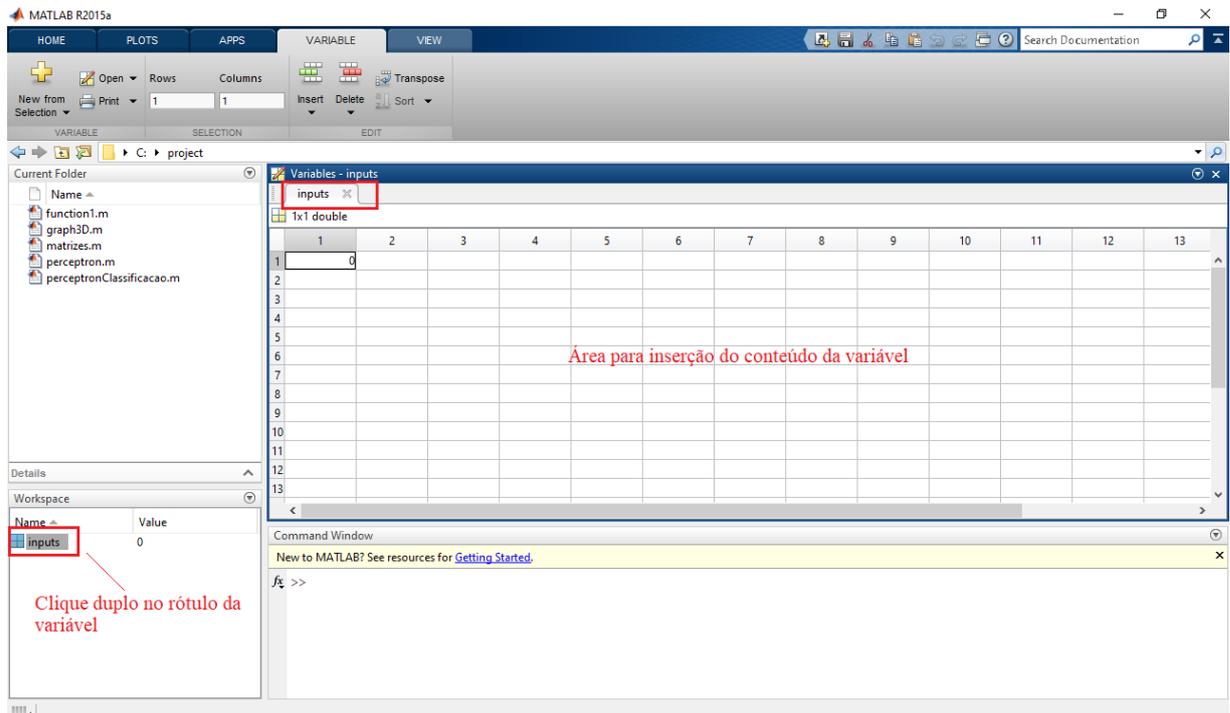
Fonte: Elaborada pelo autor.

O procedimento mostrado na Figura 53 deve ser realizado para a criação de cada uma das variáveis que fazem parte do escopo da solução do problema abordado. A seguir, é necessário digitar o rótulo para cada variável e pressionar a tecla *Enter*.

No exemplo considerado, as variáveis de entrada e saída receberam os nomes de *inputs* e *targets*, respectivamente. Para importar os dados coletados e armazenados, realiza-se clique duplo no rótulo da variável escolhida. Este procedimento abre uma janela no MATLAB contendo uma tela com conteúdo tabular em branco, pronta para a inserção dos dados que a variável conterà. A Figura 54 apresenta tal procedimento.

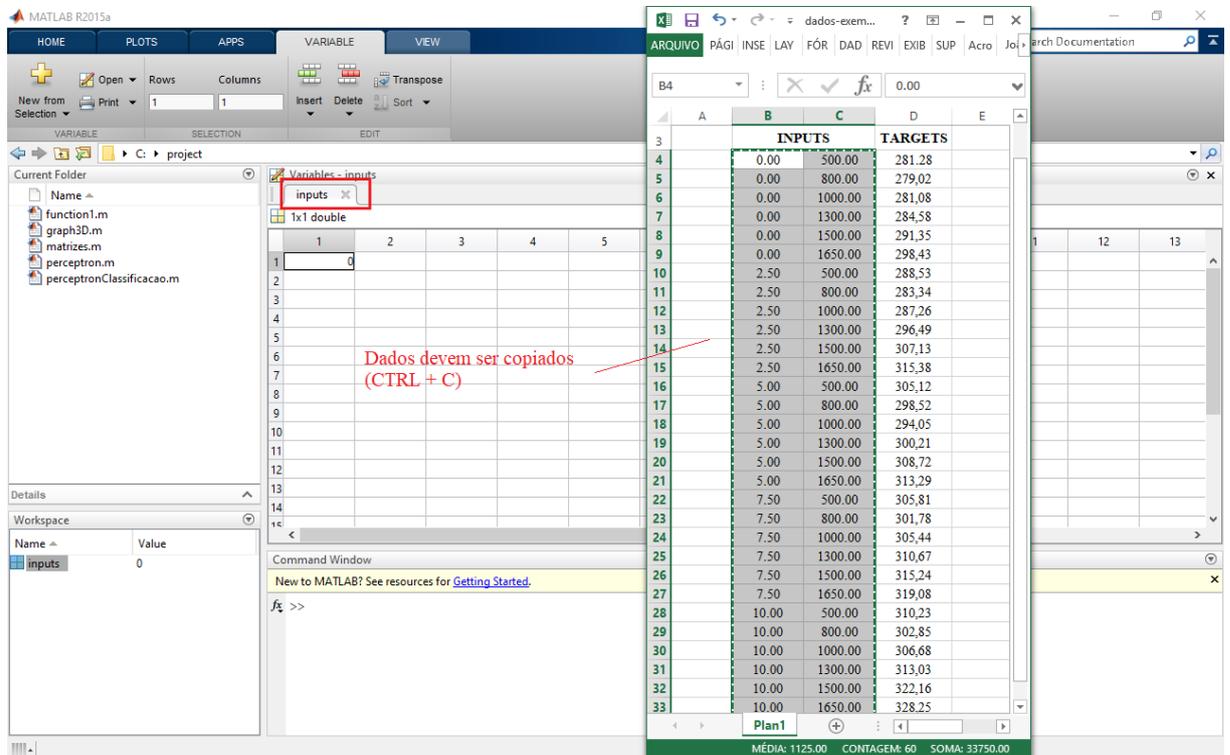
Por sua vez, as Figuras 55 e 56 mostram a importação dos dados armazenados no Microsoft® Office Excel para a variável *inputs*, que representa os dados de entrada da rede neural artificial. A Figura 55 apresenta o processo de cópia e a Figura 56 o processo de colagem. O mesmo método deve ser utilizado para importar os dados armazenados para a variável *targets*, que representa os dados de saída da rede.

