



Instituto de Tecnologia
Programa de Pós-graduação em Engenharia Civil

**Previsão de Custo e Prazo de Obras Públicas
Utilizando Redes Neurais Artificiais**

DISSERTAÇÃO DE MESTRADO

Alcineide Dutra Pessoa

2020

Alcineide Dutra Pessoa

Previsão de Custo e Prazo de Obras Públicas Utilizando Redes Neurais Artificiais

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Pará, como parte dos requisitos para obtenção do Título de Mestre.

Orientador: Prof. Dr. Luiz Maurício Furtado Maués

Belém, 04 de fevereiro de 2020.

CESSÃO DE DIREITOS

AUTOR: Alcineide Dutra Pessoa

TÍTULO: Previsão de Custo e Prazo de Obras Públicas Utilizando Redes Neurais Artificiais.

GRAU: Mestre ANO: 2020

É concedida à Universidade Federal do Pará permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

Alcineide Dutra Pessoa

Rua Cláudio Sanders, 727, Bosque Residencial
Viver Ananindeua, apto 302B97.
Centro.
67.030-325 Ananindeua – PA – Brasil.

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

P475p Pessoa, Alcineide Dutra
Previsão de Custo e Prazo de Obras Públicas Utilizando Redes
Neurais Artificiais / Alcineide Dutra Pessoa. — 2020.
120 f. : il. color.

Orientador(a): Prof. Dr. Luiz Maurício Furtado Maués
Dissertação (Mestrado) - Programa de Pós-Graduação em
Engenharia Civil, Instituto de Tecnologia, Universidade Federal do
Pará, Belém, 2020.

1. Custos. 2. Prazos. 3. Redes Neurais Artificiais. I. Título.

CDD 620

PREVISÃO DE CUSTO E PRAZO DE OBRAS PÚBLICAS UTILIZANDO REDES NEURAIS ARTIFICIAIS


AUTORA:

ALCINEIDE DUTRA PESSOA


DISSERTAÇÃO SUBMETIDA À BANCA
EXAMINADORA APROVADA PELO COLEGIADO DO
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA CIVIL DO INSTITUTO DE
TECNOLOGIA DA UNIVERSIDADE FEDERAL DO
PARÁ, COMO REQUISITO PARA OBTENÇÃO DO
GRAU DE MESTRE EM ENGENHARIA CIVIL NA
ÁREA DE CONCENTRAÇÃO EM ESTRUTURAS E
CONSTRUÇÃO CIVIL.

APROVADO EM: 04 / 02 / 2020.


BANCA EXAMINADORA:



Prof. Dr. Luiz Maurício Furtado Maués
Orientador (UFPA)




Profa. Dra. Débora de Góis Santos
Membro Externo (UFS)



Prof. Dr. Marcelo de Souza Picanço
Membro Interno (UFPA)

Visto:



Prof. Dr. Marcelo de Souza Picanço
Coordenador do PPGEC / ITEC / UFPA

Dedico este trabalho ao meu querido esposo Gean Carlos

À minha querida mãe

Aos meus irmãos e sobrinhos

AGRADECIMENTOS

Primeiramente, agradeço a Deus pela minha vida, por ter me guiado até aqui e por me permitir viver cada sonho.

Sou muito grata ao meu esposo Gean Carlos, meu companheiro e amigo, que me apoiou em todos os momentos, soube me compreender quando eu mais precisei, que sempre me ajudou e esteve presente em todas as fases, me dando forças para concluir essa etapa importante da minha vida. Agradeço a minha mãe Francisca Dutra, por sempre ter me incentivado a estudar, que nunca mediu esforços para me dar sempre o melhor e por me mostrar que esse é o melhor caminho a ser trilhado e, mesmo longe, sempre está torcendo por mim.

Ao meu pai João e aos meus irmãos que eu sei que torcem muito pelo meu sucesso. Aos meus sobrinhos que são crianças maravilhosas.

Ao professor Luiz Maurício que me acolheu, orientou pacientemente, incentivou, conversou e mostrou o caminho para realização deste trabalho. Aos meus professores do ensino fundamental que hoje são meus amigos e estão sempre torcendo por mim. Aos professores do ensino médio que ficaram felizes por mim quando entrei no mestrado. A todos os meus professores da graduação por contribuírem na minha formação e pelo incentivo em especial a professora Ana Carolina Reis, Fábio Dieguez, Rodrigo Araújo e Gean Carlos.

Ao Felipe Alvarenga por ter me ajudado com os dados para a realização deste trabalho. Obrigada a todos os meus amigos da graduação, da igreja e do PIB (Laboratório de Processamento da Informação Biológica) que sempre me incentivaram na busca desse título, em especial minha querida amiga Déborah Fabrícia um dos presentes que ganhei e que sempre se fez presente quando foi preciso. Obrigado a todos.

RESUMO

A execução de construções por parte do poder público exige a elaboração e assinatura de contratos cujas características estão definidas e regidas por lei específica. No Brasil, esse processo de escolha do ente contratado e das definições características da obra é denominado de licitação. O processo de licitação contempla, entre outras coisas, informações sobre o orçamento e o prazo previsto para execução da obra. Mesmo sendo acordado em contrato, o orçamento e o tempo previsto para conclusão das construções, esses dois itens nem sempre são cumpridos por parte do contratado. É comum então que empresas contratadas para realização de obras públicas atrasem a entrega da obra concluída e solicitem aditivos de custo. Tendo em vista essa problemática, vários modelos matemáticos e computacionais vêm sendo propostos com a finalidade de prever qual o tempo real que um determinado empreendimento levará para ser concluído e qual o valor que será gasto. Esses modelos, no entanto, se limitam a empreendimentos de origem privadas e uma lacuna com relação a obras públicas torna-se evidente. Nessa pesquisa foi proposto um modelo matemático computacional que tem como objetivo a previsão de custos, aditivos de custo, prazos e aditivos de prazos de obras públicas. Esse modelo é baseado no funcionamento de neurônios do sistema nervoso, é a chamada Rede Neural Artificial. Um modelo de Rede Neural de múltipla camada foi aplicado em dados obtidos em um sistema *on line* do Ministério da educação (MEC). Os resultados obtidos com a aplicação do método foram avaliados a partir de métricas como erro percentual médio e correlação. A avaliação dos resultados mostrou que o modelo de previsão obteve melhores resultados na previsão de custo. Uma contribuição metodológica foi apresentada, pois um modelo computacional foi proposto. O algoritmo e as matrizes de pesos foram disponibilizados para que seja possível a utilização do modelo em outras situações.

Palavras-chave: Custos. Prazos. Rede Neural Artificial.

ABSTRACT

The execution of constructions by the government requires the preparation and signing of contracts whose characteristics are defined and governed by specific law. In Brazil, this process of choosing the contracted entity and the characteristic definitions of the work is called bidding. The bidding process includes, among other things, information about the budget and the estimated time for execution of the work. Even though the budget and the estimated time for completion of the construction are agreed in the contract, these two items are not always met by the contractor. It is then common for companies contracted to carry out public works to delay delivery of the completed work and to request cost additives. In view of this problem, several mathematical and computational models have been proposed in order to predict what is the real time that a particular enterprise will take to complete and how much will be spent. These models, however, are limited to private enterprises and a gap in public works becomes evident. This research proposes a computational mathematical model that aims to forecast costs and terms of public works. This model is based on the functioning of neurons of the nervous system, is called the Artificial Neural Network. A multilayer neural network model was applied to data obtained from an online system of the Ministry of Education MEC. The results obtained with the application were evaluated from metrics such as mean percentage error and correlation. The evaluation of the results showed that the forecasting model obtained better results in the cost forecasting, when compared to the additive and time forecasting. A methodological contribution was presented because a computational model was proposed. The algorithm and the weight matrices were made available so that it is possible to use the model in other situations.

Keywords: Costs. Deadlines Artificial neural network.

Se eu vi mais longe, foi por estar sobre ombros de gigantes.

(Isaac Newton)

Sumário

Capítulo	Página
1 INTRODUÇÃO	17
1.1 Justificativa e problema de pesquisa	18
1.2 Objetivos	19
1.2.1 Objetivo Geral	19
1.2.2 Objetivos Específicos	20
1.3 Pressupostos	20
1.4 Limitações	20
1.5 Estrutura do Trabalho.....	21
2 OBRAS PÚBLICAS	22
2.1 Modalidade de Contratos: Definições e Legislação Vigente	22
2.2 Custo e aditivo de custos de projetos com financiamento público	26
2.2.1 Fatores que influenciam aditivos de custo.....	26
2.2.2 Previsão de custos de obras públicas.....	29
2.3 Prazos e atrasos na execução de obras públicas.....	30
2.3.1 Fatores que influenciam o tempo de execução de obras públicas	31
2.3.2 Previsão do tempo de execução de obras públicas	33
3 REDES NEURAIS ARTIFICIAIS – RNA’s	34
3.1 Histórico e Aplicações de Redes Neurais	34
3.2 Motivação Biológica	38
3.2.1 Neurônio Biológico	38
3.2.2 Neurônio Artificial	40
3.3 Arquitetura e Aprendizado das RNA’s	43
3.3.1 Arquiteturas das RNA’s	43
3.3.2 Tipos de Aprendizados das RNA’s	45
3.4 O <i>Perceptron</i>	46
3.5 O <i>Perceptron</i> Multicamadas (<i>Multilayer Perceptron - MLP</i>)	48
3.5.1 O Algoritmo de Retropropagação – <i>Backpropagation</i>	49
3.5.2 Análise Matemática do Algoritmo <i>Backpropagation</i>	50
4 MODELAGEM E TÉCNICAS ESTATÍSTICAS	57
4.1 Conceito de modelagem.....	57
4.2 Técnicas Estatísticas.....	58
4.2.1 Estatística Descritiva	58

4.2.2	Estatística Inferencial	61
4.2.3	Medidas de acurácia	63
5	DELINEAMENTO E MÉTODO DE PESQUISA	65
5.1	Pesquisa e método científico	65
5.2	Fases do Desenvolvimento da Pesquisa	67
5.2.1	Fase I: Revisão bibliográfica	68
5.2.2	Fase II: Preparação	70
5.2.3	Fase III: Modelagem.....	71
5.2.4	Fase IV: Avaliação e análises estatísticas.....	75
6	TREINAMENTO E VALIDAÇÃO DO MODELO NEURAL.....	77
6.1	Previsão de Custo	77
6.1.1	Treinamento da Rede Neural Artificial (RNA) para previsão de Custos	77
6.1.2	Teste da RNA para previsão de Custos	80
6.1.3	Análise Estatística da Previsão de Custo	81
6.2	Previsão de Aditivo de Custo	83
6.2.1	Treinamento da RNA para Previsão de Aditivo de Custos	83
6.2.2	Teste da RNA para previsão de aditivo de custos	85
6.2.3	Análise Estatística da Previsão de Aditivo de Custo	86
6.2.4	Estimativa do Valor Total da Obra com Base na Previsão de Aditivos de Custos	88
6.3	Previsão do Tempo de Execução de Obras Públicas.....	90
6.3.1	Treinamento da RNA para Previsão Previsão do Tempo de Execução de Obras Públicas	90
6.3.2	Teste da RNA para Previsão do Tempo de Execução de Obras Públicas	92
6.3.3	Análise Estatística da Previsão de Prazo	93
6.4	Previsão de Aditivo de Prazo	95
6.4.1	Treinamento da RNA para previsão de Aditivos de Prazo.....	95
6.4.2	Teste da RNA para previsão de Aditivos de Prazo	97
6.4.3	Análise Estatística da Previsão de Aditivos de Prazo.....	98
6.4.4	Estimativa de Prazo final da Obra com Base na Previsão de Aditivos de Prazos.	99
7	DISCUSSÕES, CONCLUSÕES E SUGESTÕES PARA NOVAS PESQUISAS.....	102
7.1	Discussões e conclusões.....	Erro! Indicador não definido.
7.2	Sugestões para novas pesquisas	104
8	REFERÊNCIAS	105

Lista de Tabelas

Tabela	Página
Tabela 5.1: Palavras-chave da revisão bibliográfica	69
Tabela 5.2: Critérios de exclusão de artigos	69
Tabela 6.1: Resultados obtidos para dados de treinamento	89
Tabela 6.2: Resultados obtidos para dados de teste	89
Tabela 6.3: Resultados obtidos para dados de treinamento (prazo final de execução)	100
Tabela 6.4: Resultados obtidos para dados de teste (prazo final de execução)	100

Lista de Figuras

Figura	Página
Figura 2.1: Fases de Procedimentos da licitação	24
Figura 2.2: Causas de atrasos mais frequentes	32
Figura 3.1: Desenvolvimento Histórico das RNA's.....	35
Figura 3.2: Visão Geral da Estrutura dos Neurônios.....	39
Figura 3.3: Estrutura do Neurônio Artificial	40
Figura 3.4: Funções de ativação parcialmente diferenciáveis: A) Função Degrau, B) Função Degrau Bipolar e C) Função Rampa Simétrica	41
Figura 3.5: Gráficos das Funções Totalmente Diferenciáveis: A) Função logística, B) Função tangente hiperbólica, C) Função Gaussiana e D) Função Linear	42
Figura 3.6: Arquitetura de uma rede alimentada adiante (feedforward) de camada simples ...	43
Figura 3.7: Rede Alimentada Adiante com Múltiplas Camadas	44
Figura 3.8: Arquitetura de uma Rede Recorrente.....	44
Figura 3.9: Rede Perceptron	46
Figura 3.10: Algoritmo de Treinamento do Perceptron	47
Figura 3.11: Perceptron Multicamdas	48
Figura 3.12: Algoritmo Bacpropagation.....	49
Figura 3.13: Gradiente descendente	51
Figura 3.14: Notação Matemática para derivação do algoritmo backpropagation.....	52
Figura 3.15: Variáveis matemáticas do Perceptron	53
Figura 4.1: Representação de box-plot.....	60
Figura 6.1: Resultados do Treinamento da RNA para Previsão de Custo.....	78
Figura 6.2: Resultados do Treinamento da RNA para Previsão de Custo - Algumas Amostras	79
Figura 6.3: Resultados da Fase de Teste da RNA para Previsão de Custo.....	80
Figura 6.4: Correlação entre os valores medidos e a saída da RNA: A) Fase de Treinamento; B) Fase de Teste	81
Figura 6.5: Distribuição dos valores medidos e da saída da RNA para previsão de custo: A) Fase de Treinamento; B) Fase de Teste.....	82
Figura 6.6: Resultados do Treinamento da RNA para Previsão de Aditivo de Custo.....	84
Figura 6.7: Treinamento da RNA para Previsão de Aditivo de Custo – Algumas Amostras ...	84
Figura 6.8: Resultados da Fase de Teste da RNA para Previsão de Aditivo de Custo.....	86
Figura 6.9: Correlação entre os valores medidos e a saída da RNA para previsão de aditivo de custo: A) Fase de Treinamento; B) Fase de Teste	87
Figura 6.10: Distribuição dos valores medidos e da saída da RNA para previsão de aditivo de custo: A) Fase de Treinamento; B) Fase de Teste	88
Figura 6.11: Previsão de custos totais através da previsão de aditivo.....	89
Figura 6.12: Resultados do Treinamento da RNA para Previsão do Tempo de Execução	91
Figura 6.13: Resultados do Treinamento da RNA para Previsão do Tempo de Execução da Obra - Algumas Amostras	91

Figura 6.14: Resultados da Fase de Teste da RNA para Previsão do Tempo de Execução da Obra	92
Figura 6.15: Correlação entre os valores medidos e a saída da RNA para previsão de Prazo: A) Fase de Treinamento; B) Fase de Teste.....	93
Figura 6.16: Distribuição dos valores medidos e da saída da RNA para previsão de prazo: A) Fase de Treinamento; B) Fase de Teste.....	94
Figura 6.17: Resultados da fase de treinamento da previsão de aditivos de prazo.....	95
Figura 6.18: Resultados para algumas amostras da fase de treino	96
Figura 6.19: Resultados da fase de teste para previsão de aditivos de prazos.....	97
Figura 6.20: Relação entre os valores reais e a saída da rede: A) Fase de treino B) Fase de teste.....	98
Figura 6.21: Box plot com valores reais e simulados: A) Fase de treino; B) Fase de teste	99
Figura 6.22: Sistema de estimação de prazo com base no aditivo de prazo.....	100
Figura 6.23:Relação entre Custos e Prazos	101

Lista de Quadros

Quadro	Página
Quadro 2.1: Fatores que influenciam os aditivos de custo	27
Quadro 2.2: Principais causas de excedentes de custos.....	29
Quadro 4.1: Comparação entre parâmetros e estatística.....	61
Quadro 5.1: Resumo do método da pesquisa	68
Quadro 6.1: Topologia da RNA / Previsão de Custos	78
Quadro 6.2: Topologia da RNA / Previsão de Aditivo de Custos.....	83
Quadro 6.3: Topologia da RNA / Previsão de Prazos	90
Quadro 6.4: Topologia da RNA / Previsão de Aditivo de Prazo.....	95

Lista de Abreviaturas e Siglas

Neste item são apresentados alguns dos símbolos utilizados nesta dissertação. Aqueles que não estão aqui apresentados têm seu significado explicado assim que mencionados ao longo do texto desta pesquisa.

Sigla	Significado
ADALINE	Adaptive Linnear Element
BIM	Building Information Model
BOT	Build Operate Transfer
CCI	Índice de Custos de Construção
ENG	Enginnering News-Record
LMS	Least Mean Square
MAPE	Mean Absolute Percentage Erro
MDL	Multilayer Perceptron
MSE	Mean Squared Erro
RC	Região Crítica
RNA	Redes Neurais Artificiais
SEURB	Secretaria Municipal de Urbanismo do Município de Belém
UFPA	Universidade Federal do Pará

1 INTRODUÇÃO

Historicamente vários trabalhos são apresentados à comunidade científica relatando a problemática que envolve custos e prazos de execução de empreendimentos públicos. Esses problemas são mais corriqueiros em países emergentes (ALVARENGA, 2019; SANTOS; STARLING; ANDERY, 2014). Realizar diagnósticos e apontar possíveis soluções de modo que se possa executar um projeto em tempo hábil e ainda minimizar os custos é sobretudo um desafio.

Em países emergentes normalmente o custo final das obras públicas é significativamente mais alto do que o valor contratado na licitação, o mesmo ocorre com os prazos de execução das obras (BUCCIOL; CHILLEMI; PALAZZI, 2013; WANJARI; DOBARIYA, 2016).

São diversos os fatores que influenciam o não cumprimento de prazos e o aumento de custos dos projetos pós licitação. Cheng (2014), por exemplo, analisou 42 fatores que influenciam no aumento dos custos na construção. Por outro lado, Gunduz; Nielson e Ozdemir (2015) apontaram 83 fatores de atraso no tempo de execução de obras públicas.

Observando os trabalhos de Cheng (2014) e Gunduz; Nielsen; Ozdemir (2015), percebeu-se que o controle, ainda em fase de planejamento, de todos os fatores que influenciam tanto no custo quanto no prazo final da obra é praticamente impossível. Esse fato faz com que diversos modelos matemáticos e computacionais tenham sido propostos com a finalidade de prever os custos finais de um projeto e ou o prazo final de execução do mesmo.

Na perspectiva de realizar a previsão de prazo, alguns trabalhos aplicaram as técnicas de regressão e obtiveram modelos matemáticos capazes de, dentro de algumas limitações, efetuar aproximações importantes (AHMADU et al., 2015; BEJO; MUSTAFFHA; WAN ISMAIL, 2014; NG et al., 2010). Por outro lado, empregando técnicas pertencentes à inteligência artificial, como por exemplo a lógica Fuzzy, Gunduz; Nielsen; Ozdemir (2015) e Maués (2017) sugeriram modelos capazes de predizer o prazo final de empreendimentos da construção civil.

Quando se analisou o desafio de se encontrar um modelo matemático ou computacional capaz de prever o custo final de uma obra, verificou-se que os trabalhos também são diversos. Porém, uma observação importante deve ser salientada, pois um grupo relevante de trabalhos realiza previsão não dos custos, mas das taxas inerentes à construção (HYARI; AL-DARAISEH; EL-MASHALEH, 2016; ZHANG et al., 2018).

Os modelos utilizados na perspectiva de previsão de custos ou índice de custos também são motivados pelas técnicas de regressão e de inteligência artificial. O uso de inteligência artificial para previsão de custos (ou taxas de custos) pode ser observado nos trabalhos de Hyari; Al-Daraiseh; El-Mashaleh (2016), Lu; Luo; Zhang (2011) e Zhang et al. (2018).

As Redes Neurais Artificiais (RNA) têm ganhado destaque em problemas de previsão, pois, segundo Silva; Spatti e Flauzino (2016), são modelos capazes de realizar estimativas com alta precisão. Essa afirmação foi confirmada quando, por exemplo, analisou-se as taxas de acerto do trabalho de Hyari; Al-Daraiseh; El-Mashaleh (2016).

Tendo em vista os trabalhos citados, foi possível pressupor que modelos computacionais baseados em inteligência artificial podem ser considerados alternativas relevantes para previsão do tempo de execução de obras públicas e do custo final das mesmas.

1.1 Justificativa e problema de pesquisa

O processo de execução de obras públicas, especialmente em países emergentes como o Brasil, tem sido corriqueiramente acometido por dois sérios problemas. O primeiro problema é o não cumprimento do prazo previsto na licitação. Esse fato além de induzir outros problemas de cunho secundário, traz consigo um segundo problema, ou seja, o aumento nos custos previstos no projeto inicial.