Figura 54 – Escolha do rótulo de variável e abertura de área tabular para a inserção de dados.



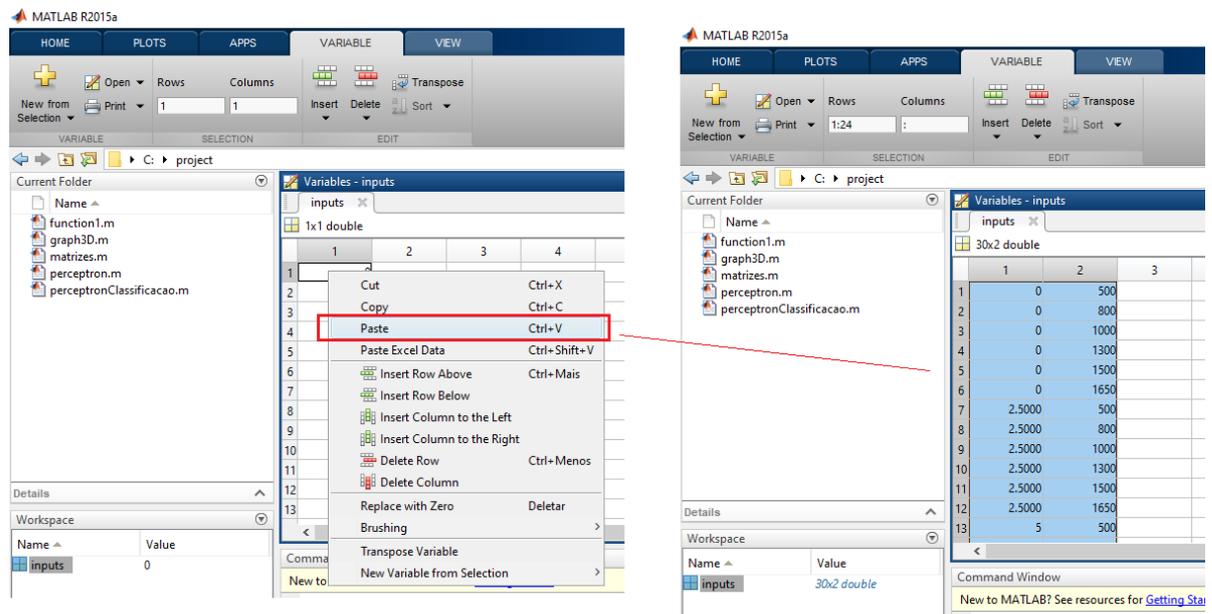
Fonte: Elaborada pelo autor.

Figura 55 – Cópia dos dados a serem carregados para a variável *inputs*.



Fonte: Elaborada pelo autor.

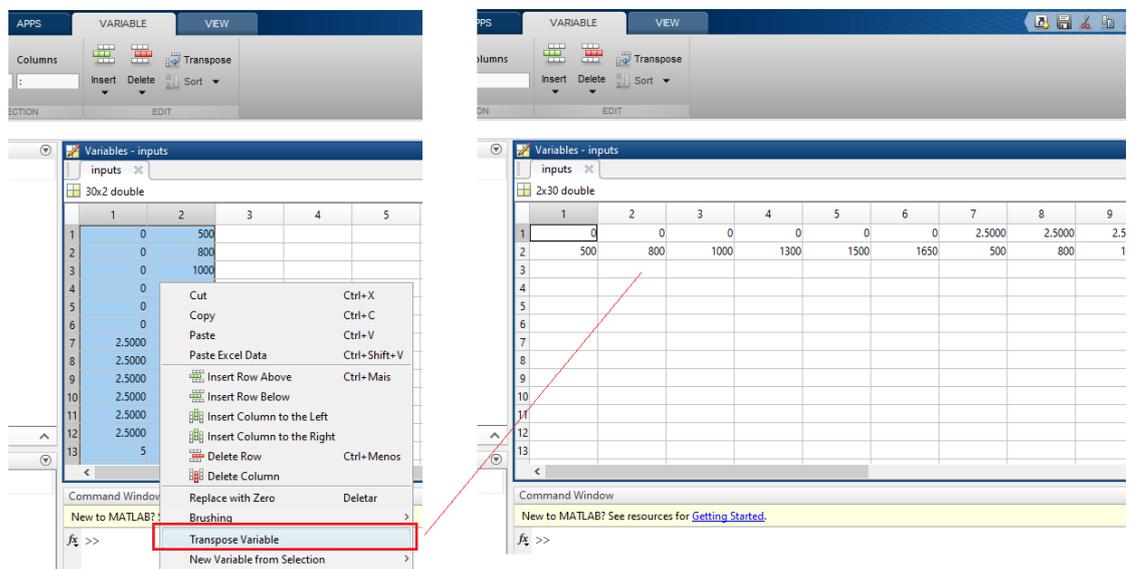
Figura 56 – Colagem dos dados coletados para a variável *inputs*.



Fonte: Elaborada pelo autor.

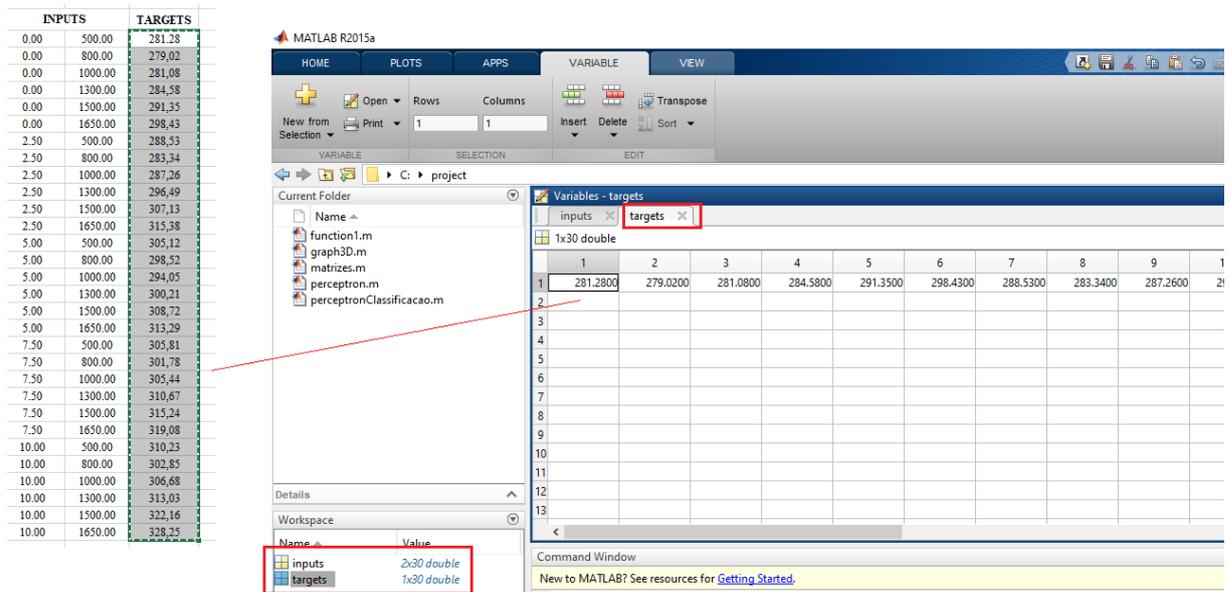
Visto que, "a unidade fundamental de dados, em qualquer programa MATLAB, é a matriz", tem-se que as variáveis *inputs* e *targets* criadas são matrizes (CHAPMAN, 2003, p. 21). Para a criação da rede neural artificial e, considerando-se as regras fundamentais das operações básicas com matrizes, é necessário transpor os dados armazenados nas referidas variáveis. A Figura 57 apresenta o procedimento para gerar a matriz transposta do conteúdo da variável *inputs*. O mesmo passo deve ser utilizado a fim de transpor o conteúdo da variável *targets*, conforme mostrado na Figura 58.

Figura 57 – Transposição do conteúdo da variável *inputs*.



Fonte: Elaborada pelo autor.

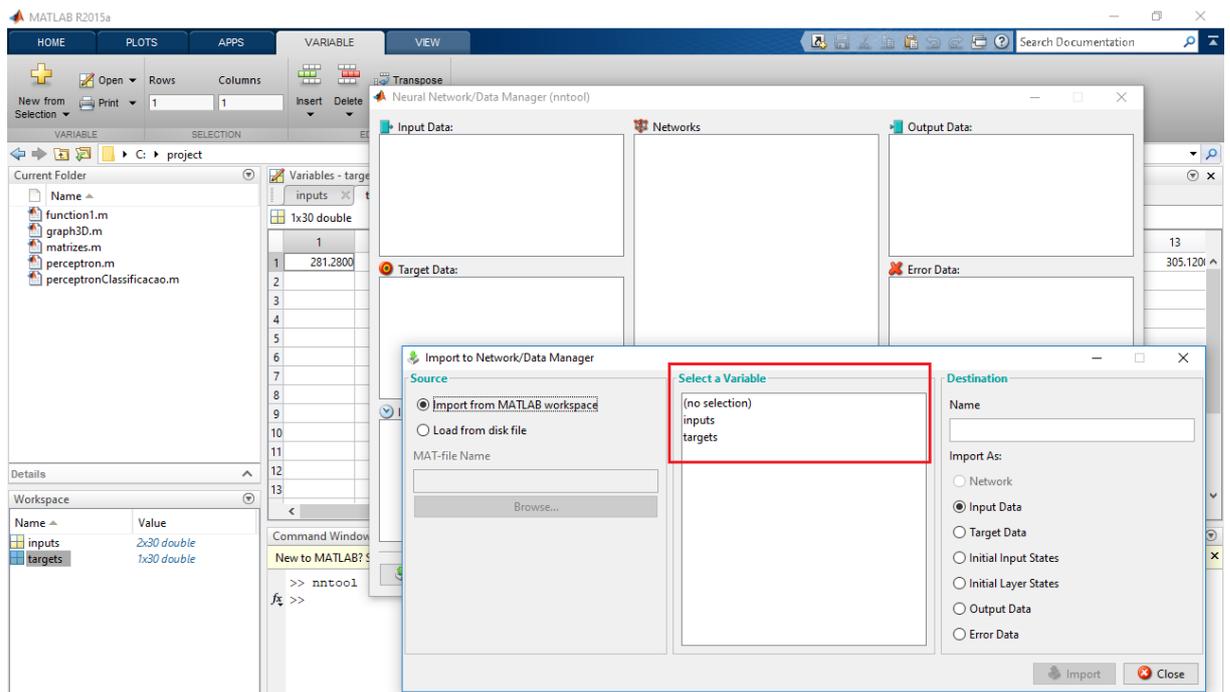
Figura 58 - Transposição do conteúdo da variável *targets*.



Fonte: Elaborada pelo autor.

Com as variáveis de entrada e saída da rede neural devidamente criadas e configuradas no ambiente MATLAB, executa-se a chamada da *toolbox* NNTOOL, conforme mostrado na Figura 50. A criação da rede é realizada através da opção “*Import*”, segundo apresentado na Figura 51. A Figura 59 mostra a tela de importação destacando o painel para seleção contendo as variáveis *inputs* e *targets* anteriormente criadas.

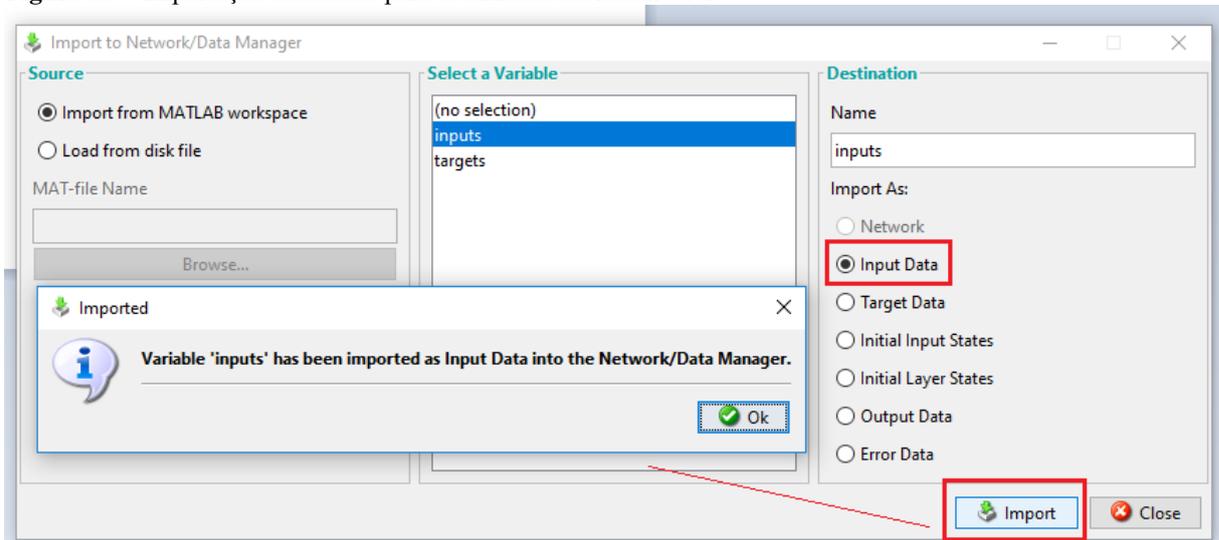
Figura 59 – Painel de seleção de variáveis para a importação de dados da rede neural.