Normalmente, as soluções encontradas para amenizar os dois problemas citados permeiam o setor jurídico através de inúmeras reclamações a respeito das leis que regem os contratos de licitação. Nesse contexto, é comum se observar no Brasil, por exemplo, grandes obras paradas há anos. Essas obras são paradas ou por problemas que envolvem a justiça ou mesmo por falta de dinheiro.

Um levantamento feito por Alvarenga (2019) mostrou que no Brasil em média 69,05% das obras do Governo Federal, na área de educação, concluídas no período de 2006 a 2017 tiveram aditivo de prazo. O quadro nacional apresentado pelo autor é semelhante a países como Arábia Saudita (59% de obras com atraso), Emirados Árabes (50%) e Portugal com (77%) (ASSAF; AL-HEJJI, 2006; FARIDI; EL-SAYEGH, 2006; MONTEIRO, 2010) .

Ainda no seu trabalho, Alvarenga (2019) realizou uma extratificação por região quanto às similaridades no que se referia ao aumento de prazo necessário para conclusão de obras em instituições de ensino superior no Brasil, sendo a região Centro-Oeste a que apresentou maior percentual de atrasos de execução dessas obras 73,09%, seguida pela região Sudeste 72,88%,

Norte 68,85%, Sul 68,60% e Nordeste com 63,76% de atrasos. Vale ressaltar que os dados apresentados por Alvarenga (2019) são referentes apenas às obras concluídas, o quadro pode ser ainda mais grave se inserida na amostra as obras que estão paradas sem previsão de conclusão.

Por outro lado, quando Alvarenga (2019) observou o problema de aditivo de custos, percebeu que o quadro não diferiu muito do problema de atrasos. A média de obras que obtiveram acréscimo em seus orçamentos no Brasil no período 2006 a 2017 foi de 61,89%. Quando extratificado por regiões, o Sudeste foi quem apresentou o maior percentual de obras públicas com acréscimo no custo 67,12%, seguido por Centro-oeste 64,00%, Norte 63,52%, Sul 62,60% e, por fim, o Nordeste com 54,36%.

Os altos percentuais de atrasos e aditivos de custo são preocupantes para o desenvolvimento de um país e merecem atenção especial dos profissionais da área. Propor soluções que reduzam esses percentuais consiste em um desafio importante. Uma alternativa para amenizar esses problemas é obter informações referentes aos prazos e custos reais do empreendimento.

Técnicas estatísticas e de inteligência artificial têm se mostrado promissoras para auxiliar no planejamento dos custos e prazos de obras públicas. No âmbito da inteligência artificial destacam-se os modelos baseados no funcionamento do sistema nervoso central, em especial no comportamento dos neurônios. Esses modelos são conhecidos como Redes Neurais Artificiais.

As Redes Neurais Artificiais têm ganhado destaque na solução de problemas de engenharia, principalmente quando a tarefa é previsão. Por esse motivo a pergunta de pesquisa norteadora desse trabalho: É possível utilizar redes neurais para projetar a predição como alternativa para prever os valores reais de custo e de prazo e assim auxiliar no processo de planejamento das obras públicas?

1.2 Objetivos

1.2.1 Objetivo Geral

Propor um modelo computacional baseado em inteligência artificial, especialmente redes neurais artificiais, que seja capaz de realizar previsão do custo, aditivo de custo, prazo e aditivos de prazo de execução de obras públicas, a fim de auxiliar os gestores no planejamento e orçamento dos empreendimentos contratados por órgãos estatais.

1.2.2 Objetivos Específicos

- Treinar redes do tipo *Perceptron* Multicamadas com o algoritmo *Backpropagation* para prever os custos totais, aditivos de custo, prazo de execução de obras públicas e aditivos de prazos;
- Testar, em dados novos, as redes treinadas, a fim de verificar a capacidade de previsão dos modelos de RNA;
- Verificar a acurácia dos resultados com base no erro percentual médio;
- Avaliar os resultados utilizando técnicas de estatística como correlação e teste de hipótese;
- Comparar eficiência dos modelos propostos quando aplicados à previsão de custos totais, aditivos de custo, prazo de execução de obras públicas e aditivos de prazos;
- Correlacionar custos e prazos.

1.3 Pressupostos

O custo total de obra, o tempo de execução e os aditivos (de custo e de prazo) podem ser previstos por meio de modelos computacionais baseados no funcionamento de neurônios biológicos, as chamadas Redes Neurais Artificiais.

1.4 Limitações

O desenvolvimento desse trabalho apresentou características próprias que geram algumas limitações, dentre as quais, cita-se:

- O banco de dados dispõe de poucas variáveis relacionadas à variável a ser prevista.
- Apenas informações sobre obras de universidades, institutos federais e hospitais universitários estão disponíveis na base de dados. Esse fato restringe a utilização do modelo proposto aos tipos de obras citadas.

1.5 Estrutura do Trabalho

A estrutura deste trabalho ficou construída sob a estruturação de sete capítulos, além das referências bibliográficas.

O capítulo 1 apresenta a introdução, na qual é realizada a justificativa e problematização de pesquisa, os objetivos do trabalho divididos em geral e específicos, assim como descreve as limitações e a estrutura do trabalho.

No segundo capítulo está sendo conceituada a gestão de obras públicas, tipos de contratos, prazos de execução e custo de projetos, aditivos, predição de prazos de execução de obras públicas predição de aditivos e de custos de obras públicas.

Em seguida, no terceiro capítulo, é realizada uma breve revisão conceitual sobre as técnicas estatísticas utilizadas neste trabalho, considerando principalmente os conceitos referentes a estatística descritiva e a estatística inferencial.

No capítulo quatro apresenta-se um breve histórico das redes neurais artificiais bem como suas aplicações, em especial na engenharia civil. São abordados neste capítulo as definições e funcionalidades dos neurônios biológicos e artificial, além das topologias e dos métodos de treinamento das RNA's. Esse capítulo é finalizado com a descrição topológica e matemática dos modelos: *Perceptron*, Regra delta, *Perceptron* Multicamadas e Algoritmo *Backpropagation*.

O capítulo cinco aborda o delineamento e método de pesquisa utilizadas neste trabalho.

No sexto capítulo são apresentados os resultados de treinamento e teste dos modelos neurais utilizados. Uma análise estatística com base em teste de correlação e hipótese é realizada neste capítulo.

No sétimo capítulo são apresentadas as conclusões gerais do trabalho, assim como as sugestões para trabalhos futuros.

2 OBRAS PÚBLICAS

A combinação entre a necessidade de obras de infraestrutura de países emergentes e o aumento das exigências para elaboração dos projetos, tem causado importantes desafios para a gestão de obras públicas (TEREZA et al., 2017). No Brasil, por exemplo, esses problemas estão cada vez mais latentes.

As obras públicas brasileiras são realizadas de acordo com o que consta na lei 8.666, de 21 de junho de 1993, na qual se define obra como sendo toda construção, reforma, fabricação, recuperação ou ampliação, realizada por execução direta ou indireta (BRASIL, 1993).

Obra pública é, por definição, toda construção, reforma, fabricação, recuperação ou ampliação de bem público. Uma obra pública pode ser realizada de duas formas, a saber, forma direta, quando a obra é feita pelo próprio órgão ou entidade da administração através de seus próprios meios, ou de forma indireta, quando a obra é contratada por terceiros (TCU-TRIBUNAL, 2013).

Ainda de acordo com Brasil (1993), toda a contratação de bens e serviços deve ser obrigatoriamente antecedida de licitação, exceto nos casos de dispensa e de inexigibilidade de licitação.

No subtópico a seguir, é realizada uma abordagem sobre as modalidades de contrato entre a administração pública e terceiros.

2.1 Modalidade de Contratos: Definições e Legislação Vigente

A contratação de bens e serviços pela administração pública deve ser sempre antecedida por um contrato de licitação. Segundo Alvarenga (2019), licitação é um processo administrativo formal, que tem como objetivo escolher o melhor contratado para a administração. O contratado normalmente tem como obrigação prestar serviços, construir obras, fornecer ou adquirir bens.

O processo licitatório é o antecedente fundamental para a contratação de obras públicas. Segundo o art. 7º da Lei nº 8.666/93, é indispensável para fins de licitação a existência de um projeto básico e de um orçamento detalhado em planilhas (BRASIL, 1993). Na composição orçamentária deve constar de forma discriminada todos os custos unitários (ALVARENGA, 2019).

Ainda, segundo Alvarenga (2019), para o êxito de uma licitação, é indispensável a participação de profissionais que possuam conhecimento técnico suficiente para administração de cada uma de suas etapas.


Para Ribeiro (2012), licitação é a forma, ou seja, o processo para a contratação de serviços e bens para fornecer à Administração Pública meios que proporcionem a realização de políticas públicas e programas de governo.

Para um bom desempenho de processos licitatórios, estes devem ser conduzidos por alguns princípios básicos que devem ser seguidos tanto pelos participantes da licitação, quanto pela Administração Pública, são eles (GERAL, 2009):

- **Princípio da Legalidade:** Tanto a Administração quanto os licitantes estão sujeitos aos princípios e as regras estabelecidas nas leis pertinentes;
- **Princípio da Igualdade:** Todos os interessados participantes da licitação, deverão receber tratamentos iguais, pois esse é um requisito fundamental que garante a competição do procedimento licitatório;
- **Princípio da Impessoalidade:** Determina que a Administração, em todas as suas decisões, deve observar critérios objetivos, que devem ser anteriormente estabelecidos em edital ou convite;
- **Princípio da Moralidade e da Probidade Administrativa:** Consiste no fato de que a conduta dos participantes da licitação e de todos os agentes públicos seja, além de lícita, compatível com a moral;
- **Princípio da Publicidade:** No processo licitatório, todas as ações praticadas pela Administração Pública em todas as fases, deverão ser divulgados de forma que todos os participantes tenham acesso a todas as informações, exceto ao conteúdo das propostas, enquanto as mesmas não forem abertas;
- **Princípio da Vinculação ao Instrumento Convocatório:** Determina que tanto os participantes da licitação quanto a Administração, observem as exigências e normas estabelecidas no ato convocatório;
- **Princípio do Julgamento Objetivo:** Obriga o administrador público a observar critérios e objetivos estipulados no ato convocatório ao analisar as propostas dos licitantes. Esse princípio evita a possibilidade de o julgador utilizar fatores subjetivos não previstos no edital ou convite, mesmo que em benefício da Administração.

Assim, para uma obra pública ser concluída, ela depende do sucesso de etapas que começam antes mesmo da licitação propriamente dita, conforme demonstrado na Figura 2.1.

Figura 2.1: Fases de Procedimentos da licitação



Fonte: TCU-TRIBUNAL (2013)

Segundo Brasil (1993), uma licitação pode ser classificada de acordo com uma das seguintes categorias:

- **Concorrência:** É a modalidade de licitação que ocorre entre quaisquer interessados em participar da licitação; na fase inicial de habilitação preliminar, os interessados devem comprovar que possuem os requisitos mínimos exigidos de qualificação no edital para a realização do seu objeto (BRASIL, 1993);
- **Tomada de Preços:** É a modalidade onde os interessados a participar da licitação devem estar primeiramente cadastrados, ou atenderem a todas as exigências para o cadastramento até o terceiro dia que antecede a data do recebimento das propostas, observadas a necessária qualificação (BRASIL, 1993) ;
- **Convite:** É a modalidade de licitação que ocorre entre interessados do ramo pertinente ao seu objeto, podendo ser cadastrados ou não, escolhidos e convidados em número mínimo de 3 pela unidade administrativa, a qual afixará,

em local apropriado, cópia do instrumento convocatório e o estenderá aos demais cadastrados na correspondente especialidade que manifestarem seu interesse com antecedência de até 24 horas da apresentação das propostas (BRASIL, 1993);

- Concurso: É a modalidade de licitação que ocorre entre quaisquer interessados para escolha de trabalho técnico, científico ou artístico, mediante a instituição de prêmios ou remuneração aos vencedores, conforme critérios que constam no edital que deverá ser publicado na imprensa oficial com antecedência mínima de 45 dias (BRASIL, 1993);
- Leilão: É a modalidade que ocorre entre quaisquer interessados para a venda de bens móveis inservíveis para a Administração ou de produtos legalmente apreendidos ou penhorados, ou para a alienação de bens imóveis, a quem oferecer o maior lance, igual ou superior ao da avaliação (BRASIL, 1993).

O valor estimado para realização do bem ou serviço define a escolha da modalidade de licitação (TCU-TRIBUNAL, 2013):

- Convite: até R\$ 150.000,00;
- Tomada de Preços; até 1.500.000,00;
- Concorrência: acima de 1.500.000,00.

É importante mencionar que a complexidade do empreendimento deve ser levada em consideração no momento da escolha da modalidade de licitação, pois quanto mais complexo for o empreendimento, maior será as exigências de habilidade e isso influenciará diretamente na escolha da modalidade.

Dentro do processo de licitação encontram-se bem definidos os valores referentes aos custos do empreendimento. Porém, em muitos casos as empresas contratadas solicitam aos contratantes valores que excedem o que foi firmado em contrato. Os motivos para se extrapolar os custos contratuais são diversos. No subtópico a seguir é realizada uma abordagem sobre os custos e sobre as principais causas de solicitação de aditivos de custos.

2.2 Custo e aditivo de custos de projetos com financiamento público

Na fase de licitação de empreendimentos públicos é comum que as empresas que ganham os contratos sejam aquelas que ofereceram em suas propostas a melhor relação custo-benefício. Porém, após iniciada a obra, verifica-se uma constante mudança nos orçamentos apresentados no ato contratual e assim surgem os pedidos de aditivos financeiros.

As mudanças orçamentárias podem trazer ao contratante problemas sérios chegando até mesmo ao interrompimento da obra por falta de recursos. Alvarenga (2019) mostrou que, no Brasil, o percentual de obras públicas que fazem uso de aditivo de custo é sobretudo importante e preocupante.

Vale ressaltar que os pedidos de aumento nos valores iniciais orçados para realização de obras públicas não é “privilegio” apenas do contexto brasileiro. Países desenvolvidos como Portugal também sofrem ou já sofreram com esse tipo de situação (MONTEIRO, 2010).

2.2.1 Fatores que influenciam aditivos de custo

Diagnosticar os fatores que combinados culminam em um aumento nos valores orçamentários contratuais têm sido historicamente objeto de estudo de diversos pesquisadores em todo planeta. Avaliando a construção de arranha-céus na Indonésia, Kaming et al. (1997) apontaram fatores que influenciam nos aditivos de custo da construção. A inclusão de aditivos de custo também foi objeto de estudo de Chang (2002). Em seu trabalho sobre projetos de *design* de engenharia, Chang (2002) classificou os fatores que influenciam no aumento dos custos em três grupos: controle do proprietário, controle do consultor e além do controle.

Um total de 67 variáveis ligadas a pedidos de aditivos de custo foram identificadas por Elhag; Boussabaine; Ballal (2005). O método de pesquisa utilizado nesse trabalho foi análise da literatura e entrevistas. Também fazendo uso de análise da literatura e entrevistas, Doloi (2013) elencou 48 fatores que influenciam no orçamento e culminam na necessidade de aditivos de custos no orçamento de projetos de construção.

Em Gana, Famiyeh et al. (2017), analisando projetos de escolas públicas, verificaram que os principais fatores que contribuem para o aumento do custo do orçamento durante as execuções dos projetos foram: contratos irrealistas, problemas financeiros, prazos impostos pelos clientes, escopo do projeto mal definido, variações iniciadas pelo cliente, subestimação de custos do projeto pelos consultores e supervisão deficiente.

É interessante notar que entre os sete fatores elencado por Famiyeh et al. (2017), como sendo os principais, quatro estão ligados ao planejamento dos empreendimentos, ou seja, nesses casos em especial um bom planejamento poderia diminuir a necessidade de se utilizar aditivos financeiros.

Segundo Wanjari; Dobariya (2016), atrasos no tempo de execução de obras e a necessidade de aditivos de custo são problemas graves especialmente em países em desenvolvimento. Na Índia, por exemplo, em um conjunto de 410 projetos, Wanjari; Dobariya (2016) verificaram que cerca de 57% tiveram seus custos aumentado. Nesse estudo, os autores verificaram que os 15 fatores que mais contribuíram para a ocorrência dessa problemática foram os apresentados, em ordem de importância, no Quadro 2.1.

Quadro 2.1: Fatores que influenciam os aditivos de custo

Código	Fatores identificados através de questionário
C01	Preço da matéria-prima
C02	Litígios na liquidação de contas
C03	Atraso na atividade planejada
C04	Documento de concurso ambíguo ou incompleto
C05	Trabalho adicional
C06	Alterações frequentes no projeto
C07	Falta de coordenação entre as partes da construção
C08	Práticas fraudulentas e retrocessos
C09	Erro durante a construção
C10	Força maior
C11	Expectativa de alta qualidade do proprietário
C12	Encurtamento do período do contrato
C13	Desperdícios no local
C14	Relação entre gerência e local de trabalho
C15	Fraco controle financeiro no local

Fonte : WANJARI; DOBARIYA (2016)

Entre os 15 fatores listados no Quadro 2.1 os três principais fatores que colaboram para os excedentes de custo, segundo Wanjari; Dobariya (2016), são: aumento de preço da matéria-prima, atraso nas atividades de planejamento e as falhas de coordenação

Oyegoke; Al Kiyumi (2017) colocam a necessidade de aditivos de custo como consequência dos atrasos nas obras, essa colocação pode ter cunho verdadeiro, porém são necessários estudos que comprovem a relação causa-efeito entre aditivos de prazo e aditivos de custos. No trabalho de Oyegoke; Al Kiyumi (2017), megaprojetos foram avaliados e os autores identificaram que lances muito baixos no processo de contratação, a condição financeira do contratante, atrasos oriundos do cliente e mau planejamento foram as causas que mais contribuíram para que aditivos de custos fossem necessários.

Recentemente, Mahamid (2018) e Kavuma; Ock; Jang (2019) também desenvolveram trabalhos cuja finalidade foi identificar e analisar os fatores que contribuem para que haja necessidade de aditivos de custos na construção. Essas publicações evidenciam que tal problemática “apesar de antiga ainda é muito atual” e merece atenção.

Mahamid (2018) realizou uma revisão de literatura sobre aditivos de custo na Cisjordânia e a combinou com entrevistas à especialistas da área, obtendo assim uma lista de 43 fatores que afetam a estimativa de custo na construção de obras públicas. Os estudos de Mahamid (2018) evidenciaram que os principais fatores que implicam no aumento dos custos são combinações de responsabilidades de contratantes e construtores.

Além dos fatores que normalmente permeiam as análises existentes na literatura como, por exemplo, problemas com o projeto ou incertezas do cliente, um fator de contribuição para o aumento nos custos chama atenção no trabalho de Kavuma; Ock; Jang (2019). Esse fator está relacionado ao uso da ferramenta computacional BIM (*Building Information Model*). Os autores relatam nesse trabalho que os clientes e as empresas contratadas devem sempre estar vigilantes nas práticas de aplicação do BIM em seus projetos.

Normalmente os trabalhos que tratam de custos e aditivos de custo usam como método de pesquisa a revisão de literatura e aplicação de questionários. Outra característica é que tratam de conjuntos de obras restritas a uma determinada localidade ou país. Por esse motivo é que, em geral, os fatores de influência são bastante diversos.

Mesmo sendo diversos, alguns fatores de influência nos aditivos de custo estão presentes em vários trabalhos e, dessa maneira, compõe uma certa intercessão. Aljohani (2017) realizou uma revisão bibliográfica sobre a problemática de aumento de custos em diferentes países e identificou 173 causas citadas nos trabalhos. As principais causas de excedente de custos foram encontradas por Aljohani (2017), estão listadas no Quadro 2.2.

Quadro 2.2: Principais causas de excedentes de custos

Fator	Causas de extrapolação de custos mais frequentes
A	Frequentes mudanças de projeto durante a fase de construção
B	Financiamento (fluxo de caixa) das empreiteiras
C	Atrasos no pagamento dos serviços concluídos
D	Falta de experiência dos contratados
E	Estimativa de custo inadequada
F	Documentos de contratação (contrato ou edital) inadequado
G	Gerenciamento de material ineficiente

Fonte: ALJOHANI (2017)

Os fatores apresentados no Quadro 2.2 evidenciam os problemas de gestão que culminam na necessidade de adicionar mais valores para conclusão dos projetos. Alvarenga (2019) chama atenção para dois fatores, a saber, mudança no projeto e atrasos no pagamento, pois esses contribuem tanto para o aumento no orçamento quanto para o atraso no tempo de execução da obra.

2.2.2 Previsão de custos de obras públicas

É interessante notar que enquanto Kavuma; Ock; Jang (2019), elencam o BIM como um dos fatores que atrasam o andamento da obra e consequentemente contribui para que aditivos de custo sejam solicitados, Alvarenga (2019) cita o BIM como uma alternativa para amenizar tais problemas. Essa aparente contradição não é em si um problema quando se avalia os dois trabalhos. Porém, a mesma evidencia a necessidade de utilização de ferramentas que auxiliem o profissional responsável pelo planejamento nas tomadas de decisões.

Segundo Hyari; Al-Daraiseh; El-Mashaleh (2016), dois fatores são de grande importância para a realização de estimativa de custos de projetos público, são eles: custos de construção e serviços de engenharia. Um modelo baseado em aprendizagem de máquina, mais especificamente Redes Neurais foi proposto por Hyari; Al-Daraiseh; El-Mashaleh (2016) a fim de prever os custos de serviços de engenharia para obras públicas.

A rede neural, proposta por Hyari; Al-Daraiseh; El-Mashaleh (2016), foi treinada em um conjunto de dados obtido do Departamento de Licitações do Governo da Jordânia e testada em amostras de dados que não foram apresentados a rede no momento do treinamento. Os resultados desse trabalho demonstraram que o modelo é capaz de prever o custo dos serviços de engenharia com um desempenho, segundo os autores, aceitável para os modelos de estimativa de custos.

Outros artigos na área da engenharia civil com objetivo de previsão também são encontrados na literatura. Shahandashti; Ashuri (2016), por exemplo, utilizaram modelos de aproximação multivariados para prever custos de construção de rodovias. Por outro lado, Lu; Luo; Zhang (2011) utilizaram algoritmos genéticos para também realizar previsão de custos de construção de rodovias.

Para Zhang et al. (2018), os custos dos empreendimentos estão ligados a alguns índices e a previsão desses índices pode auxiliar no planejamento e evitar os aditivos de custo. Nesse contexto, estudos como Zhang et al. (2018), Shahandashti; Ashuri (2013), Hwang et al. (2012) e Moon; Shin (2018) concentraram seus trabalhos na previsão de índices relacionados aos custos de construção civil.

Utilizando aproximação multivariada Shahandashti; Ashuri (2013) apresentaram modelo capaz de realizar previsão do índice de custos de construção (CCI). Esse índice é um indicador de custos norte americano publicado mensalmente pela *Engineering News-Record* (ENR).

Na previsão de custos especificamente, o trabalho de Ugur (2017) merece destaque. Nesse trabalho é utilizado modelos neurais para prever custos de empreendimentos. Ugur (2017) avaliou seus resultados, tanto de treino quanto de teste, através da métrica R^2 que no caso do treino foi de 0,97 e no teste foi de 0,89. O autor concluiu que os resultados foram satisfatórios.

2.3 Prazos e atrasos na execução de obras públicas

De acordo com Kaliba; Muya; Mumba (2009), a riqueza de um país é avaliada através do setor da construção civil, ou seja, quando esta apresenta uma boa performance quanto ao fornecimento de infraestrutura, tem-se uma avaliação positiva em termos de riqueza.

O cumprimento do prazo é um item para que se tenha uma boa performance nos empreendimentos da construção civil. Porém, o atraso em empreendimentos da construção civil é considerado um dos principais problemas nesse setor (ALVARENGA, 2019).

Bagaya; Song (2016), definem o atraso em cronogramas de empreendimentos de construção civil como sendo uma situação em que um determinado projeto de construção não é acabado dentro do período em que foi planejado. Mas, para Sweis et al. (2008), o atraso de obras é uma ação ou um evento que alonga o tempo que é necessário para realizar as tarefas sob um contrato. Já para Kaliba; Muya; Mumba (2009), o atraso refere-se a uma determinada situação em que um projeto de construção não termina dentro do prazo que foi planejado.

De acordo com Alvarenga (2019), o setor público, embora possua uma grande representatividade no ramo da construção civil, não é conhecido pela sua qualidade ou pelo cumprimento dos prazos estabelecidos em contratos, e sim pelo excesso de custo de suas obras, pelos constantes atrasos e pelo não cumprimento dos requisitos dos usuários. Essas características negativas acontecem principalmente em períodos de eleições, pois nesses períodos os investimentos em obras públicas aceleram e em épocas pós eleições desaceleram, ou até mesmo cessam.

2.3.1 Fatores que influenciam o tempo de execução de obras públicas


A análise das causas de atrasos nos empreendimentos de construção civil tem sido bastante estudada e investigada. Esse tipo de problema pode trazer sérias consequências, tanto em empreendimentos públicos quanto em empreendimentos privados. Essas consequências afetam as duas partes interessadas no projeto de construção, ou seja, afetam os usuários que precisam fazer uso do imóvel e os empreiteiros, pois com os atrasos podem não obter os lucros inicialmente previstos.

Bagaya; Song (2016), em seu artigo, identificam as causas mais frequentes e graves de atrasos que afetam as obras públicas de Burkina Faso, usando um questionário, os autores classificam os cinco fatores mais importantes de atraso, como: capacidade financeira do contratante, dificuldades financeiras do proprietário, disponibilidade de equipamento do contratante, pagamentos lentos por serviços concluídos e fraco desempenho do subcontratado pelo contratado, sendo que o estudo mostrou que a capacidade financeira do contratante, não era apenas um fator de atraso encontrado somente em Burkina Faso, mas sim em vários outros países asiáticos e africanos.

Doloi et al. (2012) identificaram os principais fatores que afetam o atraso na indústria de construção indiana e depois estabeleceram a relação entre os atributos críticos para o desenvolvimento de modelos de previsão para avaliar os impactos desses fatores no atraso.

Filippi; Melhado (2015) analisaram um conjunto de artigos científicos e elencaram 15 causas de atrasos na execução de empreendimentos que mais aparecem nesses trabalhos. A Figura 2.2 resume, em termos percentuais, essas descobertas

Figura 2.2: Causas de atrasos mais frequentes



Fonte: Adaptado de (FILIPPI; MELHADO, 2015).

Yang; Yang; Kao (2010), em seu estudo identificaram as causas de atraso em várias etapas dos projetos BOT (Build-Operate-Transfer), onde essas causas são identificadas através de questionários aplicados aos participantes do BOT. Os resultados do seu estudo revelam que as causas de atrasos mais significativas, são: planejamento inadequado do contrato, problema da dívida e incerteza sobre questões políticas e itens finalizados pelo governo.

Tendo em vista que o não cumprimento do prazo de execução de obras públicas é um problema importante e que necessita de mecanismos que possam amenizar essa problemática é que constam na literatura trabalhos cujo objetivo é apresentar modelos que sejam capazes de prever o tempo real de execução de empreendimentos. No subtópico 2.3.2 é apresentada uma abordagem sobre os modelos de previsão do tempo de execução de obras públicas que permeiam a literatura atual.

2.3.2 Previsão do tempo de execução de obras públicas

Os atrasos de obras seja ela pública ou privada, trazem diversas consequências para os envolvidos no empreendimento, logo uma ferramenta que realizasse a previsão desse atraso seria de grande importância para o setor da construção civil. Essa ferramenta permitiria ajudar gestores a solucionar os problemas dos possíveis atrasos antes mesmo desse acontecer.

Maués (2017), em seu trabalho, realizou a previsão de prazos de execução de obras residenciais no estado do Pará, por meio de um modelo matemático baseado em lógica fuzzy. Em seu estudo utilizou um banco de dados da Secretária Municipal de Urbanismo de Belém (SEURB) e das incorporadoras da cidade alvo para a construção do seu modelo; este apresentou uma assertividade de 75% e um desempenho maior de predição, quando comparado aos modelos já consagrados na literatura.

Petruseva; Zujo; Zileska-Pancovska (2013), em seu estudo, utilizaram um modelo de rede neural artificial para fazer a previsão do tempo de duração de projetos de construções na Federação da Bósnia e Herzegovina. Os resultados obtidos com esse modelo se mostraram bastante satisfatório, com uma significativa precisão do tempo de duração de projetos de construção.

As redes neurais artificiais juntamente com o modelo de regressão linear foram utilizados para a previsão dos custos iniciais e do tempo de duração de um projeto de rodovias no trabalho de Attal (2010). Nesse artigo, os resultados obtidos com o modelo neural apresentaram maior precisão e confiabilidade do que os resultantes da análise de regressão linear.

3 REDES NEURAIS ARTIFICIAIS – RNA’s

Um arcabouço teórico sobre Redes Neurais Artificiais é apresentado nesse capítulo. Inicialmente um breve histórico é apresentado e algumas aplicações, em especial na engenharia civil, são listadas. As relações entre os neurônios biológicos e artificial são apresentadas. Os conceitos de topologias e os tipos de aprendizado são abordados. Um destaque para as características topológicas e matemáticas do *perceptron* e do *perceptron* multicamadas é realizado. Para finalização do capítulo, o algoritmo de retropropagação é descrito.

3.1 Histórico e Aplicações de Redes Neurais

As investigações sobre Inteligência Artificial datam antes mesmo da criação dos computadores. As primeiras relações entre o funcionamento neuronal e modelos matemáticos, por exemplo, foram apresentadas à comunidade científica por McCulloch e Pitts em 1943 (MCCULLOCH; PITTS, 1990).

O primeiro “neurocomputador” foi proposto por Rosenblatt (1958) e ficou conhecido como *Perceptron*. Nesse trabalho, o autor desenvolveu teorias sobre um sistema nervoso hipotético, a fim de responder matematicamente questões sobre percepção de informações, a forma que tais informações são lembradas e como influenciam o reconhecimento e o comportamento.

O *perceptron* ganhou destaque na época, porém sua capacidade se restringia ao reconhecimento de padrões simples. Com a finalidade de melhoramento do *perceptron* foi que Widrow e Hoff (1960) desenvolveram o *ADaptive LINnear Element* (ADALINE). Os mesmos criadores da rede ADALINE propuseram posteriormente o algoritmo de aprendizagem atualmente conhecido como LMS (*Least Mean Square*). Esse algoritmo é também conhecido como “Regra Delta” e é bastante utilizado em diversas estruturas de redes neurais (SILVA; SPATTI; FLAUZINO, 2016).

Apesar do avanço neurocomputacional obtido com a apresentação do *perceptron* e da rede ADALINE, muitas questões foram levantadas, enfatizando principalmente a incapacidade dos modelos em identificar padrões que não fossem linearmente separáveis. Esse problema de não linearidade ficou conhecido com o problema do “ou exclusivo” (Xor) (SILVA; SPATTI; FLAUZINO, 2016). Toda essa problemática foi discutida no livro “*Perceptron – in*

introduction to computational geometry” lançado em 1969 e cuja última edição data de 2017 (MINSKY; PAPERT, 2017).


Tendo em vista o avanço computacional e a elaboração de mecanismos de otimização robustos, no ano de 1980 Rumelhat, Hilton e Williams lançam o livro intitulado *Parallel Distributed Processing*, no qual é apresentado um algoritmo capaz de ajustar os pesos de uma RNA com mais de uma camada. Ao conseguir elaborar tal algoritmo, os autores deram por fim o problema de aprendizado dos padrões não linearmente separáveis. Esse algoritmo ficou conhecido como *backpropagation* (SILVA; SPATTI; FLAUZINO, 2016).

Após solucionado o problema do XOR diversas estruturas de RNA's foram desenvolvidas com base na idéia de múltiplas camadas. Porém, vale destacar o marco mais recente na história das RNA's foi o desenvolvimento das redes com “aprendizado profundo”, ou seja, as *Deep Neural Network*.

Dois artigos marcam o início das redes com aprendizado profundo, a saber, os trabalhos de Hinton; Salakhutdinov (2006) e Hinton; Osindero; Teh (2006). O objetivo principal desses trabalhos foi desenvolver mecanismos de treinamento para RNA's aprenderem padrões de grandes quantidades de dados.

A Figura 4.1 ilustra, de maneira resumida, o processo histórico do desenvolvimento das Redes Neurais Artificiais.

Figura 3.1: Desenvolvimento Histórico das RNA's



Fonte: Adaptado de (LUZ, 2018)

É grande a importância das redes neurais para o desenvolvimento de tecnologias na engenharia. Silva; Spatti; Flauzino (2010) citam algumas aplicações das RNA' em problemas de engenharia. Entre as aplicações constam:

- Aproximação de Funções;
- Controle de Processos;
- Reconhecimento e classificação de padrões;
- Clusterização;
- Sistemas de Previsão;
- Otimização de Sistemas.

A utilização de modelos neurais é cada vez mais constante nas diversas áreas da ciência. Abiodun et al. (2018) listam diversas aplicações dos modelos neurais. Entre essas aplicações estão as seguintes:

- Sistema Financeiro: avaliação de propriedades, previsão de indicadores econômicos, previsão de mercado de ações, previsões de preços e detecção de fraude;
- Medicina: auxílio no diagnóstico médico, estimativa de custo do tratamento, estimativa do tempo de permanência do paciente e reconhecimento de padrões em sinais biomédicos;
- Indústria: previsão de temperatura e força, controle de qualidade, tomada de decisão gerencial, otimização de inventários, modelagem e análise de processos, previsão de custos de produção, previsão de pressão de máquina e previsão de confiabilidade de equipamentos;
- Educação: Previsão do desempenho do aluno, triagem de aplicativos de faculdades e ensino de redes neurais;
- Vendas e *Marketing*: previsão de uso de serviços, previsão de vendas, previsão de margens de varejo, *marketing* direcionado e reconhecimento de padrões;
- Mineração de dados: análise de séries temporais, classificação, detecção de alterações e desvios, descoberta de conhecimento e validação de dados;

- Gestão de RH: planejamento de equipe, retenção de funcionários, seleção e contratação de funcionários, previsão de margens de varejo e reconhecimento de padrões;
- Jogos: desenvolvimento de jogos, apostas esportivas, palhetas para corridas de cães e modelagem;
- Gestão: sistemas de gestão de risco, previsão e controle;
- Militarismo: simulação de operação em terra, água e ar, previsão de localização de inimigos, previsão de metas de sucesso e eficácia de armamentos;
- Produção: estimativas de produção agrícola, estimativas de produção industrial, previsão de disponibilidade e custo de mão de obra, previsão do tempo de vida de equipamentos;
- Ciências climáticas: previsão quantitativa do tempo, previsão da temperatura do brilho do sol, vento e precipitação, reconhecimento de padrões, previsão da formação de nuvens e previsão de mudanças climáticas.

Na engenharia civil destacam-se os trabalhos relacionados a problemas de previsão. Al-Gburi; Jonasson; Nilsson (2016) utilizaram RNA para predição de restrição em seções de concreto. Nesse artigo, os autores disponibilizaram materiais de cálculo em excel para que o modelo pudesse ser utilizado em outras situações.

Mallela; Upadhyay (2016) utilizaram redes neurais para previsão de carga de flambagem de painéis. Os autores verificam que o modelo apresentado é capaz de prever a carga de flambagem com precisão (erro médio de 2,71%).

Ainda com o objetivo de previsão utilizando RNA outros trabalhos podem ser citados. Belalia et al. (2017) utilizaram RNA para previsão de propriedades do concreto. Vahid et al. (2018) realizaram previsão da durabilidade de agregados de calcário. Dogan; Arslan; Ceylan (2015) incorporaram ao trabalho de previsão com redes neurais uma técnica conhecida como extração de características e aplicaram na estimação da força compressiva do concreto. Vakharia; Gujar (2019) e Khashman; Akpinar (2017) utilizando RNA realizaram predição da resistência à compressão do concreto.

A previsão de custos de projetos também já foi objetivo de aplicações de modelos neurais. Zhu; Feng (2010) e Ugur (2017) realizaram aplicação da rede neural em estimativa de

custos. Além de bons resultados em termos de acurácia, Zhu; Feng (2010) verificaram que a utilização de modelos híbridos melhoram a convergência e o aprendizado da rede.

Como mencionado anteriormente, os recentes avanços em desenvolvimento de redes Neurais perpassam pelas aplicações de redes com aprendizado profundo. Nesse contexto, Sri et al. (2018) utilizaram esse novo tipo de RNA para identificar danos estruturais através de experimentos em estruturas de armação de aço. Os autores realizaram comparações com os métodos tradicionais de RNA e verificaram a superioridade do aprendizado profundo em termos de precisão e eficiência.

3.2 Motivação Biológica

Diversos modelos computacionais dentro da grande área de inteligência computacional, como por exemplo, os algoritmos genéticos e otimização por enxame de partículas (ou formigas), são inspirados em características biológicas de seres humanos ou animais (LU; CHEN; ZHENG, 2012). Dentre esses modelos estão as Redes Neurais Artificiais que, segundo Silva; Spatti; Flauzino (2010), são modelos computacionais cuja inspiração está no funcionamento do sistema nervoso, em especial dos neurônios biológicos.

Tendo em vista que a inspiração das RNA's ancora no funcionamento dos neurônios, faz-se necessário então compreender como tal estrutura funciona e qual sua relação com o modelo matemático proposto.


3.2.1 Neurônio Biológico

Os neurônios são células capazes de perceber modificações no meio ambiente, são células que mantêm comunicação entre si através de processos químicos e ou elétricos e ainda comandam às respostas corporais. Essas características fazem dos neurônios as células mais importantes para o desenvolvimento das tarefas atribuídas ao encéfalo (BEAR; CONNORS; PARADISO, 2002).

De acordo com Silva; Spatti e Flauzino (2010), a principal característica do neurônio biológico que serve como base para elaboração dos modelos computacionais é a condução de impulsos. Os impulsos são estímulos elétricos resultantes de reações físico-químicas.

A condução de impulsos realizada pelos neurônios biológicos depende essencialmente de três partes integrantes: dendritos, corpo celular (ou soma) e axônio. A Figura 3.2 ilustra as principais partes de uma célula neuronal.

Figura 3.2: Visão Geral da Estrutura dos Neurônios



Fonte: Openstax (2015)

Os dendritos possuem semelhança aos ramos de uma árvore e funcionam como uma antena para o neurônio. A principal função dos dendritos é a transmissão de informação entre neurônios ou recepção de informação do meio externo (BEAR; CONNORS; PARADISO, 2002).


O corpo celular ou soma é uma estrutura que possui uma geometria aparentemente esférica com aproximadamente $20\ \mu\text{m}$ de diâmetro e se localiza na parte central da célula. É no corpo celular que as informações oriundas dos dendritos são processadas. Dependendo das informações recebidas, o corpo celular pode produzir um impulso elétrico que percorrerá o axônio (BEAR; CONNORS; PARADISO, 2002; SILVA; SPATTI; FLAUZINO, 2016).

O axônio consiste em uma estrutura especializada na condução de informação entre dois pontos. Essa estrutura é exclusiva dos neurônios e caracteriza-se por um prolongamento que é o responsável pela condução de impulsos elétricos. O comprimento de um axônio pode variar entre menos de um milímetro até mais de um metro (BEAR; CONNORS; PARADISO, 2002).

3.2.2 Neurônio Artificial

Uma Rede Neural Artificial tem como “organismo” fundamental o Neurônio Artificial. As principais funções desse “organismo” é o recebimento, processamento e repasse de informação. Também são três os elementos básicos do neurônio artificial: sinapse, somador e a função de ativação (HAYKIN, 2001). A Figura 3.3 ilustra o funcionamento de um neurônio computacional.

Figura 3.3: Estrutura do Neurônio Artificial



Fonte: Haykin (2001)

As operações matemáticas que caracterizam o funcionamento do neurônio iniciam-se com a multiplicação de cada entrada x_j (conectada ao neurônio k na sinapse j) sendo multiplicada pelo peso sináptico w_{kj} . Após as multiplicações um somador é acionado transformando o conjunto de multiplicações em uma combinação linear Σ . O resultado da combinação linear u_k , somado a um bias b_k , é aplicado a uma função de ativação $\varphi(.)$ (SILVA; SPATTI; FLAUZINO, 2016).

Matematicamente, o funcionamento do neurônio artificial ocorre segundo as Equações 1 e 2.

$$u_k = \sum_{i=1}^m w_{ki} x_i \quad (1)$$

e


$$y_k = \varphi(u_k + b_k). \quad (2)$$

em que $x_1, x_2, \dots, x_m$ são os sinais de entrada $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k e y_k é a saída do neurônio. A Equação 2 define um hiperplano no qual w_k é vetor normal e b_k (bias), em módulo, determina a distância entre tal hiperplano e a origem (HAYKIN, 2001).

A saída do neurônio é definida através da função de ativação $\varphi(\cdot)$. Haykin (2001) define três tipos de funções: Função Linear, Linear por parte e Sigmoide. Já Silva; Spatti; Flauzino (2016) dividem o conjunto de funções de ativação e as classifica em dois grupos: Funções parcialmente diferenciáveis e as totalmente diferenciáveis.

As funções parcialmente diferenciáveis são assim chamadas pois não possuem derivadas de primeira ordem em todos os pontos de seu domínio. A Figura 3.4 mostra os gráficos das referidas funções.

Figura 3.4: Funções de ativação parcialmente diferenciáveis: A) Função Degrau, B) Função Degrau Bipolar e C) Função Rampa Simétrica




Fonte: Adaptado de SILVA; SPATTI; FLAUZINO (2016)

Analisando os gráficos, é possível observar que a função degrau possui um ponto de descontinuidade em zero, logo não é diferenciável neste ponto. Observa-se ainda que a função degrau bipolar possui descontinuidade também em zero e consequentemente a derivada nesse ponto inexistente.

A função rampa simétrica é um caso de função que, apesar de contínua em “a” (ou “-a”), não possui derivada nesse ponto e, por isso, é chamada de parcialmente diferenciável. O ponto $(a, \varphi(a))$ é comumente chamado de “bico” e funções que possuem “bico” são contínuas porém parcialmente diferenciáveis.

Por outro lado, as funções ditas totalmente diferenciáveis possuem a primeira derivada conhecida em todos os pontos do seu domínio. As funções de ativação pertencentes a esta classe são a função logística, a tangente hiperbólica, a gaussiana e a função linear. A Figura 3.5 mostra os gráficos das funções totalmente diferenciáveis.