Fonte: Elaborada pelo autor.

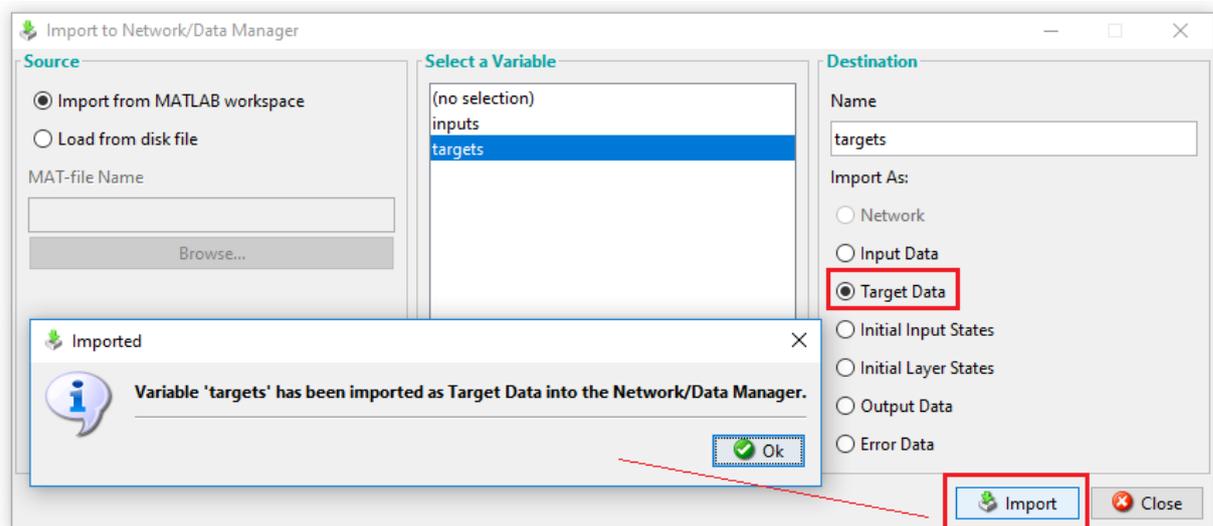
A seguir, realiza-se a importação do conteúdo da variável *inputs* para as entradas da rede neural artificial a ser criada, conforme mostrado na Figura 60. A Figura 61 apresenta a importação da variável *targets* para a saída da rede.

Figura 60 – Importação dos dados para as entradas da rede neural.



Fonte: Elaborada pelo autor.

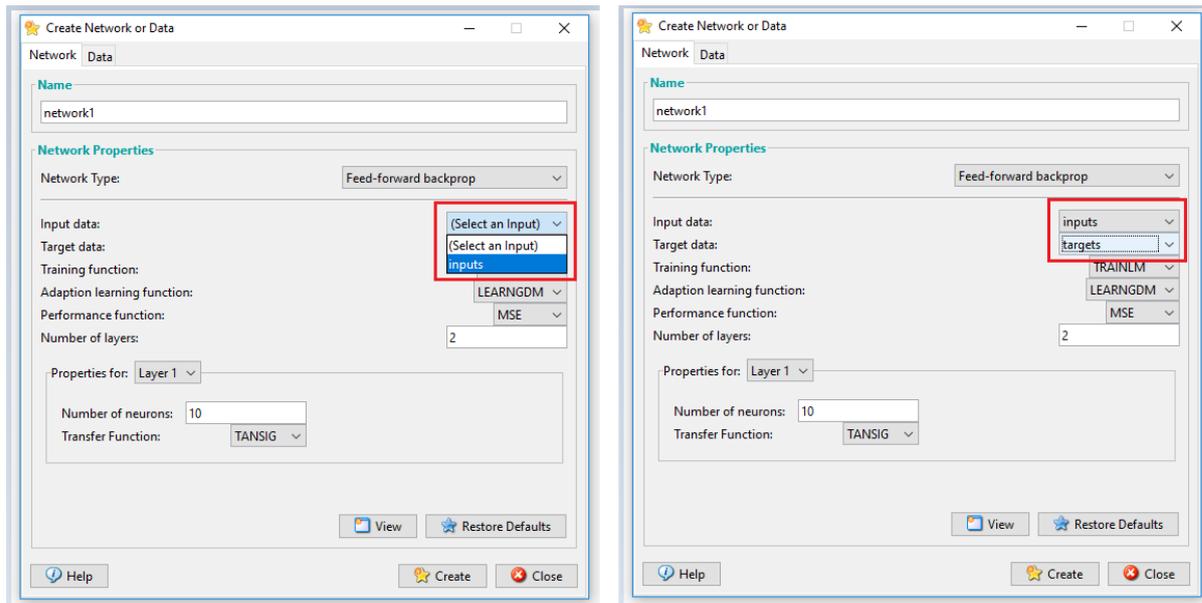
Figura 61 - Importação dos dados para as saídas da rede neural.



Fonte: Elaborada pelo autor.

Após a importação dos dados, a janela “*Import to Network/Data Manager*” pode ser fechada. A próxima etapa consiste em criar a rede neural artificial com a opção “*New*” da *NNTOOL*, conforme mostrado na Figura 52. A Figura 62 apresenta a configuração dos dados de entrada e saída da rede através das variáveis *inputs* e *targets*.

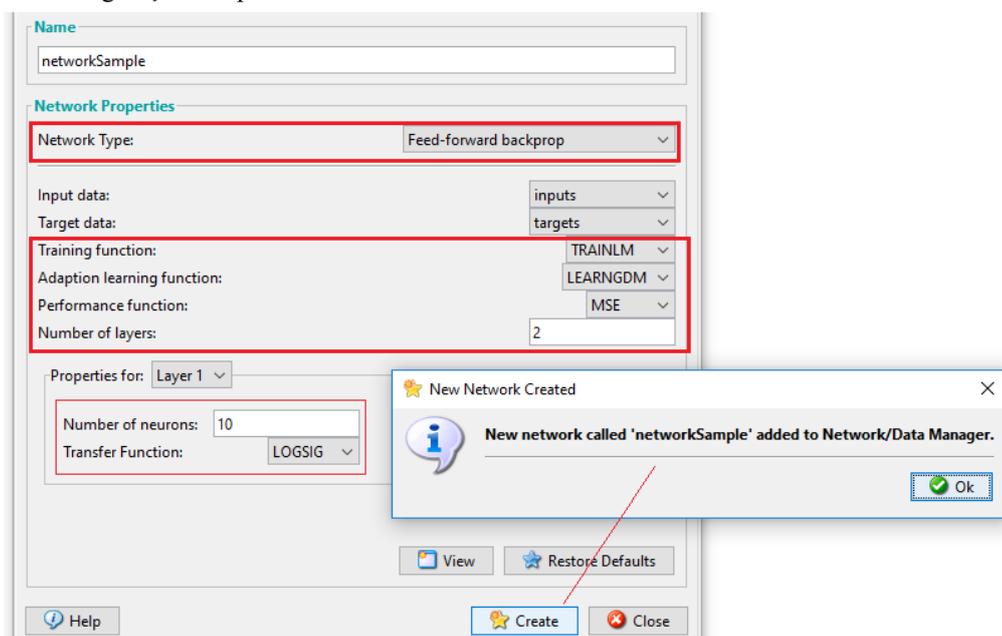
Figura 62 – Configuração dos dados de entrada e saída da rede neural artificial.