Figura 3.5: Gráficos das Funções Totalmente Diferenciáveis: A) Função logística, B) Função tangente hiperbólica, C) Função Gaussiana e D) Função Linear



Fonte: Adaptado de SILVA; SPATTI; FLAUZINO (2016)

É importante notar que todas as funções, tanto do grupo das parcialmente diferenciáveis quanto das totalmente diferenciáveis, com exceção da função linear, têm imagens limitadas. Essa característica é importante pois limita a saída da RNA em um intervalo pré-estabelecido.

Esse fato também faz com que seja necessária uma normalização das entradas, pois assim o neurônio caracteriza-se como um sistema de entrada e saídas limitadas (VAHID et al., 2018).

3.3 Arquitetura e Aprendizado das RNA's

Os algoritmos de aprendizagem de uma rede neural estão ligados principalmente à maneira como os neurônios estão dispostos e como estão ligados entre si (Arquitetura da RNA) (HAYKIN, 2001). Por esse motivo, é importante compreender quais as principais arquiteturas e quais os mecanismos de aprendizagem utilizados nos modelos neuronais.


3.3.1 Arquiteturas das RNA's

Haykin (2001) define arquitetura de uma RNA como sendo a maneira pela qual os neurônios estão estruturados, ou dispostos entre si. Nesse sentido, pode-se classificar três diferentes arquiteturas, as alimentadas adiante com camada única, as alimentadas adiante com múltiplas camadas e as redes recorrentes (HAYKIN, 2001).

As redes alimentadas adiante (*feedforward*) de camada simples, são compostas por uma camada de entrada e uma única camada de neurônios. Nessa arquitetura, a camada de neurônios é a própria camada de saída (HAYKIN, 2001).

Na arquitetura *feedforward* de camada simples, o fluxo de informação segue sempre na direção entrada-saída. A Figura 3.6 é um exemplo desse tipo de arquitetura.

Figura 3.6: Arquitetura de uma rede alimentada adiante (*feedforward*) de camada simples




Fonte: SILVA; SPATTI; FLAUZINO (2016)

A segunda arquitetura mencionada por Haykin (2001) são as redes alimentadas adiante com camada múltiplas (Figura 3.7). Redes com essa arquitetura possuem as chamadas camadas ocultas que são compostas por nós computacionais.

A principal vantagem das redes com múltiplas camadas é que essas são capazes de resolver problemas complexos, como por exemplo, classificar padrões não linearmente separáveis.


Figura 3.7: Rede Alimentada Adiante com Múltiplas Camadas



Fonte: SILVA; SPATTI; FLAUZINO (2016)

A terceira classe de arquitetura das RNA são as redes recorrentes ou realimentadas. Silva; Spatti; Flauzino (2016) definem esse tipo de arquitetura como sendo redes nas quais as saídas dos neurônios são sinais de realimentação, ou seja, são entradas para outros neurônios. A Figura 3.8 ilustra o funcionamento de uma rede recorrente.

Figura 3.8: Arquitetura de uma Rede Recorrente



Fonte: SILVA; SPATTI; FLAUZINO (2016)

É importante ressaltar que não existem mecanismos matemáticos ou lógicos que determinem a arquitetura da rede neural. Normalmente a escolha da melhor arquitetura é feita observando-se os resultados após vários testes computacionais (BATISTA, 2012).

3.3.2 Tipos de Aprendizados das RNA's

O processo de treinamento de uma RNA tem por objetivo fazer com que a rede aprenda os padrões a ela apresentados. O aprendizado consiste no ajuste dos pesos sinápticos dos neurônios até a rede executar a tarefa desejável. Quando os pesos estão ajustados, diz-se que a rede neural “aprendeu”. Quatro formas de aprendizado merecem destaque, o aprendizado supervisionado, o não supervisionado, o usando lote de padrões e o usando lote de padrão-por-padrão (BATISTA, 2012).

Uma RNA pode realizar um aprendizado supervisionado se para as entradas apresentadas no treinamento da rede existirem saídas desejadas. O algoritmo de aprendizagem supervisionada ajusta os pesos até a saída da rede estar tão próxima quanto possível das saídas desejadas, ou seja, o objetivo nesse tipo de aprendizado é minimizar o erro entre as saídas da rede e os valores desejados (ROCHA, 2018; BATISTA, 2012).

Quando não se dispõe das saídas desejadas é necessária a realização de um aprendizado não supervisionado. O aprendizado não supervisionado é também conhecido como auto-supervisionado (BATISTA, 2012). Nesse tipo de aprendizado a rede aprende com base nas características estatísticas inerentes ao conjunto de entradas, verificando características de similaridade para a realização de agrupamentos (ROCHA, 2018).

O processo de aprendizado usando lote de padrões efetua os ajustes dos pesos sinápticos somente com a apresentação de todo o conjunto de treinamento. Nesse tipo de aprendizado, cada passo depende dos desvios medidos em toda a amostra de treinamento e, por isso, é necessário que todo o conjunto de treinamento esteja disponível (SILVA; SPATTI; FLAUZINO, 2016).

Em contraponto ao aprendizado lote por padrão, o padrão-por-padrão não utiliza todo o conjunto de amostra concomitantemente. A atualização dos pesos é realizada de acordo com a apresentação das amostras individualmente. Após as amostras serem utilizadas na aprendizagem, as mesmas podem ser descartadas (SILVA; SPATTI; FLAUZINO, 2016).


Assim como na escolha da arquitetura da rede, o processo de aprendizagem é escolhido de acordo com a tarefa a ser utilizada, os dados disponíveis e a arquitetura escolhida.

3.4 O Perceptron

No breve histórico exposto no início deste capítulo foi informado que a idéia de redes neurais como modelos matemáticos foi introduzido por McCulloch e Pitts em 1943. Nessa linha histórica, Rosenblatt em 1958 propôs o primeiro modelo neuronal para uma aprendizagem supervisionada, a saber, o **Perceptron**.

O *perceptron* é a forma mais simples de uma rede neural, pois é constituído por apenas uma camada e apenas um neurônio. Essa rede tem como função a classificação de padrões ditos linearmente separáveis, ou seja, padrões que se encontram em lados opostos por um hiperplano (SILVA; SPATTI; FLAUZINO, 2016; HAYKIN, 2001). A Figura 3.9 ilustra uma rede do tipo *Perceptron* com n entradas e uma saída.

Figura 3.9: Rede *Perceptron*



Fonte: SILVA; SPATTI; FLAUZINO (2016)

Como já mencionado anteriormente o funcionamento matemático de um neurônio (o *perceptron* se resume a um neurônio) é dado pelas expressões (Equação 3):

$$u_k = \sum_{i=1}^m w_{ki}x_i \text{ e } y_k = \varphi(u_k + b_k) \quad (3)$$

Tendo em vista que o tipo de aprendizado utilizado para ajuste dos pesos é supervisionado, e o objetivo é minimizar o erro entre a saída da rede e os valores reais, em 1949, Hebb propôs uma “regra” matemática para atualização dos pesos até o objetivo da rede

ser alcançado (HARRIS; NIRANJAN; HARE, 2019). Segundo Silva; Spatti; Flauzino (2016), a regra vetorizada de atualização dos pesos é a dada pela Equação 4.

$$w^{atual} = w^{anterior} + \eta (d^{(k)} - y) \cdot x^{(k)}, \quad (4)$$

em que $\mathbf{w} = [w_1, w_2, \dots, w_n]^T$ é o vetor de pesos;

$\mathbf{x}^k$ é um vetor com a k -ésima amostra de treinamento;

d^k é o valor desejado para a k -ésima amostra de treinamento;

y é o valor da saída produzida pelo *Perceptron*;

η é conhecida como taxa de aprendizagem.

A taxa de aprendizagem η introduzida no algoritmo proposto por Hebb é uma constante que determina a “velocidade de convergência” com a qual o *Perceptron* converge. Uma elaboração matemática mais robusta sobre η será realizada posteriormente quando o *Perceptron* Multicamadas for apresentado. O algoritmo apresentado na Figura 3.10 resume os passos a serem seguidos para o treinamento de um *perceptron*.

Figura 3.10: Algoritmo de Treinamento do Perceptron

Início {Algoritmo *Perceptron* – Fase de Treinamento}

```

<1> Obter o conjunto de amostras de treinamento  $\{\mathbf{x}^{(k)}\}$ ;
<2> Associar a saída desejada  $\{d^{(k)}\}$  para cada amostra obtida;
<3> Iniciar o vetor  $\mathbf{w}$  com valores aleatórios pequenos;
<4> Especificar a taxa de aprendizagem  $\{\eta\}$ ;
<5> Iniciar o contador de número de épocas  $\{época \leftarrow 0\}$ ;
<6> Repetir as instruções:
    {
        <6.1> erro  $\leftarrow$  “inexiste”;
        <6.2> Para todas as amostras de treinamento  $\{\mathbf{x}^{(k)}, d^{(k)}\}$ , fazer:
            {
                <6.2.1>  $u \leftarrow \mathbf{w}^T \cdot \mathbf{x}^{(k)}$ ;
                <6.2.2>  $y \leftarrow \text{sinal}(u)$ ;
                <6.2.3> Se  $y \neq d^{(k)}$ 
                    {
                        <6.2.3.1> Então  $\begin{cases} \mathbf{w} \leftarrow \mathbf{w} + \eta \cdot (d^{(k)} - y) \cdot \mathbf{x}^{(k)} \\ \text{erro} \leftarrow \text{"existe"} \end{cases}$ 
                    }
            }
        <6.3>  $época \leftarrow época + 1$ ;
    }
    Até que: erro  $\leftarrow$  “inexiste”

```


Fim {Algoritmo *Perceptron* – Fase de Treinamento}

Fonte: SILVA; SPATTI; FLAUZINO (2016)

3.5 O Perceptron Multicamadas (*Multilayer Perceptron - MLP*)

O que caracteriza uma rede multicamadas é a existência de pelo menos uma camada de neurônios entre as entradas e a camada de saída. Essa camada intermediária é conhecida como camada oculta. Inicialmente a inserção de uma camada oculta possibilitava a solução de problemas que envolviam classes não linearmente separáveis (ROCHA, 2018). Atualmente observa-se que as redes MLP são aplicáveis a uma gama de aplicações, como por exemplo, aproximação de funções, previsão de séries temporais, otimização etc. (SILVA; SPATTI; FLAUZINO, 2016). A Figura 3.11 ilustra uma rede MLP com quatro camadas, uma camada de entrada, duas ocultas e a camada de saída.

Figura 3.11: Perceptron Multicamadas



Fonte: Adaptado de HAYKIN (2001)

O treinamento de uma rede MLP é efetuado através do aprendizado supervisionado e do algoritmo de retropropagação de erros, Algoritmo *Backpropagation*. Esse algoritmo é baseado na regra de aprendizagem por correção de erro (HAYKIN, 2001).

A utilização de uma rede MLP para um determinado projeto requer do projetista que o mesmo defina *a priori* as especificações (topologia) da rede, como por exemplo, número de sinais de entrada, número de camadas ocultas, quantidade de neurônios em cada camada oculta e o número de neurônios na camada de saída. Não existem regras pré-estabelecidas para escolha da topologia da rede. Essa escolha depende do problema em questão e normalmente é escolhida através de testes computacionais (ROCHA, 2018).


3.5.1 O Algoritmo de Retropropagação – *Backpropagation*

Apesar do algoritmo Backpropagation ser conhecido por retropropagação, este é composto por duas fases, propagação e retropropagação. Na fase de propagação os sinais de entrada são multiplicados pelos pesos sinápticos, aplicados ao somador para formação de uma combinação linear, o resultado aplicado a uma função de ativação. Esse processo é realizado em todos os neurônios e em todas as camadas até chegar na camada de saída (SILVA; SPATTI; FLAUZINO, 2016).

Quando o processo chega à camada de saída, o resultado é comparado ao sinal desejado para verificação do um erro existente entre a saída da rede e o sinal desejado (HAYKIN, 2001; ROCHA, 2018; BATISTA, 2012).

O erro obtido na fase de propagação é utilizado na atualização dos pesos das camadas da MLP, de modo que tal atualização seja feita iniciando na última camada até chegar na primeira camada. Esse processo de atualização dos pesos é conhecido como retropropagação (HAYKIN, 2001).

A fase de propagação (sentido entrada-saída) é também chamada de fase *forward* e a retropropagação *backward*. A Figura 3.12 mostra o funcionamento do algoritmo *backpropagation* em uma rede MLP.



Fonte: Adaptado de ASTERIS et al.(2016)

Em resumo, a aplicação sucessiva das fases *forward* e *backward* implica na minimização do erro e consequentemente na convergência da rede (SILVA; SPATTI; FLAUZINO, 2016). Métodos de otimização são aplicados para derivação das expressões iterativas de atualização dos pesos. A seguir tem-se uma análise matemática dessas expressões.

3.5.2 Análise Matemática do Algoritmo *Backpropagation*

Já foi citado, diversas vezes, durante o texto que o objetivo de um *perceptron* é adaptação dos pesos de modo que o erro entre a saída desejada e a obtida pela RNA seja mínimo. Essa tarefa é caracteriza-se como um clássico problema de otimização não linear sem restrições (BATISTA, 2012).

Para solucionar problemas de otimização sem restrições, diversos métodos foram desenvolvidos, como por exemplo, Levenberg-Marquardt, Newton e o Método do Gradiente Descendente (BOYD, 2009). É apresentada a seguir uma abordagem sobre o Método do Gradiente Descendente, a fim de embasar o processo de derivação das expressões de atualização dos pesos sinápticos utilizadas pelo algoritmo de retropropagação.

3.5.2.1 Método do Gradiente Descendente

O método do gradiente descendente ou método da descida mais íngreme, tem como objetivo encontrar os parâmetros que minimizam determinada função, tendo como base o vetor gradiente da mesma. Sabe-se por exemplo que o vetor gradiente de uma função $f: R^n \rightarrow R$ tem a mesma direção de crescimento da mesma. Isso significa que colocando um sinal de “menos” antes do vetor gradiente a direção do mesmo muda, ou seja, aponta para o decrescimento de f . Com base nessa característica geométrica é que o método da descida mais íngreme foi estabelecido (YUAN, 2008).

Dada uma função $f: R^n \rightarrow R$ contínua e diferenciável no R^n . O problema de otimização consiste em encontrar $\mathbf{x}$ que minimize f . Traçando um paralelo com o problema da RNA, pretende-se encontrar $\mathbf{w}$ (vetor de pesos) que minimize o $E(\mathbf{w})$ erro.


A Equação 5 resume o processo iterativo segundo o método do gradiente descendente para solução do problema de otimização.

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \eta \cdot \mathbf{g}_k \quad (5)$$

onde, $\mathbf{x}_k$ é o ponto da iteração atual, $\eta > 0$ é uma constante que determina a velocidade de convergência do algoritmo e $\mathbf{g}_k = \nabla f(\mathbf{x}_k)$ o vetor gradiente em $\mathbf{x}_k$ (YUAN, 2008).

O Método do gradiente descendente é bastante utilizado na atualização de pesos sinápticos de algumas Redes Neurais Artificiais, como por exemplo, no *Perceptron* Multicamadas. Considerando inicialmente um valor inicial para W^0 , e utilizando a Equação 17 tem-se o próximo valor W^1 . Repete-se esses passos até encontrar W^* que minimiza a função do erro quadrático médio (SILVA; SPATTI; FLAUZINO, 2016). A Figura 3.13 é uma representação, em três dimensões, de como funciona a atualização de pesos através da descida do gradiente.

Figura 3.13: Gradiente descendente



Fonte: (Autora, 2019).

Traçando novamente um paralelo com atualização dos pesos sinápticos W das camadas de neurônios da RNA, pode-se afirmar então que a expressão, baseada no Método do Gradiente Descendente, para atualização de W é descrita pela Equação 6.


$$W^{k+1} = W^k - \eta \frac{\partial E(W)}{\partial W}. \quad (6)$$

A Equação 6 aplicada em cada camada da rede MLP na ordem estabelecida pela retropropagação faz com que o erro seja minimizado. No subtópico a seguir é possível verificar matematicamente como funciona tal processo.

3.5.2.2 Atualização dos Pesos Sinápticos

Apesar de na descrição do método de gradiente descendente se chegar a uma expressão geral para atualização dos pesos sinápticos, essa expressão assumirá formas diferentes em cada camada, porém com a mesma origem. Nesta seção, é apresentada a forma matemática com a qual se determina as expressões de atualização em cada camada da rede MLP. Para isso, são apresentadas na Figura 3.14 as relações entre as variáveis, índices matriciais, a arquitetura e topologia da rede e a notação matemática usada no desenvolvimento matemático.


Figura 3.14: Notação Matemática para derivação do algoritmo backpropagation



Fonte: SILVA; SPATTI; FLAUZINO (2016)

Segundo Silva; Spatti; Flauzino (2016), é possível observar o j -ésimo neurônio pertencente a uma das camadas qualquer topologia ilustrada, como um *perceptron* simples ilustrado na Figura 3.15.

Figura 3.15: Variáveis matemáticas do Perceptron



Fonte : SILVA; SPATTI; FLAUZINO (2016)

Em que $g(\cdot)$ representa uma função de ativação, que no caso específico do algoritmo *backpropagation* tem que ser diferenciável em todo seu domínio. Para fins de cálculo matemático, assume-se então as seguintes notações para as variáveis e parâmetros (BATISTA, 2012).

$W_{ji}^{(L)}$ São matrizes de pesos cujos elementos denotam o valor do peso sináptico, conectando o j -ésimo neurônio da camada (L) ao i -ésimo neurônio da camada (L-1). Como exemplo, tem-se que $W_{ji}^{(3)}$ é o peso sináptico, conectando o j -ésimo neurônio da terceira camada ao i -ésimo neurônio da segunda camada.

Seguindo a mesma lógica, $W_{ji}^{(2)}$ é o peso sináptico, conectando o j -ésimo neurônio da segunda camada ao i -ésimo neurônio da primeira camada, e ainda $W_{ji}^{(1)}$ é o peso sináptico, conectando o j -ésimo neurônio da primeira camada ao i -ésimo neurônio da camada de entrada.

As notações para as demais variáveis são:

- ✓ $I_j^{(L)}$ São vetores resultantes da ponderação das entradas em relação ao j -ésimo neurônio da camada L, de tal forma que as Equações 7 a 9 sejam satisfeitas.

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} \cdot x_i = W_{j,0}^{(1)} \cdot x_0 + W_{j,1}^{(1)} \cdot x_1 + \cdots + W_{j,n}^{(1)} \cdot x_n ; \quad (7)$$

$$I_j^{(2)} = \sum_{i=0}^n W_{ji}^{(2)} \cdot y_i^{(1)} = W_{j,0}^{(2)} \cdot y_0^{(1)} + W_{j,1}^{(2)} \cdot y_1^{(1)} + \cdots + W_{j,n}^{(2)} \cdot y_n^{(1)} ; \quad (8)$$

$$I_j^{(3)} = \sum_{i=0}^n W_{j,i}^{(3)} \cdot y_i^{(2)} = W_{j,0}^{(3)} \cdot y_0^{(2)} + W_{j,1}^{(3)} \cdot y_1^{(2)} + \dots + W_{j,n}^{(3)} \cdot y_n^{(2)} ; \quad (9)$$

✓ $Y_j^{(L)}$ é o vetor de saída do j-ésimo neurônio em relação à camada L, ou seja, é o resultado da combinação linear aplicada na função de ativação escolhida. Em termos matemáticos pode-se observar $Y_j^{(L)}$ nas Equações 10 a 12.

$$Y_j^{(1)} = g(I_j^{(1)}); \quad (10)$$

$$Y_j^{(2)} = g(I_j^{(2)}); \quad (11)$$

$$Y_j^{(3)} = g(I_j^{(3)}); \quad (12)$$

A notação para o erro em cada neurônio da rede MLP é dada de acordo com a Equação 13.

$$e_j(k) = d_j(k) - y_j(k) \quad (13)$$

em que $y_j(k)$ é a resposta calculada para o neurônio j e $d_j(k)$ é a resposta desejada também para o neurônio j.

É importante salientar que é impossível mensurar o valor do erro nos neurônios das camadas intermediárias, uma vez que é conhecido apenas o valor desejado final. Nestas condições, faz-se necessário então estabelecer a notação para o erro quadrático da camada de saída.

Tendo em vista a arquitetura da rede MLP ilustrada na Figura 3.14, assume-se que a função de erro quadrático a ser minimizada é dada por (Equação 14):

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} (d_j(k) - y_j^{(3)}(k))^2, \quad (14)$$

em que $y_j^{(3)}(k)$ é o valor produzido pelo j -ésimo neurônio de saída da rede, considerando-se a k -ésima amostra de treinamento, enquanto que $d_j(k)$ é o seu respectivo valor desejado.

Assumindo um conjunto de treinamento composto por p amostra, a Equação 15 reflete a expressão matemática do erro quadrático médio.

$$E = \frac{1}{p} \sum_{k=1}^p E(k). \quad (15)$$

Portanto, função E é aquela a ser minimizada pelo método do gradiente descendente. Assim, a expressão de ajuste dos pesos da camada de saída, é obtida determinando-se o gradiente ∇E . Esse gradiente é utilizado para encontrar a matriz de pesos $w_{ji}^{(3)}$ que minimiza E . De acordo com a regra da cadeia para o cálculo de derivadas de funções compostas, pode expressar esse gradiente como descrito da Equação 16.

$$\nabla E = \frac{\partial E}{\partial w_{ji}^{(3)}} = \frac{\partial E}{\partial Y_j^{(3)}} \cdot \frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} \cdot \frac{\partial I_j^{(3)}}{\partial w_{ji}^{(3)}}. \quad (16)$$

Considerando as definições anteriores chega-se as Equações 17 – 19.

$$\frac{\partial I_j^{(3)}}{\partial w_{ji}^{(3)}} = Y_i^{(2)} \quad (17)$$

$$\frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} = g'(I_j^{(3)}) \quad (18)$$

$$\frac{\partial E}{\partial Y_j^{(3)}} = -(d_j - Y_j^{(3)}). \quad (19)$$

Lembra-se que $g'(\cdot)$ é a notação para derivada de primeira ordem da função de ativação considerada.

Substituindo os resultados das Equações (17), (18) e (19) na Equação (16), obtem-se a Equação 20.

$$\nabla E = \frac{\partial E}{\partial w_{ji}^{(3)}} = -(d_j - Y_j^{(3)}) \cdot g'(\mathbf{I}_j^{(3)}) \cdot Y_i^{(2)}. \quad (20)$$

Aplicando a expressão iterativa do método do gradiente descendente, o ajuste da matriz de pesos $w_{ji}^{(3)}$ efetuado em direção oposta ao gradiente, a fim de encontrar o mínimo de E obtem-se o algoritmo iterativo dado pela Equação 21.

$$w_{ij}^{(3)}(t+1) = w_{ij}^{(3)}(t) - \eta \cdot \nabla E. \quad (21)$$

Substituindo a Equação 20 em 21 chega-se a expressão de atualização a ser utilizada (Equação 22):

$$w_{ij}^{(3)}(t+1) = w_{ij}^{(3)}(t) + \eta \cdot (d_j - Y_j^{(3)}) \cdot g'(\mathbf{I}_j^{(3)}) \cdot Y_i^{(2)}. \quad (22)$$

O procedimento para se obter as expressões de atualização dos pesos das demais camadas da rede MLP é realizado de modo análogo ao descrito nesse tópico. O leitor que tiver interesse em conhece-las pode encontra-las em Batista (2012) ou em Silva; Spatti; Flauzino (2016).

4 MODELAGEM E TÉCNICAS ESTATÍSTICAS

A realização de modelagem matemática requer formalizações inerentes ao processo. Uma das maneiras de apresentar e ou avaliar um modelo matemático ou computacional é fazendo uso de ferramentas estatística já consolidadas na literatura. É nesse contexto que são apresentados nesse capítulo, os conceitos de modelagem e das ferramentas estatísticas utilizadas nesse tipo de processo.

4.1 Conceito de modelagem

Para Armellini (2010), modelagem consiste na reunião de equações matemáticas capazes de descrever determinado processo organizadas com o auxílio de um computador a fim de serem realizadas simulações. A modelagem matemática e a simulação computacional são recursos indispensáveis no desenvolvimento e estudo dos mais diversos processos (ARMELLINI, 2010).

Segundo Maués (2017), modelar consiste na tentativa de representar a realidade de tal maneira que essa representação possa ser a mais correta possível e que se aproxime ao máximo da realidade, dentro de um intervalo de confiança ao qual foi projetado.

Modelagem, para Biembengut (2012), é o processo de representação simplificada da realidade, preservando, em determinadas situações, equivalência. Para Bassanezi; Ferreira (1988), o processo de modelagem está estruturado em cinco importante etapas:

- Experimentação: é a etapa na qual se realiza a obtenção e interpretação dos dados;
- Abstração: nessa etapa a formulação matemática é pensada, as variáveis são definidas, o problema é estruturado e as hipóteses são apresentadas;
- Resolução: ocorre nessa fase a substituição da linguagem natural pela linguagem matemática;
- Validação: nessa fase o modelo é testado e os resultados são analisados;
- Modificação: processo de aceitação ou não do modelo proposto verificando as possíveis falhas e melhorias do mesmo.

O conceito de modelagem, portanto está ligado à tarefa de traduzir para uma linguagem científica fenômenos reais, com o cuidado de garantir uma representação mais fidedigna possível, minimizando os erros entre o modelo e o fenômeno, garantindo assim sua aplicabilidade.

4.2 Técnicas Estatísticas

A estatística oferece ferramentas importantes para consolidação do processo de modelagem matemática, pois formaliza técnicas que auxiliam desde a experimentação até a modificação. Na etapa de experimentação por exemplo o uso de estatística descritiva é bastante empregado na aquisição, leitura e interpretação dos dados. Outro exemplo é a utilização da estatística inferencial para validação, análise dos resultados e tomadas de decisão.

Nesse tópico do trabalho serão abordadas as principais técnicas estatísticas utilizadas nos processos de modelagem em geral.

4.2.1 Estatística Descritiva

O início de um processo de modelagem normalmente ocorre na experimentação, nessa fase os dados são coletados. Nesse contexto, a estatística descritiva é a ferramenta que possibilita de maneira clara a exibição, estudo, resumo e interpretação das informações coletadas. Para essas tarefas, é comum resumir as informações contidas nos dados em valores que sejam representativos da série toda. Usualmente, emprega-se uma das seguintes medidas de posição (ou localização) central: média, mediana ou moda (BUSSAB; MORETTIN, 2003).

A moda é definida como a realização mais frequente do conjunto de valores observados. Já a mediana é a realização que ocupa a posição central da série de observações, quando estão ordenadas em ordem crescente ou decrescente, e a média aritmética consiste na soma das observações dividida pela quantidade de amostras (Eq. 23) (BECKER, 2015).

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (23)$$

em que x_i é o valor referente a i -ésima amostra e n é o número total de amostras.

A utilização de medidas de posição central pode “esconder” informações importantes sobre o conjunto de dados, principalmente no que diz respeito a sua variabilidade. Nesse sentido, ao avaliar um conjunto de amostra de determinada pesquisa é sempre conveniente analisar também as medidas de variabilidade, isto é, o desvio médio e a variância (Eq. 24 e Eq. 25) (BECKER, 2015).

$$dm(X) = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n} \quad (24)$$

$$var(X) = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} \quad (25)$$

Segundo Bussab; Morettin (2003), tanto a média quanto o desvio e a variância podem não ser medidas adequadas para representar um conjunto de dados, pois:

- (a) São afetados, de forma exagerada, por valores extremos;
- (b) Apenas com estes dois valores não se tem ideia da simetria ou assimetria da distribuição dos dados.

A proposta de Bussab; Morettin (2003), para contornar esses problemas, é analisar outras medidas, como por exemplo os quantis. Tendo em vista que a mediana é um valor que deixa metade dos dados abaixo dela e metade acima, define-se quantil de ordem p ou p -quantil, indicado por $q(p)$ (em que p é um valor extritamente entre 0 e 1) o valor tal que $100p$ % das observações sejam menores do que $q(p)$. Em resumo, tem-se os seguintes exemplos:

$q(0,25)$: 1º Quartil

$q(0,50)$: 2º Quartil (Mediana)

$q(0,75)$: 3º Quartil

As informações sobre mediana, primeiro quartil e terceiro quartil podem ser observadas graficamente em um diagrama conhecido por desenho esquemático ou *box plot*. A nomenclatura *box plot* é a mais utilizada na prática.


A construção do *box plot* é feita considerando um retângulo onde estão representados o primeiro quartil, a mediana e o terceiro quartil. A partir do retângulo, para cima, é estabelecida uma linha até o ponto mais remoto, chamado limite superior. De modo similar, a parte inferior

do retângulo, para baixo, segue uma linha até o ponto mais remoto, chamado limite inferior (AYRES, 2012).

As observações que estiverem acima do limite superior ou abaixo do limite inferior estabelecido são chamadas de *pontos exteriores* e são representadas por asteriscos. Essas observações são destoantes das demais e podem ou não ser o que se chama de *outliers* ou valores atípicos (AYRES, 2012; BUSSAB; MORETTIN, 2003).

Em resumo, pode-se afirmar que o *box plot* repassa, em uma única figura, as informações a respeito de posição, dispersão, assimetria, causas e dados discrepantes. A figura 4.1 consiste em um exemplo de *box plot*.

Figura 4.1: Representação de box-plot



Fonte: (Autora, 2019)

Vale ressaltar ainda que quando se analisa vários conjuntos de dados a utilização do *box plot* é de extrema utilidade para realização de comparações entre os grupos. Basta colocar os gráficos em uma mesma escala para perceber informações concomitantes dos conjuntos analisados e assim verificar semelhanças e ou diferenças em termos de distribuição.

4.2.2 Estatística Inferencial

Segundo Bussab; Morettin (2003), a Inferência Estatística tem como objetivo fornecer informações sobre determinada população a partir de um conjunto de características de uma amostra. Vale lembrar que, por definição, população é o conjunto de todos os elementos ou resultados sob determinada investigação e amostra consiste em qualquer subconjunto da população.

Nesse sentido, é importante diferenciar, em termos de notação, parâmetros (população) e estatísticas (amostra). O Quadro 4.1 retrata essa diferença.

Quadro 4.1: Comparação entre parâmetros e estatística

Denominação	População	Amostra
Média	$\mu = E(X)$	$\bar{X} = \sum X_i/n$
Mediana	Md	md
Variância	$\sigma^2 = Var(X)$	$S^2 = \sum \frac{(X_i - \bar{X})^2}{n-1}$
Nº de elementos	N	n
Quantil	$Q(p)$	$q(p)$
Quartis	Q_1, Q_2, Q_3	q_1, q_2, q_3

Fonte: Modificado de BUSSAB; MORETTIN (2003)

Durante o processo de modelagem, em especial, na fase de teste, surge a necessidade de verificar se as hipóteses pré-estabelecidas são aceitáveis ou não. Testar uma hipótese é uma tarefa atribuída à Inferência Estatística.

Realizada uma afirmação sobre uma população, normalmente sobre um parâmetro da mesma, deseja-se saber se os resultados experimentais provenientes de uma amostra contrariam ou não a afirmação. O objetivo do teste estatístico de hipóteses é estabelecer mecanismos matemáticos que permitam averiguar se as informações oriundas dos dados amostrais são suficientes para refutar ou apoiar a hipótese estatística formulada (BOLFARINE; SANDOVAL, 2001).

O procedimento para construção de um teste de hipóteses, sobre determinado parâmetro populacional, consiste no seguinte: Seja X uma variável associada a uma determinada população, considera-se ainda uma hipótese H sobre determinado parâmetro θ dessa população (por exemplo, afirma-se que o verdadeiro valor de θ é θ_0). A partir de uma amostra aleatória

de elementos dessa população deseja-se comprovar ou não a hipótese (NAGHETTINI; PINTO, 2007).

A hipótese que está sendo colocada à prova é denominada de hipótese nula, em notação matemática a Equação 26 define a hipótese nula.

$$H_0: \theta = \theta_0 \quad (26)$$

Por outro lado, é importante verificar também a hipótese que será considerada aceitável, caso H_0 seja rejeitada. Essa hipótese é chamada de hipótese alternativa (AYRES, 2012) (Eq. 27 e Eq. 28).

$$H_1: \theta \neq \theta_0 \quad (27)$$

ou ainda,

$$H_1: \theta < \theta_0 \text{ ou } H_1: \theta > \theta_0. \quad (28)$$

Após o teste de hipótese ser realizado, é possível que a decisão tomada contenha erros. Esses erros podem ocorrer de duas maneiras: Erro do tipo I ou Erro do tipo II. O erro do tipo I consiste em rejeitar a hipótese nula quando essa é verdadeira (BOLFARINE; SANDOVAL, 2001). Desde que, por definição, α seja a probabilidade de cometer esse erro, tem-se que a relação dada pela Equação 29 é verdadeira.

$$\alpha = P(\text{erro do tipo I}) = P(\text{rejeitar } H_0 | H_0 \text{ é verdadeira}). \quad (29)$$

O erro do tipo II ocorre ao não rejeitar H_0 quando H_0 é falsa. Desse modo, definindo por β a probabilidade de cometer esse erro, tem-se então (Eq. 30):

$$\beta = P(\text{erro do tipo II}) = P(\text{não rejeitar } H_0 | H_0 \text{ é falsa}). \quad (30)$$

Vale lembrar que um teste de hipótese tem por objetivo verificar se a hipótese H_0 é ou não aceitável, considerando uma dada estatística $\hat{\theta}$ (informação sobre a amostra). Nesse contexto, define-se então uma região denominada de “região crítica-RC” (BUSSAB; MORETTIN, 2003).

Se o valor observado da estatística $\hat{\theta}$ faz parte da RC então a hipótese nula H_0 deve ser rejeitada, caso contrário, não se rejeita H_0 . A construção da RC é feita de tal modo que $P(\hat{\theta} \in RC | H_0 \text{ é verdadeira})$ seja igual a α . O valor de α é definido *a priori* pelo pesquisador e a RC também é conhecida por região de rejeição do teste (NAGHETTINI; PINTO, 2007).

Bussab; Morettin (2003), afirmam que a probabilidade α de se cometer um erro de tipo I é um valor arbitrário e recebe o nome de nível de significância do teste, ou seja, o resultado da amostra é tanto mais significativo para rejeitar H_0 quanto menor for esse valor de α . Ou seja, é comum utilizar como nível de significância dos testes de hipótese os valores de α iguais a 5%, 1% ou 0,1%.

Ayres (2012) e Bussab; Morettin (2003) resumem em uma sequência de passos a metodologia utilizada na realização de qualquer teste de hipótese:

Passo 1: Fixar qual a hipótese H_0 a ser testada e qual a hipótese alternativa H_1 ;

Passo 2: Usar a teoria estatística e as informações disponíveis para decidir qual estatística (estimador) será usada para testar a hipótese H_0 e assim obter as propriedades dessa estatística (distribuição, média, desvio padrão);

Passo 3: Fixar a probabilidade α de cometer o erro de tipo I e usar este valor para construir a região crítica (regra de decisão). É importante lembrar que essa região é construída para a estatística definida no passo 2, usando os valores dos parâmetros hipotetizados por H_0 ;

Passo 4: Usar as observações da amostra para calcular o valor da estatística do teste;

Passo 5: Se o valor da estatística calculado com os dados da amostra não pertencer à região crítica, H_0 deve ser rejeitada; caso contrário, não se deve rejeitar H_0 ;

Passo 6: Estabelecer a conclusão em relação ao trabalho efetuado.

4.2.3 Medidas de acurácia

Além de se ter um bom tratamento dos dados através da estatística descritiva e de verificação de hipótese com o uso da estatística inferencial, é necessário dentro do processo de modelagem aplicar algumas métricas, a fim de verificar o quanto o modelo proposto pelo pesquisador está acertando. Para essa finalidade, utiliza-se normalmente as medidas de acurácia.

No entanto, antes de apresentar as definições das medidas de acurácia é importante diferenciar os conceitos de acurácia e precisão, pois essas duas definições ainda causam alguma confusão em suas aplicações. Bussab; Morettin (2003), definem precisão como uma medida

de proximidade entre cada observação e a média de todas as observações, em contrapartida a acurácia mede o quão próxima cada observação está do valor que se procura atingir.

Definir medidas de acurácia então, significa estabelecer métricas que sejam capazes de mensurar a “distância” entre os valores reais e os obtidos pelo modelo estudado. Nesse contexto, duas métricas se destacam: A média percentual absoluta do erro (MAPE – *mean absolute percentage error*) e o erro quadrático médio.

Trabalhos como os de Belalia et al. (2017) e de Maués (2017) utilizaram a média percentual absoluta do erro como métrica de avaliação de acurácia. A MAPE é definida matematicamente conforme a Equação 31.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{X_i - Y_i}{X_i} \right| \quad (31)$$

em que X_i é o valor medido ou observado (valor real), Y_i é a respectiva aproximação de X_i obtida através do modelo matemático e n é a quantidade de amostras avaliadas. O número “100” que aparece antes do somatório é a normalização necessária para que o valor de MAPE seja em termos percentuais.

Outra medida de acurácia que também é comumente utilizada é o erro quadrático médio (MSE - *mean squared error*). O MSE além de ser utilizado como métrica avaliativa em modelagem, algumas vezes faz parte da construção do modelo como é o caso de Redes Neurais Artificiais cuja construção do algoritmo computacional tem como premissa a minimização do MSE (HAYKIN, 2001). A definição matemática do MSE é dada da seguinte forma (Eq. 32):

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2 \quad (32)$$

em que X_i , Y_i e n já foram definidos anteriormente.

Nesse trabalho especificamente, o MSE será utilizado na construção do modelo computacional e o MAPE na avaliação do mesmo, por isso a importância dessas duas métricas estarem bem definidas.

5 DELINEAMENTO E MÉTODO DE PESQUISA

O desenvolvimento desse capítulo consiste na exposição dos conceitos referentes ao método científico, ao delineamento e a metodologia de pesquisa. Um detalhamento de todas as fases da pesquisa e do processo de modelagem também são apresentados.

5.1 Pesquisa e método científico

Gil (2008) define pesquisa como sendo o processo formal e sistemático de desenvolvimento do método científico, cujo objetivo fundamental é descobrir respostas para problemas através da utilização de procedimentos científicos.

Considerando a chamada “pesquisa pura”, Gil (2008) afirma que esta busca o progresso da ciência, procurando desenvolver os conhecimentos científicos. A pesquisa pura não tem como foco aplicações e consequências práticas e seu desenvolvimento normalmente é bastante formalizado e objetivo, e busca a generalização com foco na construção de teorias e leis (GIL, 2008).

Para Praça (2015), existem sete diferentes tipos de pesquisa científica, a saber, a exploratória, experimental, acadêmica, empírica, de campo, laboratorial e pesquisa teórica. Independente do tipo de pesquisa a ser realizada, o pesquisador deve elencar ou procedimentos metodológicos sob os quais realizará a coleta de dados, o delineamento do estudo, a definição da amostragem, o tratamento dos dados e a interpretação dos resultados (PRAÇA, 2015).

Por outro lado, Zanella (2013) classifica pesquisa de acordo com os objetivos, quanto à abordagem e quanto aos Procedimentos Adotados na Coleta de Dados.

Quanto aos objetivos tem-se:

- Pesquisa exploratória: tem como objetivo ampliar o conhecimento a respeito de um determinado fenômeno, explorando a realidade e buscando maior conhecimento. Esse tipo de pesquisa serve como suporte para o planejamento de uma pesquisa descritiva (ZANELLA, 2013).
- Pesquisa descritiva: estuda as características e os problemas do objeto de pesquisa (ZANELLA, 2013).

- Pesquisa explicativa: tem como objetivo identificar os fatores determinantes ou quantificar a contribuição dos mesmos no desencadeamento dos fenômenos (ZANELLA, 2013).

Quanto à abordagem, a pesquisa pode ser classificada em:

- Pesquisa Qualitativa: tem como característica principal a não utilização do instrumental estatístico como centro de suas análises (ZANELLA, 2013).
- Pesquisa Quantitativa: ao contrário da pesquisa qualitativa, a quantitativa se caracteriza pelo emprego de instrumentos estatísticos, tanto na coleta como no tratamento dos dados. Esse tipo de pesquisa objetiva estabelecer medidas que relacionem as variáveis que compõe o fenômeno estudado (ZANELLA, 2013).

Quanto aos procedimentos adotados na coleta de dados, Zanella (2013) lista os seguintes tipos de pesquisa:

- Pesquisa bibliográfica: nesse tipo de pesquisa ocorre o uso exclusivo de fontes bibliográficas;
- Pesquisa documental: é um tipo muito semelhante à pesquisa bibliográfica, porém aqui as fontes são apenas documentais;
- Pesquisa Experimental: nesse tipo de pesquisa é necessário algum tipo de experimento. As variáveis envolvidas podem ser manipuladas pelo pesquisador.
- *Ex-post-facto* (tradução “partir do fato passado”): nesse tipo de pesquisa o estudo é realizado após a ocorrência de variações na variável.

Considerando as definições apresentadas por Gil (2008), Praça (2015) e Zanella (2013) percebe-se que o conceito de pesquisa está intimamente ligado aos mecanismos de realização da mesma. É, nesse contexto, que surge a necessidade de se estudar um pouco sobre o método científico.

Etimologicamente, a palavra **Método** tem origem no grego “*méthodos*”, que consiste na composição de duas palavras *metá* que significa no meio de; através, entre..., acrescida de *odós*, que significa “caminho” (ZANELLA, 2013).

Para Zanella (2013), **Método** pode ser definido como sendo uma série de procedimentos intelectuais e técnicos adotados para atingir determinado conhecimento, ou seja, é a forma que o cientista escolhe para ampliar o conhecimento sobre determinado objeto, fato ou fenômeno.

O método científico pode ser classificado em dois grupos, os métodos de abordagem e os métodos de procedimentos. Compõe o grupo dos métodos de abordagem, o método dedutivo, o método indutivo, o método hipotético-dedutivo, o método dialético e o método fenomenológico. Já ao grupo dos métodos de procedimentos pertencem o método histórico, o método experimental, o método observacional, o método comparativo, o método estatístico, o método clínico e o método monográfico (PROVDANOV; FREITAS, 2013).

Apesar da quantidade de métodos descritos na literatura ser sobretudo extensa, vale ressaltar que o pesquisador dispõe de um elevado grau de liberdade para escolher os melhores procedimentos na execução de sua pesquisa, visando sempre alcançar os objetivos propostos de maneira mais qualificada possível.