Fonte: Elaborada pelo autor.

A configuração dos demais campos da rede a ser criada é mostrada na Figura 63, sendo escolhidos: arquitetura MLP, algoritmo de treinamento *backpropagation* com otimização Levenberg-Marquardt (*trainlm*), função de desempenho medida pela média quadrática dos erros (RMSE, do inglês *Root Mean Square Error*), duas camadas - cada uma com 10 neurônios - e função de transferência das camadas do tipo sigmóide (*logsig*). Por fim, cria-se a rede com o botão “Create”.

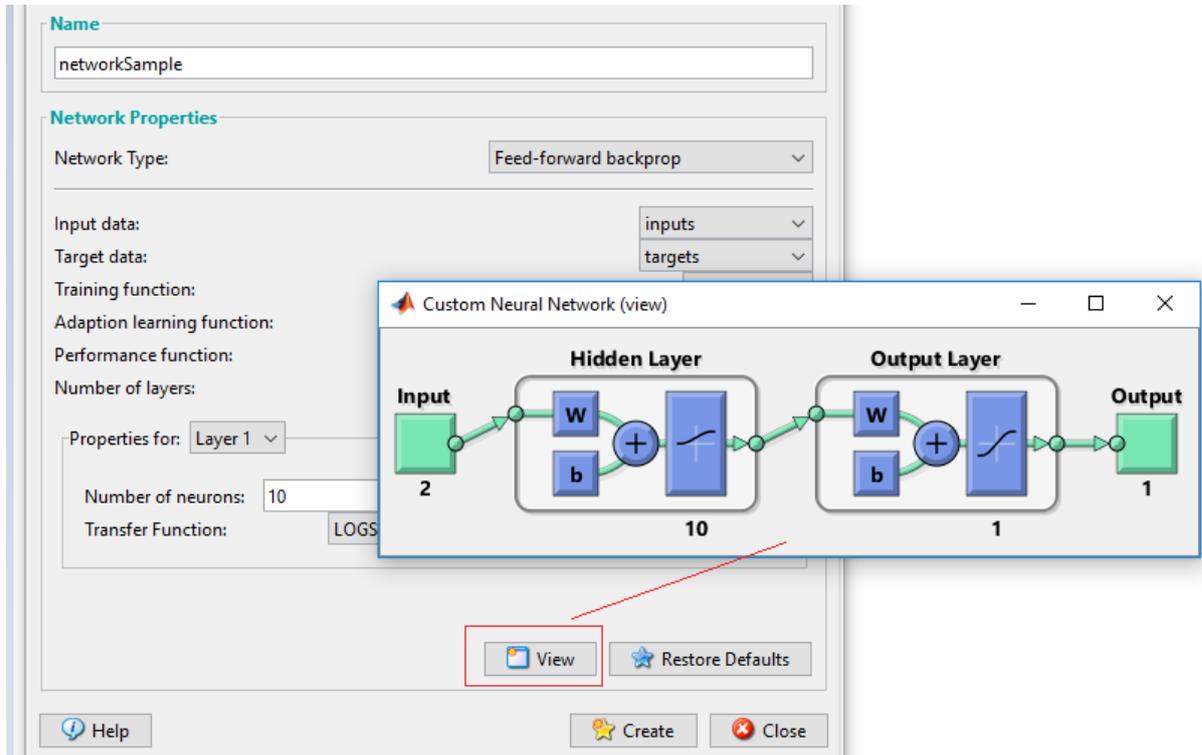
Figura 63 – Configuração dos parâmetros da rede neural artificial.



Fonte: Elaborada pelo autor.

Para visualizar a rede neural artificial criada, o botão “View” pode ser utilizado, conforme mostrado na Figura 64. Em seguida, a janela “Create network or Data” pode ser fechada.

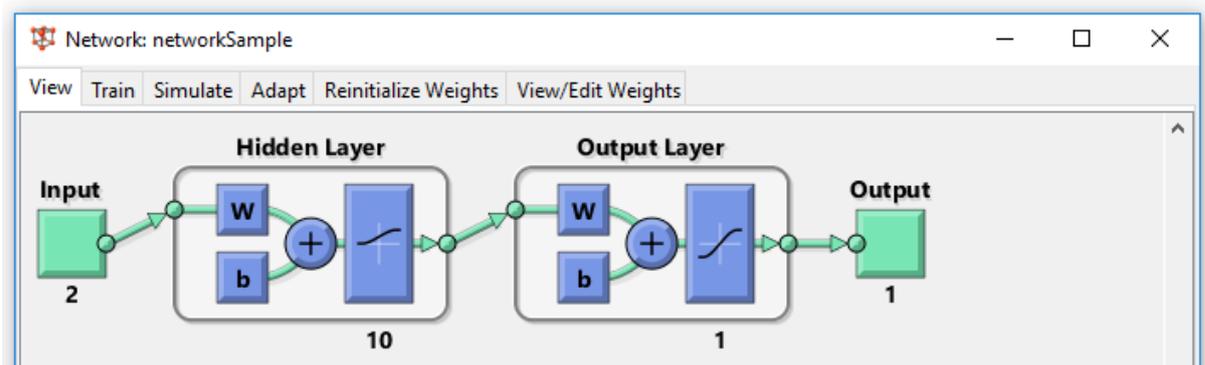
Figura 64 – Visualização da rede neural artificial criada.



Fonte: Elaborada pelo autor.

Após o encerramento da janela “Create network or Data”, retorna-se à janela “Neural Network/Data Manager (nntool)”, a qual contém agora, no painel “Networks”, a rede recém-criada. Ao clicar no nome da mesma, para acessar suas opções de manipulação, o botão “Open” deve ser utilizado, o que resulta na abertura da janela “Network”, apresentada na Figura 65.

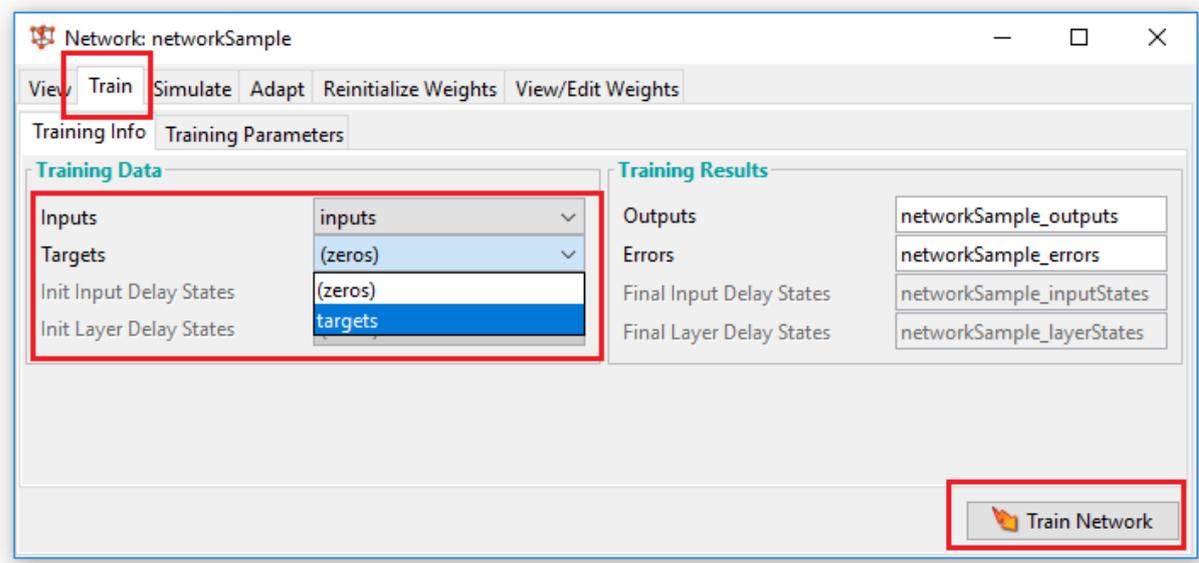
Figura 65 – Janela com opções para a manipulação da rede neural artificial criada.



Fonte: Elaborada pelo autor.

Dispostas em abas, as opções presentes na janela “*Network*” permitem visualizar, treinar, simular ou adaptar a rede neural artificial criada. Também possibilitam a reinicialização dos pesos sinápticos ou a visualização e edição deles. Nesse momento, é necessário treinar a rede neural a fim de analisar o seu aprendizado a partir dos dados de entrada e saída fornecidos. Antes disso, a fase de treinamento deve ser configurada. A Figura 66 apresenta tal procedimento.

Figura 66 – Configuração dos parâmetros de entrada e saída para o treinamento da rede neural.



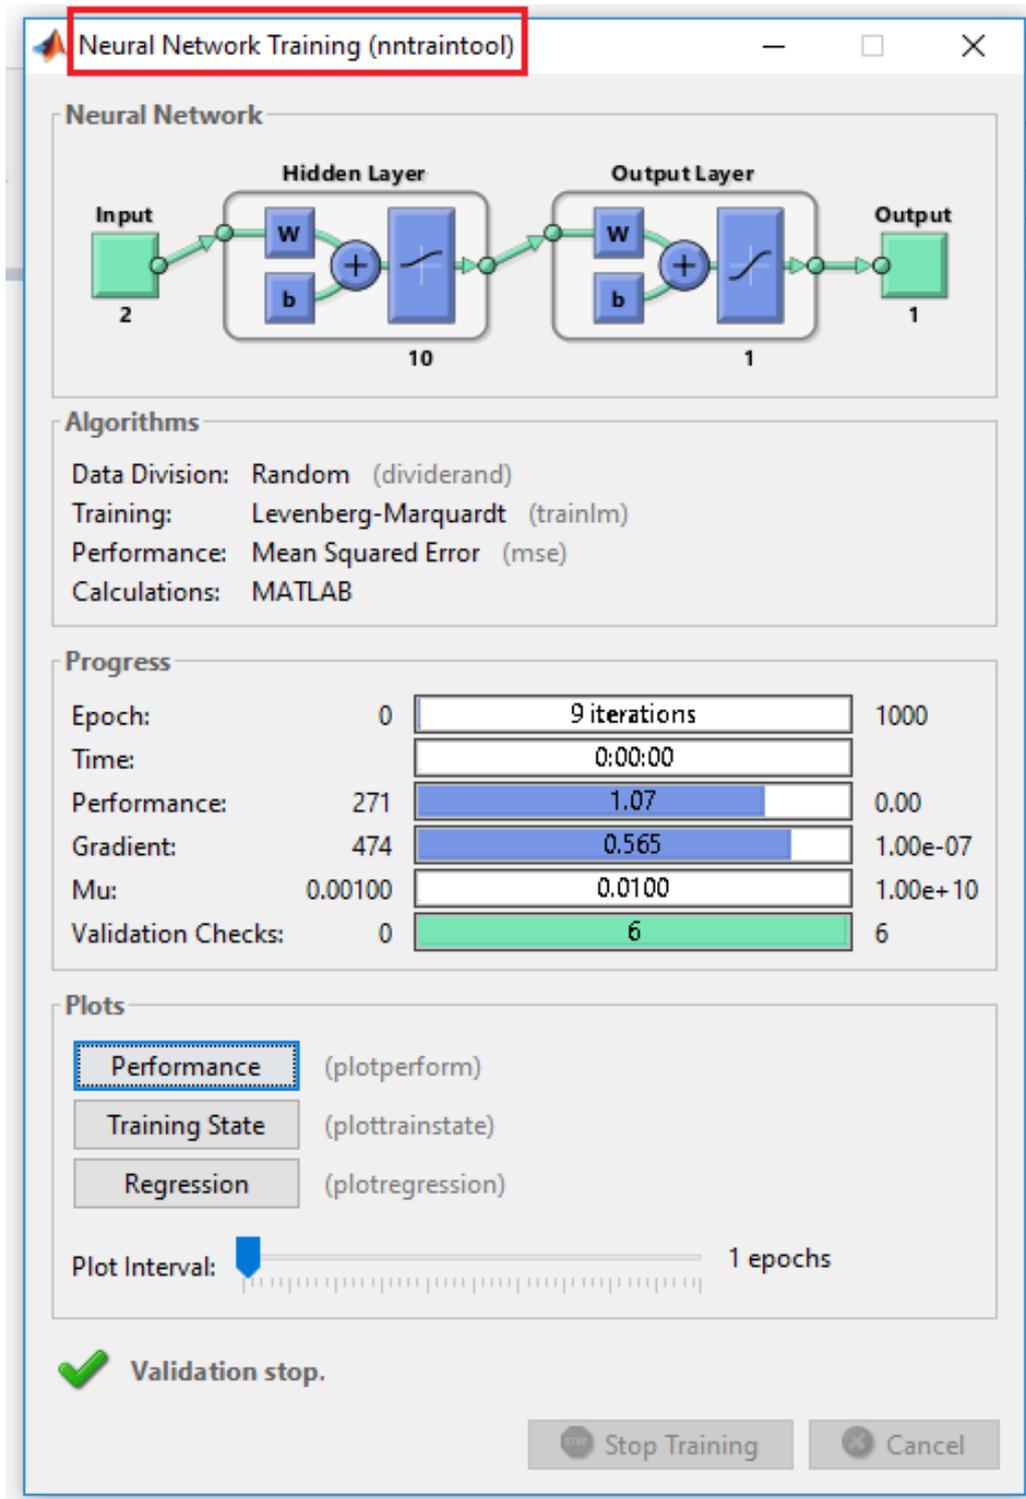
Fonte: Elaborada pelo autor.