5.2 Fases do Desenvolvimento da Pesquisa

Com base no que foi exposto sobre pesquisa científica, buscou-se verificar o enquadramento metodológico no qual esta pesquisa se desenvolve. De acordo com as definições apresentadas por Zanella (2013), a pesquisa apresentada nesse trabalho foi então classificada, quanto aos objetivos, como sendo explicativa. Já quanto à abordagem é uma pesquisa quantitativa, e quanto aos procedimentos adotados na coleta de dados como do tipo *ex-post facto*.

O método utilizado para realização dessa pesquisa foi composto por quatro fases, revisão bibliográfica, preparação, modelagem e validação do modelo. Cada fase, porém, foi realizada em etapas. Um resumo das fases e suas respectivas etapas está apresentado no Quadro 5.1.

Quadro 5.1: Resumo do método da pesquisa

Fase I: Revisão Bibliográfica	Ocorre de modo transversal em todas as fases do projeto.
Fase II: Preparação	1ª Etapa: Estudo exploratório e definição do problema; 2ª Etapa: Escolha das variáveis; 3ª Etapa: Organização da base de dados.
Fase III: Modelagem	1ª Etapa: Escolha do tipo de RNA e construção do algoritmo; 2ª Etapa: Especificações e treinamento das RNA's; 3ª Etapa: Teste das RNA's.
Fase IV: Avaliação e análises estatísticas	1ª Etapa: Avaliação por meio das medidas de acurácia; 2ª Etapa: Estatística Descritiva (correlação e box plot) 3ª Etapa: Estatística Inferencial (Testes de hipótese)

Fonte: (Autora, 2019).

O detalhamento explicativo do método adotado e resumido no Quadro 5.1 está apresentado nos subtópico a seguir.

5.2.1 Fase I: Revisão bibliográfica

Devido à necessidade de embasamento teórico em todas as fases do trabalho, a revisão bibliográfica teve início antes mesmo da definição do problema a ser estudado e continuou inserida em todo o desenvolvimento da pesquisa. O objetivo principal da revisão bibliográfica foi de dar suporte para uma boa caracterização do problema estudado, para elaboração do modelo e para análise dos resultados obtidos.

Um levantamento bibliográfico foi realizado considerando as principais bases de trabalhos científicos, *Science Direct* e *Periódicos Capes*. Esse levantamento foi realizado com o auxílio do *software* StArt e teve como foco temas como Redes Neurais Artificiais, Predição e modelos para previsão de custo e prazos de empreendimento públicos. Na Tabela 5.1 consta um resumo das características de execução da revisão bibliográfica.

Tabela 5.1: Palavras-chave da revisão bibliográfica

Palavras-Chave	Trabalhos encontrados
Prediction of execution cost public works	5115
Prediction and deadline and public works	1.607
Artificial neural networks and public works	9.178
Total	15.900

Fonte: (Autora, 2019).

Alguns critérios foram aplicados para que apenas artigos relacionados a esta pesquisa fossem utilizados. Na Tabela 5.2 estão listados os critérios de exclusão dos artigos e o quantitativo de trabalhos excluídos pelos mesmos.

Tabela 5.2: Critérios de exclusão de artigos

Critério de exclusão	Trabalhos excluídos
Artigos repetidos	302
Leitura do tema	15.512
Leitura do resumo	53
Total excluídos	15.867

Fonte: (Autora, 2019).

Após a verificação do tema e posteriormente dos resumos dos artigos encontrados restou um total de 33 artigos e esses foram os primeiros trabalhos lidos e estudados. Esses trabalhos serviram como embasamento inicial para o desenvolvimento dessa pesquisa.

5.2.2 Fase II: Preparação

A fase de preparação da pesquisa ocorreu em três etapas distintas: definição do problema, escolha das variáveis e a organização da base de dados.

1ª Etapa: Estudo exploratório e definição do problema.

Um estudo exploratório sobre modelagem e técnicas estatísticas também foi realizado. Nesse estudo, foi averiguado quais as etapas que compõe o processo de modelagem e quais as técnicas estatísticas utilizadas, tanto na elaboração de modelos quanto nas avaliações do mesmo.

Após os primeiros contatos com trabalhos sobre o tema, percebeu-se haver uma lacuna no que diz respeito a modelos de previsão de prazo de obras públicas. No âmbito nacional essa lacuna ainda se mostrou maior. Nesse contexto, surge a suposição de que é possível utilizar técnicas de inteligência artificial para ajudar a preencher tal lacuna e assim se estabelece a problemática percorrida nesse trabalho.

2ª Etapa: Escolha das variáveis

Os objetivos propostos nesse trabalho implicam na definição de dois grupos de variáveis. O primeiro grupo constitui-se daquelas que se deseja modelar e prever quais seriam seus valores quando não se tem informações sobre as mesmas. A este grupo denominou-se de variáveis dependentes.

Para essa pesquisa, as variáveis dependentes foram estabelecidas como sendo o valor final de cada obra, o aditivo de custo e o tempo total de conclusão de cada empreendimento. O segundo grupo de variáveis (variáveis independentes) ficou composto por características dos projetos disponíveis aos usuários do modelo, ou seja, a definição das variáveis independentes foi realizada em função das informações disponíveis no site do MEC.

A escolha das variáveis independentes pode representar uma limitação do modelo proposto, pois as que se tinha disponível no banco de dados não necessariamente são as mesmas que a literatura aponta como as que mais influenciam no aumento de custos e prazos. Porém, acreditou-se que como o modelo proposto tem capacidade de aprender padrões então a previsão seria possível.

3ª Etapa: Organização da base de dados

Os dados utilizados no processo de modelagem foram obtidos em uma plataforma *on-line* do Ministério da Educação- MEC. Essa plataforma é denominada de Sistema Integrado de Monitoramento, Execução e Controle (SIMEC). A metodologia de aquisição, a descrição completa e uma análise dessa base de dados podem ser encontradas no trabalho de Alvarenga (2019), pois os dados utilizados neste trabalho foram cedidos pelo pesquisador quando da elaboração da sua dissertação de mestrado.

Inicialmente um total de 2178 amostras compõe a base de dados. Uma filtragem foi realizada a fim de se obter apenas as amostras que continham concomitantemente, informações sobre as variáveis dependentes e independentes utilizadas no processo de modelagem. Após a realização da filtragem, o banco de dados foi reduzido para 1094 amostras.

5.2.3 Fase III: Modelagem

O processo de modelagem realizado na terceira fase dessa pesquisa buscou consonância com os de experimentação, abstração, resolução, validação e modificação apresentados por Bassanezi; Ferreira (1988). A fase de modelagem, portanto foi realizada em três etapas.

1ª Etapa: Escolha do tipo de RNA e construção do algoritmo

Diferentes técnicas baseadas em inteligência artificial são utilizadas em problemas de engenharia. Quanto às RNA's a diversidade de modelos também é uma realidade. A escolha, porém, do tipo de rede normalmente depende do problema a ser modelado. Para problemas de previsão, é comum se utilizar a rede *Perceptron* Multicamadas (MLP). Nesse contexto, optou-se em utilizar uma rede MLP para realizar previsão de custo e prazo.

Optou-se ainda por escrever um algoritmo para realização das fases de treino e teste da MLP. O algoritmo foi escrito em linguagem *Matlab* (do inglês MATrix LABoratory). A opção de escrever o código se deu pelo fato de que assim o pesquisador tem acesso a todas as informações da rede e também tem a liberdade de realizar modificações que achar necessário. O código do algoritmo utilizado nessa pesquisa encontra-se no Apêndice A.

Vale ressaltar que a escolha da quantidade de amostras separadas para treino e teste não provém de metodologias estatísticas e sim de testes quanto a capacidade de aprendizado da RNA, ou seja, depende do problema a ser solucionado. Em alguns problemas essa separação pode ocorrer segundo a proporção 70/30 (70% para treino e 30% para teste), ou até mesmo a 90/10 (90% para treino e 10% para o teste). Existem ainda casos que o conjunto de teste é subdividido para que se possa realizar vários treinamentos.

2ª Etapa: Especificações e treinamento das RNA's

As características topológicas da rede referentes ao número de camadas, taxa de aprendizagem, critérios de parada, número de neurônios em cada camada e bias foram definidos a partir de vários treinamentos e validação das redes.

Vale ressaltar que não existem mecanismos matemáticos para definição das características da rede, fazendo com que essa escolha seja feita de maneira empírica. Após realizar vários treinamentos com topologia diferentes, os melhores resultados foram escolhidos e as respectivas topologias apresentadas.


Antes de realizar o treinamento de uma RNA é sempre aconselhável realizar a normalização dos dados para que estes fiquem limitados dentro do intervalo [0,1] (DOGAN; ARSLAN; CEYLAN, 2015). Uma maneira de realizar essa normalização é fazendo uso da Equação 33.

$$A_N = \frac{A_i - \min(A)}{\max(A) - \min(A)}, \quad (33)$$

em que A_N é a amostra normalizada, A_i amostra original e $\min(A)$ e $\max(A)$ respectivamente menor e maior valor dentre todas as amostras da variável a ser normalizada. Foram treinadas duas topologias diferentes. Com a primeira topologia foi possível prever o custo final da obra e os aditivos de prazo. A segunda topologia, no entanto, foi utilizada para previsão de prazos e aditivos de custo.

No caso da previsão de custos, as especificações utilizadas foram: quatro entradas, uma camada oculta, oito neurônios na camada oculta e uma saída (custo final previsto pela rede). A Figura 5.1 ilustra a topologia e o processo de treinamento da RNA na previsão de custos e de aditivos de prazos.

Figura 5.1: Topologia da rede utilizada para previsão de custos e aditivos de prazos




Fonte: (Autora, 2019).

O valor previsto pela rede em cada *looping* é comparado com o valor medido enquanto a diferença entre o erro de um *looping* e outro não for menor que 10^{-7} a rede continua atualizando os pesos.

Apesar de ser utilizada a mesma topologia da previsão de custos, o modelo neural para previsão de aditivos de prazo dependeu de cinco entradas, ou seja, a diferença entre o modelo de previsão de custos e previsão de aditivos de prazo consiste apenas no número de entradas.

A RNA utilizada no treinamento para previsão de aditivos de custo teve como características: cinco entradas, uma camada oculta, dez neurônios na camada oculta e uma saída. O processo de treinamento se deu de modo similar ao que ocorreu para previsão de custos. Na Figura 5.2, é possível observar as características da rede utilizada.

Figura 5.2: Topologia da rede utilizada para previsão de prazos e aditivos de custo



Fonte: (Autora, 2019).

Quando o objetivo foi realizar previsão de prazos, a topologia e o processo de treinamento ocorreram de maneira similar ao caso de previsão de aditivos de custo, inclusive no que tange ao número de entradas.


3ª Etapa: Teste das RNA's.

Os testes das RNA's também ocorreram para os quatros problemas citados, a saber, previsão de custos, de prazos e de aditivos (de custos e de prazos). As diferenças entre essa fase e o teste são as seguintes:

- ✓ É realizado apenas um *looping*;
- ✓ Não existe mais atualização de pesos;
- ✓ Os pesos utilizados são aqueles obtidos durante o treinamento;
- ✓ O erro calculado é analisado para fins de validação do modelo.

A figura 5.3 apresenta como ocorre o processo de teste da RNA para previsão de custos.


Figura 5.3: Topologia da rede utilizada para validação do modelo de previsão de custos e aditivos de prazos



Fonte: (Autora, 2019).

As fases de teste para previsão de prazo de execução e de aditivos de custos podem ser ilustradas a partir de Figura 5.4.

Figura 5.4: Topologia da rede utilizada para validação do modelo de previsão de prazos de execução e de aditivos de custos



Fonte: (Autora, 2019).

Ao comparar as figuras 5.2 a 5.5, percebe-se que as figuras referentes a fase de teste não contêm a informação de atualização dos pesos através do erro entre a saída da rede e os valores reais. Essa característica é, portanto, a principal diferença entre o treinamento e o teste de uma RNA.

5.2.4 Fase IV: Avaliação e análises estatísticas

Antes de realizar as avaliações dos resultados, os valores de amostras foram desnormalizados segundo a Equação 34.

$$A_i = A_N[\max(A) - \min(A)] + \min(A). \quad (34)$$

em que A_N é a amostra normalizada, A_i amostra original e $\min(A)$ e $\max(A)$ respectivamente menor e maior valor dentre todas as amostras da variável a ser normalizada.

A fase de análise dos resultados dos modelos apresentados consistiu tanto em verificar a fase de treinamento quanto a fase de teste das RNA's apresentadas. Para tanto, ferramentas estatísticas foram utilizadas em quatro etapas distintas.

1ª Etapa: Avaliação por meio das medidas de acurácia

De posse dos valores calculados pelas redes neurais, o erro percentual médio (MAPE) entre as saídas da rede e os valores reais foram calculados, a fim de verificar a acurácia do modelo. A acurácia (ou assertividade) do modelo foi determinada apartir do percentual de valores previstos pertencentes ao intervalo $[L_s, L_i]$ definido pelas Equações 35 e 36.

$$L_s = V_R + MAPE * V_R, \quad (35)$$

$$L_i = V_R - MAPE * V_R, \quad (36)$$

em que L_s e L_i são os limite superior e inferior do intervalo de assertividade e V_R é o valor real da base de dados.

2ª Etapa: Estatística Descritiva

Nessa etapa foram realizadas comparações entre os *boxplots* dos valores reais e dos valores obtidos com os modelos, a fim de verificar graficamente diferenças entre as amostras analisadas.

Foi realizada ainda uma análise de correlação para verificar se existia relação de linearidade entre os valores previstos e os valores reais. Esse tipo de análise foi verificado em alguns trabalhos que realizam previsões através de modelos matemáticos.

3ª Etapa: Estatística Inferencial (Testes de hipótese)

Tendo em vista que apenas uma análise gráfica não é suficiente para inferir sobre a existência ou não de diferenças entre os conjuntos de amostras analisados, verificou-se a necessidade da realização de testes de hipótese.

Primeiramente aplicou-se o teste de *Kolmogorov-Smirnov* para inferir sobre o tipo de distribuição dos dados. Verificou-se a hipótese de que as amostras são oriundas de distribuição normal. Em seguida, o teste de *Mann Whitney* foi aplicado para verificação de diferenças significativas entre os valores reais e os obtidos pelos modelos neurais.

Com base nas técnicas estatísticas percorridas e aplicadas nessa fase, reflexões sobre a utilização do modelo foram realizadas e as conclusões foram apresentadas como desfecho dessa pesquisa.

6 TREINAMENTO E VALIDAÇÃO DO MODELO NEURAL

Neste capítulo são apresentados os resultados que a aplicação do modelo neural obteve para previsão de custo, aditivo de custo e prazo de execução de obras públicas. Cada aplicação do modelo foi composta de duas fases, fase de treinamento e fase de teste.

Antes de realizar o treinamento da RNA, as amostras utilizadas, tanto no treino quanto no teste, foram normalizadas de acordo com a Equação 33, e após realizada a fase de aprendizado e a fase de teste os dados foram “desnormalizados” (Eq. 34) para fins de cálculo do erro, correlação e testes de hipótese.

Na fase de treinamento os parâmetros foram ajustados até a função de custo alcançar o mínimo. Nessa fase, diferentes quantidades de amostras foram utilizadas e a que apresentou melhor aprendizado da rede foi escolhida e apresentada no texto. Após a fase de treinamento, os dados separados para o teste (dados novos) foram utilizados para validação do modelo. Na fase de teste, não existe ajuste dos parâmetros.

A avaliação dos resultados foi realizada através do erro percentual médio, da acurácia (assertividade), do cálculo do coeficiente de correlação de Pearson e dos testes de hipótese.

6.1 Previsão de Custo

As primeiras simulações realizadas tiveram como objetivo prever os custos finais das obras. Primeiramente, realizou-se o treinamento da rede para que os pesos sinápticos fossem atualizados de modo a minimizar o erro entre a saída da rede e os valores reais.

Na segunda fase, os pesos obtidos no treinamento foram utilizados para teste e validação do modelo. Nos subtópicos a seguir são apresentados os resultados obtidos para previsão de custo no treinamento e no teste da RNA. Uma análise estatística baseada em testes de hipótese e no cálculo de correlação entre valores obtidos pela rede e valores reais é apresentada.

6.1.1 Treinamento da Rede Neural Artificial (RNA) para previsão de Custos

Para a fase de treinamento do modelo foram utilizadas como variáveis de entrada da RNA a área do empreendimento a ser construído, quantidade de vistorias, valor previsto em orçamento e o valor contratado. A topologia da rede utilizada está descrita no Quadro 6.1.


Quadro 6.1: Topologia da RNA / Previsão de Custos

Item topológico	Quantidade
Entradas	4
Camadas ocultas	1
Neurônio na camada oculta	8
Taxa de aprendizagem	0.5
Função de ativação	Sigmoide
Tipo de RNA	Perceptron Multicamadas
Algoritmo	Backpropagation

Fonte: (Autora, 2019).

Foram utilizadas 994 amostras para treinamento da Rede Neural. Foi obtido um erro percentual (MAPE) igual a 9,62 % (Apêndice B – Figura B1). A partir do valor do MAPE foi estabelecido um intervalo para cômputo da acurácia. Dos 994 valores referentes ao custo total das obras utilizados no treinamento da RNA, 878 ficaram dentro do intervalo estabelecido, ou seja, o modelo obteve uma acurácia de 88,33% na fase de treino. Na Figura 6.1 é apresentada uma visão geral dos conjuntos de valores dentro e fora do intervalo estabelecido.

Figura 6.1: Resultados do Treinamento da RNA para Previsão de Custo




Fonte: (Autora, 2019).

Na Figura 6.2 é apresentado um conjunto de amostras, a fim de que se possa entender melhor a relação entre os valores estimados e o intervalo de erro estabelecido para análise do modelo. Nas amostras apresentadas, verifica-se que os valores estimados que não pertencem ao

intervalo de erro encontram-se, no entanto, visivelmente próximos ao limite superior ou ao limite inferior.

Figura 6.2: Resultados do Treinamento da RNA para Previsão de Custo - Algumas Amostras



Fonte: (Autora, 2019).

O principal objetivo da fase de treinamento de uma RNA do tipo *perceptron* é encontrar as matrizes de pesos que minimizam o erro entre os valores reais e a saída da rede. Se as matrizes de pesos são conhecidas então o modelo neural pode ser aplicado a dados novos e consequentemente podem-se extrapolar os resultados. Tendo em vista esse fato, apresenta-se a seguir as matrizes de pesos obtidas no processo de treinamento para previsão de custo:

$$w_1 = \begin{bmatrix} 0,10 & 0,58 & -0,08 & 2,08 & 0,45 \\ 0,21 & 0,25 & 0,37 & 1,08 & 0,99 \\ -0,82 & 0,43 & 1,20 & -0,25 & 0,47 \\ 0,77 & 0,77 & 0,58 & -0,06 & 0,77 \\ -0,33 & -0,25 & 3,16 & 7,74 & -0,00 \\ 0,16 & -0,22 & 1,05 & 0,88 & 0,62 \\ 1,58 & -0,17 & -0,39 & 2,07 & -0,40 \\ 1,43 & 0,02 & 0,11 & 1,36 & -0,26 \end{bmatrix}$$

$$e \quad w_2 = [5,03 \quad 1,45 \quad 0,44 \quad -1,62 \quad -0,41 \quad 4,36 \quad 0,12 \quad 2,35 \quad 1,56],$$

em que w_1 são os pesos da primeira camada e w_2 da segunda camada. É importante notar que o número de linhas de w_1 corresponde ao número de neurônios da camada escondida, já o número de colunas é igual a quantidade de entradas mais 1 (bias). As dimensões de w_2 são


referentes a quantidade de variáveis de saída (linha) e ao número de neurônios da camada oculta mais 1 (colunas).

6.1.2 Teste da RNA para previsão de Custos

Utilizando as matrizes apresentadas anteriormente, realizou-se então o teste do modelo neural. Para a fase de teste da RNA foram separadas e utilizadas 100 novas amostras. Vale ressaltar que a escolha das amostras, tanto para o treino quanto para o teste foram escolhidos aleatoriamente.

O valor do MAPE encontrado na fase de teste foi de 9,14% (ver apêndice B – Figura B2) e assim, de modo análogo ao que foi feito no treinamento, estabeleceu-se um intervalo para verificação da acurácia do modelo. Ficaram inseridos nesse intervalo 90 amostras, ou seja, a acurácia na fase de teste foi de 90%. Na Figura 6.3 é possível verificar quais valores estimados ficaram dentro do intervalo e quais ficaram fora.

Figura 6.3: Resultados da Fase de Teste da RNA para Previsão de Custo



Fonte: (Autora, 2019).

Uma observação interessante a se fazer quando se observa a Figura 6.3 é que praticamente inexistem valores com grandes diferenças em relação aos limites de erro. Esse fato sugere que o modelo treinado possui forte “poder” de generalização.


6.1.3 Análise Estatística da Previsão de Custo

Nesta subseção uma análise estatística é apresentada considerando o cálculo do coeficiente de correlação de Pearson, as características das distribuições dos valores reais e dos valores de saída da rede e testes de hipótese.

Para a fase de treinamento, a correlação entre os valores de saída da rede e os valores medidos foi de 0,9921 e para fase de teste foi de 0,9912.

A análise de correlação é importante, pois demonstra o quanto as duas variáveis podem estar relacionadas por de uma reta. Na Figura 6.4, observa-se a relação entre as variáveis analisadas e a reta que melhor as aproxima, tanto para o treinamento quanto para o teste.