Após a configuração dos itens de entrada e saída da rede, o treinamento é realizado clicando-se no botão “*Train Network*”. Como resultado, a janela “*Neural Network Training (nntraintool)*” será aberta, mostrando todos os parâmetros de treinamento da rede, como o algoritmo utilizado, o número de camadas, o tempo decorrido, o número de épocas, etc.

Ademais, as opções presentes na janela “*Neural Network Training (nntraintool)*” ainda possibilitam a visualização gráfica de algumas particularidades da rede neural ao longo do seu treinamento, como, por exemplo, a medição de seu desempenho.

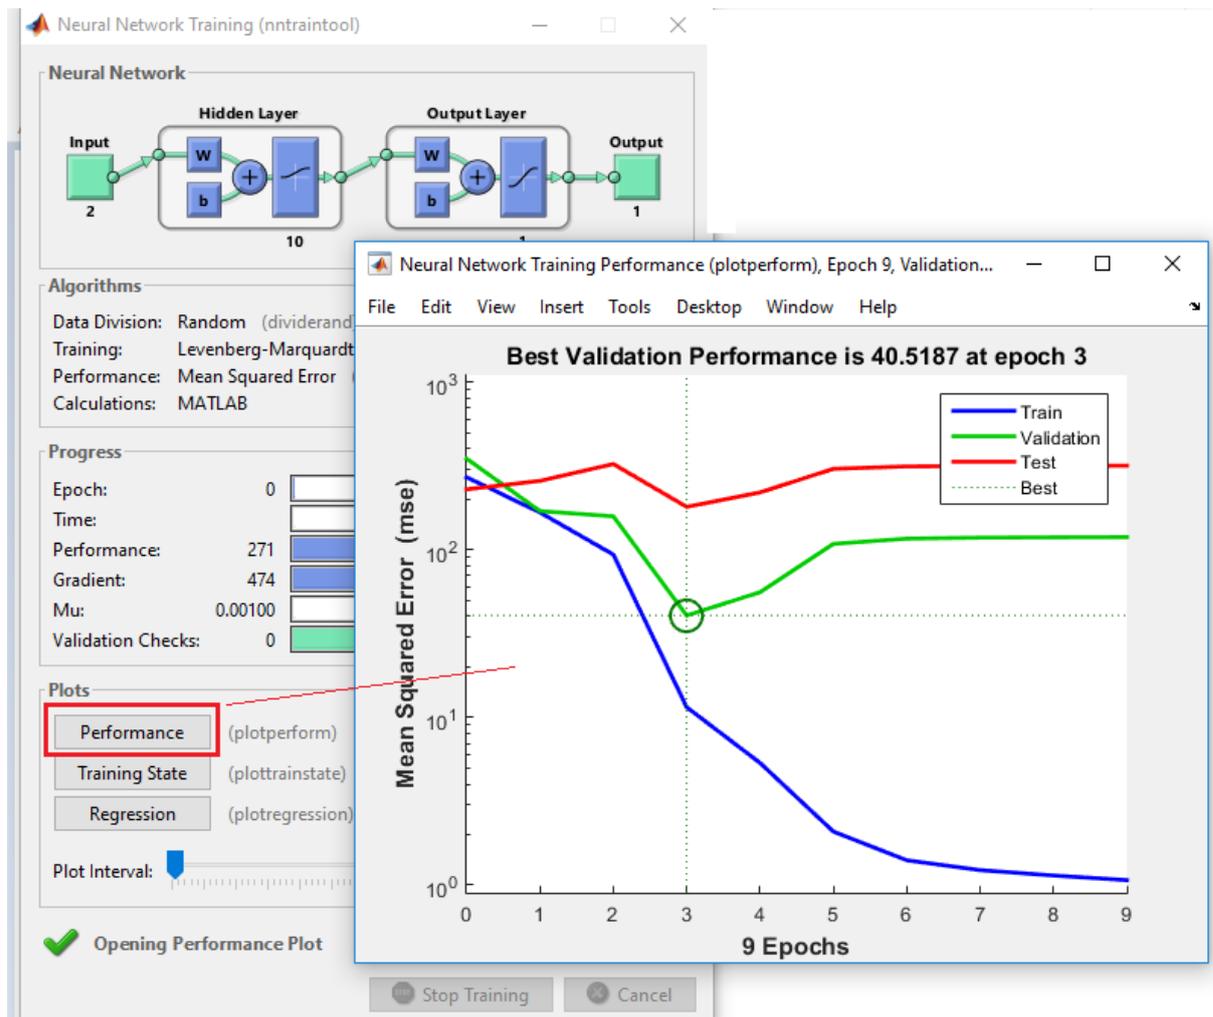
A Figura 67 mostra o resultado do primeiro treinamento da rede neural artificial criada no exemplo apresentado, enquanto que, a Figura 68 apresenta o desempenho obtido no primeiro treinamento efetuado.

Figura 67 – Visualização do 1º treinamento da rede neural artificial criada.



Fonte: Elaborada pelo autor.

Figura 68 – Desempenho da rede neural artificial no 1º treinamento realizado.



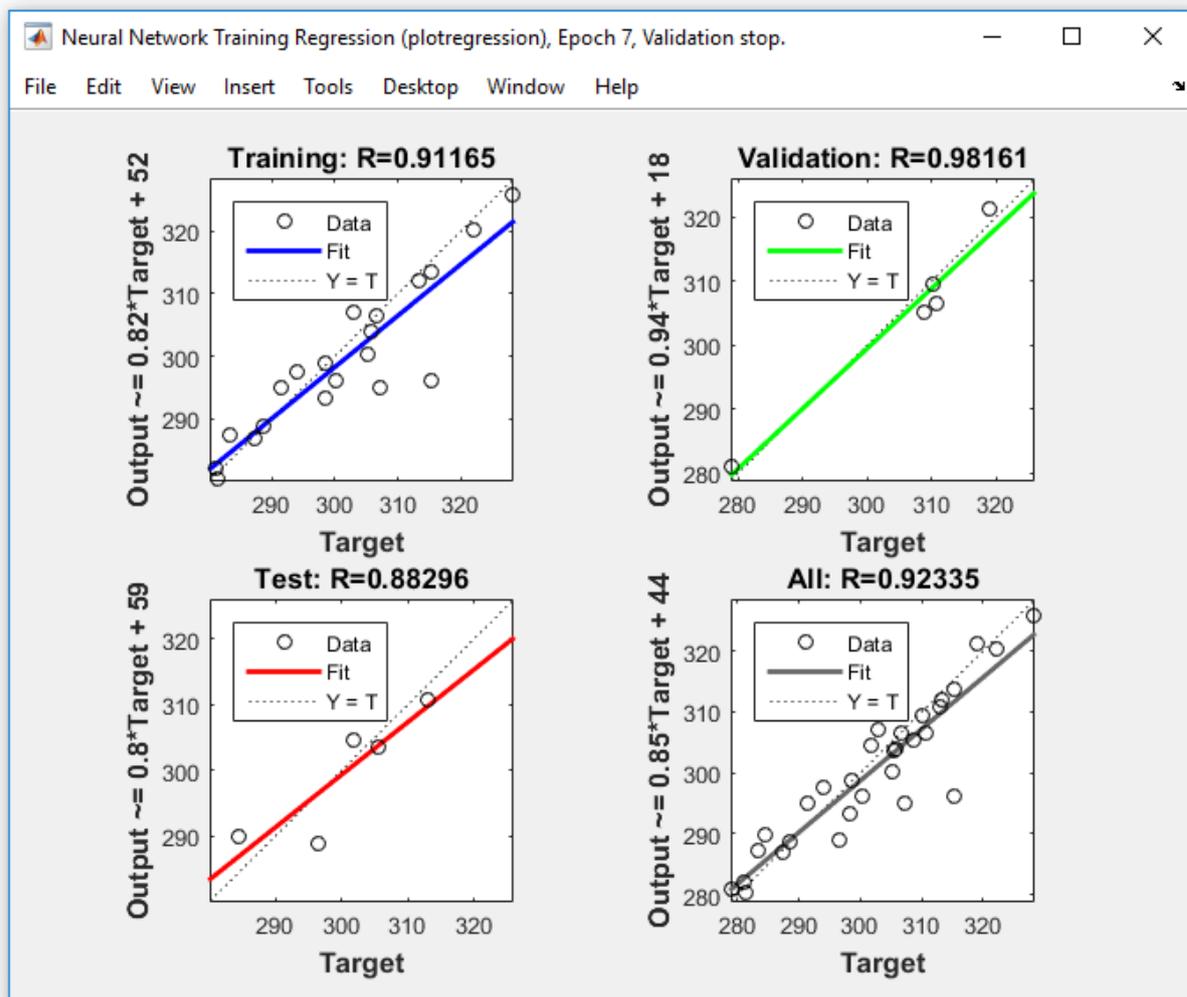
Fonte: Elaborada pelo autor.

A plotagem do gráfico que apresenta o desempenho da rede neural artificial permite comparar o resultado apresentado frente à saída esperada, de modo a avaliar o modelo preditivo construído. Se os resultados não forem satisfatórios, a rede deve ser treinada até atingir um comportamento com erro mínimo possível. Para isso, os parâmetros podem ser ajustados nas opções presentes nas abas da janela “*Neural Network Training (nntool)*”.

Adicionalmente, a Figura 69 apresenta o gráfico de regressão obtido a partir do primeiro treinamento da rede neural artificial construída no exemplo. Tal gráfico é muito interessante para a observação dos ajustes da rede à medida em que é treinada para se aproximar o máximo possível da solução desejada. O gráfico é obtido clicando-se no botão “*Regression*”, que pode ser visto na Figura 68.

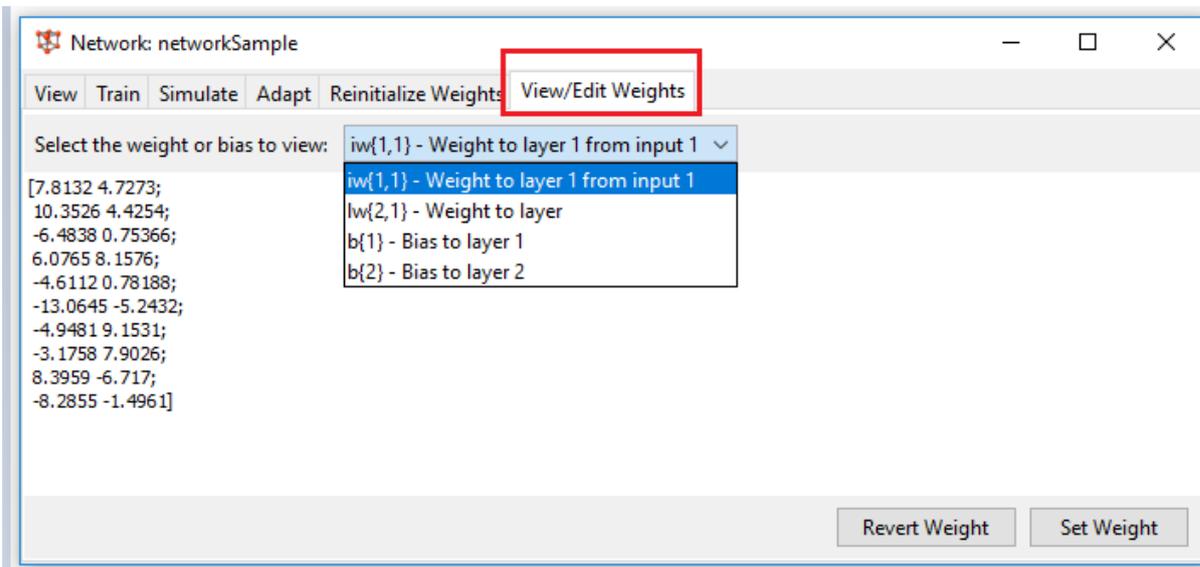
Por fim, a Figura 70 mostra alguns dos pesos sinápticos obtidos na primeira rodada de aprendizagem. Tais pesos podem ser visualizados para cada camada particular da rede, bastando selecionar os itens presentes na lista suspensa mostrada na referida figura.

Figura 69 – Gráfico de regressão resultante do 1º treinamento da rede neural.



Fonte: Elaborada pelo autor.

Figura 70 – Visualização de alguns pesos sinápticos no 1º treinamento da rede neural.



Fonte: Elaborada pelo autor.