Figura 6.4: Correlação entre os valores medidos e a saída da RNA: A) Fase de Treinamento; B) Fase de Teste



Fonte: (Autora, 2019).


A alta correlação obtida tanto na fase de teste quanto no treinamento da rede significa que existe uma relação linear entre os valores reais e os obtidos pela rede. Esse fato corrobora com os resultados relacionados à pequena quantidade de valores fora do intervalo de erro.

O fato de existir uma relação linear entre os dados reais e os obtidos pela rede evidencia que para este caso em especial, além do erro percentual ser pequeno ainda existe uma relação de proporcionalidade entre as variáveis. Essa tendência indica que quando um valor real cresce (ou decresce) o resultado da rede também cresce (ou decresce). Essa análise é importante pois pode instigar novas pesquisas sobre modelos complementares a RNA (criar um modelo

híbrido), ou seja, utilizar a saída da RNA como entrada de outro modelo e assim melhorar os resultados.

Quanto ao “comportamento” em termos de distribuição, o *box plots* a seguir (Figura 6.5) mostram como os dados, tanto no treino quanto no teste da RNA estão distribuídos em torno na mediana.

Figura 6.5: Distribuição dos valores medidos e da saída da RNA para previsão de custo: A) Fase de Treinamento; B) Fase de Teste



Fonte: (Autora, 2019).

Com base nas distribuições apresentadas na Figura 6.5, pode-se tentar inferir e pressupor não haver “muita diferença” entre os conjuntos comparados na figura. Porém, é necessário mensurar e aplicar técnicas que evidenciem se existem ou não diferenças significativas entre os valores oriundos da RNA e os valores reais. Para cumprir esse objetivo, testes de hipótese foram aplicados. Primeiramente, foi realizado o teste de normalidade de *Kolmogorov-Smirnov* tanto nos valores de saída da rede quanto nos valores medidos nas duas fases que compõe a construção do modelo proposto (treinamento e teste).

Os resultados dos testes, em todos os conjuntos de dados apontaram para rejeição da hipótese nula (dados normais), com nível de significância de 5%. Como a hipótese nula foi rejeitada, ou seja, os dados não provêm de uma distribuição normal, resolveu-se aplicar o teste U de Mann-Whitney para verificação da existência ou não de diferenças significativas.

O teste U foi aplicado nos resultados obtidos na fase de treinamento e na fase de teste da RNA para o caso da previsão de custo. Na fase de treinamento, o teste estatístico mostrou que se deve, ao nível de significância de 5%, rejeitar a hipótese de que os valores de saída da

rede e os valores reais são amostras de distribuições com medianas iguais ($p\text{-valor} = 0,0307$). Já na fase de teste os resultados apontam para não rejeição dessa hipótese ($p\text{-valor} = 0,555$).

6.2 Previsão de Aditivo de Custo

A diferença entre o custo final da obra e o valor contratado define o aditivo de custo. A fim de prevê essa diferença foi utilizado um modelo neural em duas fases, a saber, treinamento e teste.

6.2.1 Treinamento da RNA para Previsão de Aditivo de Custos

Para treinar a RNA, a fim de prever os aditivos de custos de obras públicas, foram utilizados como variáveis de entrada a área a ser construída, quantidade de vistorias, valor previsto em orçamento, valor contratado e o tempo previsto para execução da obra. O Quadro 6.2 resume os valores referentes à topologia da rede utilizada nesta simulação.

Quadro 6.2: Topologia da RNA / Previsão de Aditivo de Custos


Item topológico	Quantidade
Entradas	5
Camadas ocultas	1
Neurônio na camada oculta	10
Taxa de aprendizagem	0,5
Função de ativação	Sigmoide
Tipo de RNA	Perceptron Multicamadas
Algoritmo	Backpropagation

Fonte: (Autora, 2019).

Nessas simulações, foram utilizadas 849 amostras para realização do treinamento. Foram excluídas as amostras referentes a valores correspondentes a valores superiores a 25% do valor contratado. O erro percentual (MAPE) entre os valores reais e os obtidos pela rede na fase de treinamento foi de 37,03% (ver apêndice B- Figura B3).

A quantidade de valores dentro dos limites estabelecidos foi igual a 614, ou seja, o percentual de assertividade (acurácia) foi de 72%. Na Figura 6.6, é apresentado um resumo gráfico do exposto nesse parágrafo.


Figura 6.6: Resultados do Treinamento da RNA para Previsão de Aditivo de Custo



Fonte: (Autora, 2019).

Devido à grande quantidade de dados apresentados através do gráfico que compõe a figura 6.6, uma visualização mais individualizada é apresentada na Figura 6.7.

Figura 6.7: Treinamento da RNA para Previsão de Aditivo de Custo – Algumas Amostras



Fonte: (Autora, 2019).

Como mencionado, é de extrema importância conhecer as matrizes de peso obtidas na fase de treinamento. Considerando esse fato, são apresentadas a seguir as matrizes de pesos sinápticos dos neurônios da RNA das camadas de entrada e da camada oculta.

$$w_1 = \begin{bmatrix} 0,96 & 0,28 & 0,20 & 0,29 & 0,05 & 0,16 \\ 0,14 & 0,39 & 0,49 & 0,03 & 0,38 & 1,29 \\ -0,22 & 1,91 & 0,24 & 0,66 & 1,07 & -0,32 \\ -0,03 & 1,23 & 0,84 & 0,80 & 0,58 & 0,45 \\ 0,18 & 2,92 & 0,84 & 1,38 & 1,21 & 0,44 \\ 0,75 & 0,85 & 0,22 & 0,32 & 0,21 & 0,96 \\ 0,56 & 0,53 & 0,47 & 0,27 & 0,53 & 0,24 \\ 0,78 & 0,33 & 0,01 & 1,02 & 0,99 & 0,42 \end{bmatrix}$$

e

$$w_2 = [2,24 \quad -0,10 \quad -1,08 \quad 1,14 \quad 0,25 \quad 1,88 \quad -0,88 \quad -0,19 \quad -0,07],$$

em que w_1 são os pesos da primeira camada e w_2 da segunda camada.


6.2.2 Teste da RNA para previsão de aditivo de custos

Os pesos w_1 e w_2 encontrados no treinamento da rede foram aplicados na mesma topologia em 80 novas amostras, a fim de testar o modelo neural estabelecido.

O valor do MAPE nessa fase (validação do modelo) foi de 29,34% (ver apêndice B – Figura B4). Com esse valor foram estabelecidos os limites superior e inferior do intervalo para cálculo da acurácia. A quantidade de dados pertencentes ao intervalo estabelecido foi de 63 amostras de um total de 80, ou seja, a assertividade foi de 78,75%.

Na Figura 6.8, é possível verificar quais dados estão dentro e fora dos limites estabelecidos com base no valor do MAPE e assim se ter uma idéia da assertividade do modelo com relação a novas amostras.

Figura 6.8: Resultados da Fase de Teste da RNA para Previsão de Aditivo de Custo



Fonte: (Autora, 2019).


O percentual de valores de aditivos de custo previstos pela RNA que ficaram de fora do intervalo estabelecido é, sobretudo, maior do que quando buscou-se estimar o valor total da obra. Porém, observa-se na figura 6.8 que os dados fora dos limites de erro mantiveram uma boa proximidade ao intervalo estabelecido. Essa constatação, mesmo que apenas visual incentiva a busca por um melhoramento do modelo, a fim de diminuir os erros.

6.2.3 Análise Estatística da Previsão de Aditivo de Custo

Com base nos valores obtidos a partir do modelo neural, tanto na fase de treino quanto na fase de teste, uma análise baseada em valores de correlação e testes de hipótese é apresentada nessa seção.

Os coeficientes de correlação de Pearson encontrados na fase de treino e teste foram de 0,89 e 0,86 respectivamente. Esses valores evidenciam que uma possível relação linear entre os valores de saída do modelo e os valores reais, pode não existir. Na Figura 6.9 observa-se o quanto os dados reais e os simulados se aproximam de uma reta. Verifica-se a partir da observação da Figura 6.9 que os dados não se concentram próximo da reta, corroborando com o que demonstra os valores de correlação calculados respectivamente (0,89 e 0,82).

Figura 6.9: Correlação entre os valores medidos e a saída da RNA para previsão de aditivo de custo: A) Fase de Treinamento; B) Fase de Teste




Fonte: (Autora, 2019).

Uma observação importante é que os resultados em termos de avaliação de erro percentual são ratificados quando observado em termos de correlação, pois essas duas grandezas tem apresentado um “comportamento” inversamente proporcional, ou seja, quanto maior o erro menor a correlação.

Os resultados obtidos tanto na fase de treino quando na fase de teste da RNA proposta para previsão do aditivo de custo aparentam não ter a mesma eficácia do modelo para prever o custo total. Porém, uma análise mais aprofundada pode ser necessária para verificar os motivos e as consequências de tal divergência.

Uma análise estatística com base em características das distribuições para as simulações de aditivo de custos também foi realizada. A seguir os *box plots* mostrando como os dados estão distribuídos em torno da mediana (Figura 6.10).

Figura 6.10: Distribuição dos valores medidos e da saída da RNA para previsão de aditivo de custo: A) Fase de Treinamento; B) Fase de Teste




Fonte: (Autora, 2019).

De modo semelhante ao que foi feito na previsão de custo, um teste t foi aplicado aos valores reais de aditivo e aos valores de saída da rede. O teste indicou a rejeição da hipótese nula, ou seja, os dados reais e os simulados não provêm de uma distribuição normal e por conta disso o teste U foi utilizado para verificação de diferenças entre os conjuntos de dados

Assim como na previsão de custo, na fase de treino o teste mostrou que se deve rejeitar, ao nível de significância de 5%, a hipótese de que os dados de saída da rede e os dados reais são amostras de uma distribuição com medianas iguais (p-valor = 0,00048). Na fase de teste não se teve evidência de que a hipótese nula deve ser rejeitada (p-valor = 0,69).

6.2.4 Estimativa do Valor Total da Obra com Base na Previsão de Aditivos de Custos

Os resultados de previsão de aditivos de custo obtidos através do modelo neuronal proposto culminaram em um erro percentual médio igual a 29% na validação do modelo. Esse valor, a princípio, parece ser bem elevado e de fato é observado apenas pela ótica de previsão de aditivos. Porém, quando se considera necessidade de estimar o valor total da obra (somando valor do aditivo previsto com valor contratado), percebe-se uma boa eficiência desse método. Um resumo do procedimento para estimar o custo total da obra tendo como base a saída da rede usada para previsão de aditivos é apresentado na Figura 6.11.



Fonte: (Autora, 2019).

Os resultados de previsão de aditivos de custo (de treino e de teste) apresentados na seção 6.2, foram utilizados para aplicação do método ilustrado na Figura 6.11. Essa combinação culminou em resultados importantes.

Na Tabela 4 constam os valores das principais métricas avaliativas no que tange a previsão de custo total da obra a partir dos valores de aditivos previstos pela RNA, cujo treinamento é descrito seção 6.2 (subseção 6.2.1).

Tabela 6.1: Resultados obtidos para dados de treinamento

Métrica	Valor
MAPE	5,97%
Assertividade	95,54%
Correlação - ρ	0,99

Fonte: (Autora, 2019).

Os Resultados obtidos na fase de teste da previsão de custo total da obra a partir dos valores de aditivos de custo estão apresentados na Tabela 5.

Tabela 6.2: Resultados obtidos para dados de teste

Métrica	Valor
MAPE	5,27%
Assertividade	96,25%
Correlação - ρ	0,99

Fonte: (Autora, 2019).

Ao observar os resultados apresentados nas Tabelas 6.1 e 6.2, percebe-se que os resultados de obtidos na previsão de aditivos de custo quando observados sob a ótica de estimativa de custos totais apresentam resultados relativamente melhores do que quando os resultados de previsão dos custos totais apresentados da seção 6.1.

6.3 Previsão do Tempo de Execução de Obras Públicas

O modelo de RNA apresentado nessa dissertação também foi testado na previsão do tempo de execução de obras públicas. Os valores a serem previsto referem-se ao total de semanas que a obra foi concluída.

6.3.1 Treinamento da RNA para Previsão Previsão do Tempo de Execução de Obras Públicas

No treinamento da RNA foram utilizadas cinco variáveis de entrada a área a ser construída, a quantidade de vistorias, o valor previsto em orçamento, o valor contratado e o tempo previsto para execução da obra (Quadro 6.3).


Quadro 6.3: Topologia da RNA / Previsão de Prazos

Item topológico	Quantidade
Entradas	5
Camadas ocultas	1
Neurônio na camada oculta	10
Taxa de aprendizagem	0.01
Função de ativação	Sigmoide
Tipo de RNA	Perceptron Multicamadas
Algoritmo	Backpropagation

Fonte: (Autora, 2019).

Na Figura 6.12 são apresentados os resultados da fase de treinamento da rede. Nessa fase foram utilizadas 789 amostras (de um total 849) e o erro percentual (MAPE) foi de 22,28 (ver apêndice B – Figura B5). Ficaram dentro do intervalo estabelecido pelo valor do MAPE um total de 595 amostras, o que implica em uma acurácia de 75,41%.


Figura 6.12: Resultados do Treinamento da RNA para Previsão do Tempo de Execução



Fonte: (Autora, 2019).

Assim como no treinamento dos modelos de previsão para custo e aditivo de custo um gráfico, com apenas algumas amostras de prazo, é apresentado na Figura 6.13. Esse gráfico tem como finalidade melhorar a compreensão dos resultados do treinamento.

Figura 6.13: Resultados do Treinamento da RNA para Previsão do Tempo de Execução da Obra - Algumas Amostras



Fonte: (Autora, 2019).

As matrizes de pesos sinápticos dos neurônios obtidas na fase de treinamento foram:

$$w_1 = \begin{bmatrix} 0,40 & 0,34 & 0,53 & 0,89 & 0,26 & 0,68 \\ 0,45 & 0,00 & 0,37 & 0,60 & 0,11 & 0,96 \\ 0,51 & 0,89 & 0,16 & -0,05 & 0,32 & 0,26 \\ 0,09 & 0,21 & 0,53 & 0,63 & 0,03 & 0,26 \\ 0,21 & 2,79 & 0,32 & 1,39 & 0,61 & 1,04 \\ 0,22 & 0,41 & 0,62 & 0,13 & 0,52 & 0,12 \\ 0,43 & -0,01 & 0,56 & 0,60 & 0,36 & 0,88 \\ 0,44 & 0,80 & 0,94 & 0,93 & 0,63 & 0,30 \\ 1,11 & 0,36 & 0,71 & -0,02 & 0,05 & 0,12 \\ 0,08 & 0,85 & 0,32 & 0,48 & 0,87 & 0,74 \end{bmatrix}$$

e


$$w_2 = [1,80 \quad -0,00 \quad 0,18 \quad -0,15 \quad -0,50 \quad 2,06 \quad -0,60 \quad 0,38 \quad -0,13 \quad 0,32 \quad 0,02],$$

em que w_1 são os pesos da primeira camada e w_2 da segunda camada.

6.3.2 Teste da RNA para Previsão do Tempo de Execução de Obras Públicas

Tendo em vista a convergência do algoritmo para os pesos ótimos, realizou-se então a fase de teste. Nessa fase, foram utilizadas 60 amostras restantes (do total de 849) diferentes das utilizadas no treino. O valor do MAPE nessa fase foi de 19,3% (ver apêndice B – Figura B6). Um total de 43 valores previstos ficaram dentro do intervalo proposto com o MAPE, ou seja, a acurácia foi de 71,67%. Na Figura 6.14 é possível verificar quais amostras ficaram fora e quais ficaram no intervalo estabelecido.

Figura 6.14: Resultados da Fase de Teste da RNA para Previsão do Tempo de Execução da Obra



Fonte: (Autora, 2019).


Vale ressaltar que mesmo os valores classificados fora do intervalo estabelecido pelos valores de MAPE encontram-se próximos ao limite superior ou inferior (Figura 6.13). Esse fato demonstra que o modelo não apresenta como resultado valores que possam comprometer sua utilização prática.

6.3.3 Análise Estatística da Previsão de Prazo

Nessa seção duas técnicas estatísticas foram aplicadas aos resultados de treino e teste. Na primeira, o cálculo do coeficiente de correlação de Pearson foi realizado e na segunda, testes de hipótese foram aplicados.

Quanto à correlação, observou-se que na fase de treino, o coeficiente de correlação de Pearson entre os valores reais e os obtidos pela rede foi de 0,59. Já na fase de teste, esse coeficiente foi de 0,71. Na Figura 6.15 é possível observar os gráficos de dispersão, tanto para o treino quanto para o teste.

Figura 6.15: Correlação entre os valores medidos e a saída da RNA para previsão de Prazo: A) Fase de Treinamento; B) Fase de Teste



Fonte: (Autora, 2019).


Nestes gráficos da Figura 6.15, verifica-se a possibilidade de aproximação à uma reta. É possível perceber uma “forte” dispersão dos dados e assim uma “fraca” aproximação da melhor reta de aproximação.

Quando os testes estatísticos foram aplicados aos resultados de saída da rede para previsão de prazo, verificou-se que os dados reais e os de saída da rede não se originam em uma distribuição normal. Por esse motivo o teste U foi aplicado para verificar se existem diferenças significativas entre os valores reais e os obtidos com o modelo neural.

Quando aplicado o teste U obteve-se como resultado para a fase de treinamento a rejeição da hipótese nula (os dados têm origem em distribuições com medianas iguais) com $p\text{-valor} = 0,0166$ e nível de significância de 5%.

Já na fase de validação o teste U indicou que a hipótese nula não deve ser rejeitada ($p\text{-valor} = 0,6347$). As distribuições em torno da mediana para esse caso estão expressas na Figura 6.16.

Figura 6.16: Distribuição dos valores medidos e da saída da RNA para previsão de prazo: A) Fase de Treinamento; B) Fase de Teste



Fonte: (Autora, 2019).

As análises estatísticas realizadas através dos *boxplot's* e dos testes de hipótese aplicados tem sua importância, pois expressam quantitativamente as pequenas diferenças entre os valores reais e os obtidos nos modelos apresentados. Essas análises reforçaram os resultados analisados quando os valores do MAPE e correlação foram observados.

6.4 Previsão de Aditivo de Prazo

6.4.1 Treinamento da RNA para previsão de Aditivos de Prazo

No treinamento do modelo neural para previsão de aditivos de prazo, utilizou-se como entrada da rede, a área a ser construída, a quantidade de vistorias, o valor previsto em orçamento, o valor contratado e o tempo previsto para execução da obra. O Quadro 6.4 descreve os valores dos parâmetros da topológicas da rede utilizada.


Quadro 6.4: Topologia da RNA / Previsão de Aditivo de Prazo

Item topológico	Quantidade
Entradas	5
Camadas ocultas	1
Neurônio na camada oculta	8
Taxa de aprendizagem	0.1
Função de ativação	Sigmoide
Tipo de RNA	Perceptron Multicamadas
Algoritmo	Backpropagation

Fonte: (Autora, 2019).

Utilizou-se um total de de 789 amostras na fase de treinamento, o erro percentual médio (MAPE) entre as amostras e os valores obtidos pelo modelo foi de 39,99% (ver apêndice B – Figura B7). Como nos experimento anteriores, definiu-se então o intervalo de acrtividade (Figura 6.17).


Figura 6.17: Resultados da fase de treinamento da previsão de aditivos de prazo



Fonte: (Autora, 2019).

Tendo em vista que a grande quantidade de amostras dificulta a visualização e compreensão da Figura 6.17, é apresentado então na Figura 6.18 apenas algumas amostras a fim de melhorar a compreensão.

Figura 6.18: Resultados para algumas amostras da fase de treino



Fonte: (Autora, 2019).

Percebe-se observando a Figura 6.18 que poucas amostras ficam, inicialmente, de fora do intervalo. No entanto, esse comportamento não se repete em termos gerais pois 221 amostras de 789 ficam fora do intervalo e consequentemente 568 dentro do mesmo. Sendo assim, o percentual de assertividade foi de 71,99.

As matrizes de pesos obtidas na fase de treinamento foram:

$$w_1 = \begin{bmatrix} 0,96 & 0,28 & 0,20 & 0,29 & 0,05 & 0,16 \\ 0,14 & 0,39 & 0,49 & 0,03 & 0,38 & 1,29 \\ -0,22 & 1,91 & 0,24 & 0,66 & 1,07 & -0,32 \\ -0,03 & 1,23 & 0,84 & 0,80 & 0,58 & 0,45 \\ 0,18 & 2,92 & 0,84 & 1,38 & 1,21 & 0,44 \\ 0,75 & 0,85 & 0,22 & 0,32 & 0,21 & 0,96 \\ 0,56 & 0,53 & 0,47 & 0,27 & 0,53 & 0,24 \\ 0,78 & 0,33 & 0,01 & 1,02 & 0,99 & 0,42 \end{bmatrix}$$


e $w_2 = [2,24 \quad -0,10 \quad -1,08 \quad 1,14 \quad 0,25 \quad 1,88 \quad -0,88 \quad -0,19 \quad -0,07].$

Vale ressaltar que obter essas matrizes é o principal objetivo da fase de treino.

6.4.2 Teste da RNA para previsão de Aditivos de Prazo

Após se obter, na fase de treino, as matrizes de pesos sinápticos, as mesmas são utilizadas para testar novos valores, ou seja, é realizada a validação do modelo neural. A essa validação dar-se o nome de fase de teste. Na fase de teste foram utilizadas 60 novas amostras e o erro entre esses valores e o previsto pela rede foi de 39,36% (ver apêndice B – Figura B8). De modo análogo ao que foi feito nos demais teste, estabeleceu-se um intervalo baseado no erro percentual e verificou-se que das 60 amostras 45 ficaram dentro desse intervalo, o equivalente a 75% de acurácia. A Figura 6.19 demonstra quais os valores previstos que ficaram no interior e no exterior do intervalo estabelecido.

Figura 6.19: Resultados da fase de teste para previsão de aditivos de prazos




Fonte: (Autora, 2019).

6.4.3 Análise Estatística da Previsão de Aditivos de Prazo

Além da análise em termos de erro e acurácia também foram realizadas observações considerando técnicas da estatística descritiva e inferencial. A Figura 6.20, por exemplo, demonstra como os valores reais e os obtidos pela rede estão correlacionados.

Figura 6.20: Relação entre os valores reais e a saída da rede: A) Fase de treino B) Fase de teste




Fonte: (Autora, 2019).

Para uma melhor compreensão da Figura 6.20 foram calculados os coeficientes de correlação. Para a fase de treinamento, o coeficiente de correlação de Pearson foi de 44,16 e para o teste de 38,45, o que demonstra uma fraca correlação entre os valores analisados. Esses valores de correlação corroboram com o erro encontrado, pois este se mostrou elevado e pode representar uma deficiência do modelo para previsão de prazos.

Em termos de distribuição e comparação entre medianas, percebe-se na Figura 6.21 que graficamente as diferenças entre os grupos em análise são pequenas, porém a dispersão entre o máximo e o mínimo é sempre maior nos valores reais. Na Figura 6.21 consta os *box plots* com

as distribuições em torno da mediana dos valores reais e obtidos com o modelo, tanto para a fase de treino quanto para fase de teste.

Figura 6.21: Box plot com valores reais e simulados: A) Fase de treino; B) Fase de teste




Fonte: (Autora, 2019).

Afim de quantificar as possíveis diferenças entre os dados apresentados na Figura 6.21 alguns testes de hipótese foram realizados. Primeiramente aplicou-se o teste de normalidade e observou-se que os valores não provêm de uma distribuição normal. Após verificar esse fato o teste U foi aplicado e constatou-se que os resultados da fase de treino apresentaram diferenças significativas entre as medianas dos valores reais e os do modelo ($p\text{-valor} = 0,0011$). Porém, para fase de validação do modelo o teste U apontou não haver diferenças significativas, em termos de mediana, entre valor real e valor simulado ($p\text{-valor} = 0,2323$).

6.4.4 Estimativa de Prazo final da Obra com Base na Previsão de Aditivos de Prazos

De maneira análoga ao que foi feito com aditivos de custo, nessa subseção estão apresentados os resultados da aplicação do modelo de estimação do prazo final com base nos valores de aditivos de prazos obtidos no respectivo modelo neural treinado e testado na seção 6.4. Na Figura 6.22 consta o esquema utilizado para obter os valores de prazos finais tendo como núcleo a RNA treinada e testada para prever os aditivos de prazos.

Figura 6.22: Sistema de estimação de prazo com base no aditivo de prazo



Fonte: (Autora, 2019).

O método ilustrado na Figura 6.22 foi aplicado utilizando os valores obtidos na previsão de aditivos de prazo (de treino e de teste) apresentados na seção 6.4. Na Tabela 6.3 constam os valores das principais métricas avaliativas no que tange a previsão de prazo final de execução da obra a partir dos valores de aditivos previstos pela RNA, cujo treinamento é descrito seção 6.4 (subseção 6.4.1).

Tabela 6.3: Resultados obtidos para dados de treinamento (prazo final de execução)

Métrica	Valor
MAPE	21,50%
Assertividade	74,90%
Correlação - ρ	0,60

Fonte: (Autora, 2019).

Os Resultados obtidos quando os dados previstos para aditivos de prazo na fase de teste referentes às simulações da seção 6.4 (subseção 6.4.2) estão apresentados na Tabela 6.4.

Tabela 6.4: Resultados obtidos para dados de teste (prazo final de execução)


Métrica	Valor
MAPE	22,49%
Assertividade	78,33%
Correlação - ρ	0,63

Fonte: (Autora, 2019).

Nota-se que o sistema para prever prazo final tendo em vista que o aditivo de prazo já tenha sido previsto pela rede não difere muito do modelo neural utilizado na previsão de prazo treinado e testado na seção 6.3. Esses resultados evidenciam que a previsão de prazos e aditivos de prazos de obras públicas em especial apresenta-se como um desafio importante no contexto da engenharia civil. Esse desafio perpassa pela melhor escolha de variáveis e ainda melhor modelo a ser utilizado.

Foi verificada a existência ou não de correlação entre os valores de custo e de prazo. O coeficiente de correlação de Pearson foi calculado e a hipótese de haver ou não correlação foi testada a um nível de significância de 5%. Verificou-se então que o coeficiente de correlação entre custo e prazo foi de 0,34 e um p-valor igual a $2,4 \cdot 10^{-5}$, o que demonstra haver correlação significativa. Na Figura 6.23 consta a relação Custo versus Prazos.

Figura 6.23:Relação entre Custos e Prazos



Fonte: (Autora, 2019).

Como pode observar-se na Figura 6.23, a correlação é caracterizada como leve, mas apresenta um alto nível de significância estatística, cabe ressaltar que esta correlação indica que existem outros fatores que podem influenciar na relação entre o custo e prazo final da obra, não existindo um determinismo simples entre as alterações de prazo nos empreendimentos (aditivos) e um consequente aumento do custo na mesma proporção. Isso é bastante relevante, pois deixa claro que o assunto ainda apresenta oportunidade de pesquisa na área, onde se deve aprofundar o entendimento sobre as causas de atrasos e a reflexo no custo final das obras.

7 CONSIDERAÇÕES FINAIS E SUGESTÕES PARA NOVAS PESQUISAS

7.1 Considerações Finais

O sucesso das construções, em geral, depende da eficácia de um bom planejamento. Em obras públicas, no entanto, os planejamentos têm se mostrado deficitários, principalmente em países emergentes. Nesse contexto, tem-se percebido que um dos fatores que colabora para que o planejamento da obra não seja cumprido em sua totalidade é a falta de mecanismos capazes de prever o valor final da obra, bem como o prazo final, nascendo assim a necessidade de aditivos.

A fim de realizar previsão de custos e prazos de execução de obras públicas é que nesse trabalho foram utilizados modelos computacionais baseados no funcionamento de neurônios, e assim colaborar com o planejamento de empreendimentos. Diversas topologias de RNA's foram testadas e os resultados apresentados através de métricas estatísticas de avaliação.

O modelo neural utilizado na previsão de custo obteve um aprendizado que ao quando aplicado em novas amostras resultou em um erro percentual de 9,14%. Esse resultado demonstra que a utilização de inteligência artificial nesse tipo de problema pode ajudar no planejamento de obras públicas.

Quando a tarefa foi estimar os valores de aditivos de custo os percentuais de erro já não foram tão baixos, pois foram próximos aos 30%. Esses resultados poderiam indicar uma deficiência do modelo em prever aditivos de custo. Porém, quando se combinou a previsão de adito de custo com a previsão de custo final verificou-se que o modelo de previsão de custo total foi melhorado e os resultados reduzidos a erros de 5%.

Esses percentuais de erro de previsão de custos de obras públicas são animadores e demonstram que nessa pesquisa consta uma contribuição importante quanto a propostas de modelos de previsão de custos, pois segundo Hyari; Al-Daraiseh; El-Mashaleh (2016) a estimativa conceitual de custos, através de métodos tradicionais, está inerentemente associada a um alto erro percentual, normalmente na faixa compreendida entre 20,8 e 27,9%.

Para fins de comparação, pode-se observar os resultados obtidos por Hyari; Al-Daraiseh; El-Mashaleh (2016) que em um trabalho semelhante a essa pesquisa aplicaram um modelo neural para previsão de custos e obtiveram 28,2% de MAPE (fase de teste). No entanto, é importante observar uma diferença importante entre o trabalho de Hyari; Al-Daraiseh; El-Mashaleh (2016) e esta pesquisa. Essa diferença consiste na quantidade de valores disponíveis

para treinamento da rede, pois é conhecido que o desempenho das RNA's aumenta de acordo com a quantidade de amostras de treinamento. Ou seja, como a quantidade de amostras utilizadas nessa pesquisa é bem maior do que as utilizadas por Hyari; Al-Daraiseh; El-Mashaleh (2016) é de se esperar que os resultados aqui apresentados (para previsão de custos) sejam melhores.

Tendo em vista que as matrizes de pesos foram disponibilizadas no texto torna-se possível a implementação do modelo em *softwares* mais populares como, por exemplo, o *Microsoft Excel*, e assim possibilitar que profissionais da engenharia (mesmo sem conhecimento sobre RNA's) possam utilizar em sua prática profissional o modelo de previsão, desde que disponham das informações de entrada da rede. Além disso, o algoritmo disponível no Apêndice A também pode ser “embarcado” em dispositivos eletrônicos como computadores e celulares facilitando assim o uso do modelo neural proposto nessa pesquisa.

Além da contribuição em termos de proposição de um modelo que minimiza os erros de previsão, esse trabalho também colabora com a prática profissional da engenharia, no que tange a fase de planejamento de obras públicas, quando possibilita que a previsão de custo possa ser realizada na prática.

Quando a tarefa foi realizar previsão de prazos os modelos neurais não apresentaram resultados tão bons quanto na previsão de custos. Para essa tarefa o modelo apresentou um aprendizado importante e promissor, porém aquém do que já se conhece na literatura. Os erros de previsão de prazos na fase de testes, por exemplo, foram de aproximadamente 20%. Esse fato pode indicar que esse modelo ainda precisa ser melhorado testando novas topologias de rede ou ainda inserindo novas entradas, como por exemplo, características dos locais onde o empreendimento foi construído.

A título de comparação, observa-se no trabalho de Maués (2017) que o modelo Fuzzy conseguiu prever prazo com erro percentual médio de 6,83 %. Esse valor de erro é notoriamente menor do que os 20% obtidos com o modelo neural testado nessa pesquisa. No entanto, é importante salientar que os dados utilizados por Maués (2017) têm informações diferentes dos utilizados nessa pesquisa, ou seja, não se pode garantir que a diferença entre os resultados obtidos é consequência apenas da eficiência (ou deficiência) dos modelos comparados.

Sobre a previsão de aditivos de prazos pode-se afirmar que tal tarefa apresentou o maior desafio para metodologia proposta através de RNA. Os resultados dos testes apresentaram erros percentuais de aproximadamente 40%, o que demonstra a dificuldade do modelo em aprender os padrões referentes aos aditivos de prazo. Nesse contexto, pode-se afirmar que esse problema

(previsão de aditivos de prazo) é importante do ponto de vista computacional e pode instigar novas pesquisas

Em resumo, fica evidente que a técnica de modelagem baseada em RNA foi mais eficaz para previsão de custos do que para prazos, pois o modelo de previsão de custos apresentou erros percentuais médios próximos a 9% e 5%, enquanto que o de previsão de aditivos prazos culminou em erros de aproximadamente 40%. Além disso a proposta de previsão de custo possibilita duas contribuições importantes no tratamento dessa problemática, a saber, a redução do erro percentual de previsão (em média) e a possibilidade de utilização prática do modelo através das matrizes e algoritmos disponíveis no trabalho.

7.2 Sugestões para novas pesquisas

A realização desse trabalho permitiu que alguns questionamentos fossem levantados e consequentemente algumas lacunas fossem identificadas. Esses questionamentos e lacunas podem servir como ponto de partida para pesquisas futuras, tais como:

- Aplicar o modelo neural em outros tipos de empreendimentos, como por exemplo, obras privadas.
- Melhorar o modelo de previsão de prazos e aditivos de prazos através do uso de outros tipos de rede neural, como por exemplo, redes Convolucionais.
- Embarcar o modelo de previsão de custos em um aplicativo a fim de facilitar seu uso no dia a dia dos profissionais ligados ao planejamento de obras.
- Utilizar RNA para prever índices relacionados a construção civil, como preços de materiais, mão de obras e etc.
- Utilizar modelos neurais para auxiliar na prevenção de acidentes e melhorar a segurança no canteiro de obras.

8 REFERÊNCIAS

- ABIODUN, O. I. et al. State-of-the-art in artificial neural network applications: A survey. **Heliyon**, v. 4, n. 11, p. 938, 2018.
- AHMADU, H. A. et al. Modelling building construction durations. **Journal of Financial Management of Property and Construction**, v. 20, n. 1, p. 65–84, 2015.
- AL-GBURI, M.; JONASSON, J.; NILSSON, M. Prediction of restraint in second cast sections of concrete culverts using artificial neural networks. **Journal of Environmental and Civil Engineering**, v. 8189, n. May, 2016.
- ALJOHANI, A. Construction Projects Cost Overrun: What Does the Literature Tell Us? **International Journal of Innovation, Management and Technology**, v. 8, n. 2, p. 137–143, 2017.
- ALVARENGA, F. C. **Análise das causas de aditivos de custo e de prazo em obras públicas de instituições federais de ensino**. [s.l.] Universidade Federal do Maranhão, 2019.
- ARMELLINI, V. **Modelagem e Simulação do Processo de Absorção Reativa de CO₂ em Módulos de Membrana**. 2010.
- ASSAF, S. A.; AL-HEJJI, S. Causes of delay in large construction projects. **International Journal of Project Management**, v. 24, n. 4, p. 349–357, 2006.
- ASTERIS, P. G. et al. Prediction of self-compacting concrete strength using artificial neural networks. **European Journal of Environmental and Civil Engineering**, v. 8189, n. November, p. 1–21, 2016.
- ATTAL, A. **Development of Neural Network Models for Prediction of Highway Construction Cost and Project Duration**. n. 45, p. 39, 2010.
- AYRES, M. **Elementos de Bioestatística: A Seiva do Açaizeiro**. 2 ed. ed. Belém: [s.n.], 2012.
- BAGAYA, O.; SONG, J. Empirical study of factors influencing schedule delays of public construction projects in Burkina Faso. **Journal of Management in Engineering**, v. 32, n. 5, 2016.
- BASSANEZI, R.; FERREIRA, W. **Equações Diferenciais com Aplicações**. São Paulo: Harbra, 1988.
- BATISTA, C. F. B. **Soluções de Equações Diferenciais Usando Redes Neurais de Múltiplas camadas com os métodos da Descida mais íngreme e Levenberg-Marquardt**. [s.l.] Universidade Federal do Pará, 2012.
- BRASIL. **Lei nº 8666, de 21 de junho de 1993**. Institui normas para licitações e contratos da Administração Pública, e dá outras providências. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/l8666cons.htm>. Acesso em: 23 agosto.

2019.

BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. **Neurociências: Desvendando o Sistema Nervoso**. 2. ed. [s.l: s.n.], 2002.

BECKER, J. L. **Estatística básica: transformando dados em informação**. [s.l.] Bookman editora, 2015.

BEJO, S.; MUSTAFFHA, S.; WAN ISMAIL, W. Application of artificial neural network in predicting crop yield: a review. **Journal of Food Science and Engineering**, v. 4, n. 1, p. 1–9, 2014.

BELALIA, O. et al. Prediction of properties of self-compacting concrete containing fly ash using artificial neural network. **Neural Computing and Applications**, v. 28, n. s1, p. 707–718, 2017.

BIEMBENGUT, M. S. Matemática na Educação Básica. **Conceptions and tendencies of mathematical modelling in Basic Education**. p. 118–138, 2012.

BOLFARINE, H.; SANDOVAL, M. C. **Introdução à inferência estatística**. [s.l.] SBM, 2001. v. 2

BOYD, S. **Convex optimization theory**. [s.l: s.n.]. v. 25

BUCCIOL, A.; CHILLEMI, O.; PALAZZI, G. Cost overrun and auction format in small size public works. **European Journal of Political Economy**, v. 30, p. 35–42, 2013.

BUSSAB, W. DE O.; MORETTIN, P. A. **Estatística Básica**. 5 ed. ed. São Paulo: [s.n.], 2003.

CHANG, A. S. T. Reasons for cost and schedule increase for engineering design projects. **Journal of Management in Engineering**, v. 18, n. 1, p. 29–36, 2002.

CHENG, Y. M. An exploration into cost-influencing factors on construction projects. **International Journal of Project Management**, v. 32, n. 5, p. 850–860, 2014.

DOGAN, G.; ARSLAN, M. H.; CEYLAN, M. Statistical Feature Extraction Based on an ANN Approach For Estimating the Compressive Strength of Concrete. **Neural Network World** 2015.

DOLOI, H. et al. Analysing factors affecting delays in Indian construction projects. **International Journal of Project Management**, v. 30, n. 4, p. 479–489, 2012.

DOLOI, H. Cost Overruns and Failure in Project Management: Understanding the Roles of Key Stakeholders in Construction Projects. **Journal of construction engineering and management**, v. 137, n. 2, p. 1–12, 2013.

ELHAG, T. M. S.; BOUSSABAIN, A. H.; BALLAL, T. M. A. Critical determinants of construction tendering costs: Quantity surveyors' standpoint. **International Journal of Project Management**, v. 23, n. 7, p. 538–545, 2005.

FAMIYEH, S. et al. Major causes of construction time and cost overruns: A case of selected educational sector projects in Ghana. **Journal of Engineering, Design and Technology**, v. 15, n. 2, p. 181–198, 2017.

FARIDI, A. S.; EL-SAYEGH, S. M. Significant factors causing delay in the UAE construction industry. **Construction Management and Economics**, v. 24, n. 11, p. 1167–1176, 2006.

FILIPPI, G. A. DE; MELHADO, S. B. Um estudo sobre as causas de atrasos de obras de empreendimentos imobiliários na região Metropolitana de São Paulo. **Ambiente Construído**, v. 15, p. 161–173, 2015.

GERAL, D. Manual de Licitações e Contratos de Obras Públicas. 2009.

GIL, A. C. **Métodos e Técnicas de Pesquisa Social**. 6ª ed. São Paulo: [s.n.]. v. 10, 2008.

GUNDUZ, M.; NIELSEN, Y.; OZDEMIR, M. Fuzzy assessment model to estimate the probability of delay in Turkish construction projects. **Journal of Management in Engineering**, v. 31, n. 4, 2015.

HARRIS, E.; NIRANJAN, M.; HARE, J. A Biologically Inspired Visual Working Memory for Deep Networks. p. 1–22, 2019.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2 ed. ed. Porto Alegre: Bookman, 2001.

HINTON, G. E.; OSINDERO, S.; TEH, Y.-W. A Fast Learning Algorithm for Deep Belief Nets. **Communicated by Yann Le Cun**, v. 425, n. 3, p. 2069–2082, 2006.

HINTON, G. E.; SALAKHUTDINOV, R. R. Reducing the Dimensionality of Data with Neural Networks. **Science**, v. 313, n. July, p. 504–507, 2006.

HWANG, S. et al. Automated time-series cost forecasting system for construction materials. **Journal of Construction Engineering and Management**, v. 138, n. 11, p. 1259–1269, 2012.

HYARI, K. H.; AL-DARASEH, A.; EL-MASHALEH, M. Conceptual Cost Estimation Model for Engineering Services in Public Construction Projects. **Journal of Management in Engineering**, v. 32, n. 1, p. 1–9, 2016.

KALIBA, C.; MUYYA, M.; MUMBA, K. Cost escalation and schedule delays in road construction projects in Zambia. **International Journal of Project Management**, v. 27, n. 5, p. 522–531, 2009.

KAMING, P. F. et al. Factors influencing construction time and cost overruns on high-rise projects in Indonesia. **Construction Management and Economics**, v. 15, n. 1, p. 83–94, 1997.

KAVUMA, A.; OCK, J.; JANG, H. Factors influencing Time and Cost Overruns on Freeform Construction Projects. **KSCE Journal of Civil Engineering**, v. 23, n. 4, p. 1442–1450, 2019.

KHASHMAN, A.; AKPINAR, P. ScienceDirect Non-Destructive Prediction of Concrete Compressive Strength Using Neural Networks Prediction of Concrete Compressive Strength

Using Neural Networks. **Procedia Computer Science**, v. 108, n. June, p. 2358–2362, 2017.

LU, P.; CHEN, S.; ZHENG, Y. Artificial Intelligence in Civil Engineering. v. 2012, p. 1–23, 2012.

LU, Y.; LUO, X. Y.; ZHANG, H. A gene expression programming algorithm for highway construction cost prediction problems. **Jiaotong Yunshu Xitong Gongcheng Yu Xinxin/Journal of Transportation Systems Engineering and Information Technology**, v. 11, n. 6, p. 85–92, 2011.

LUZ, G. **Introdução a Redes Neurais Artificiais – Parte 1**, 2018. Disponível em: <<http://mundoia.com.br/ia/introducao-a-redes-neurais-artificiais-parte-1/>>. Acesso em: 29 ago. 2019.

MAHAMID, I. Critical Determinants of Public Construction Tendering Costs. **International Journal of Architecture, Engineering and Construction**, v. 7, n. 1, 2018.

MALLELA, U. K.; UPADHYAY, A. Thin-Walled Structures Buckling load prediction of laminated composite stiffened panels subjected to in-plane shear using artificial neural networks. **Thin Walled Structures**, v. 102, p. 158–164, 2016.

MAUÉS, M. L. **Modelo para Estimar o Prazo de Execução de Obras Residenciais Verticais - Por meio da Lógica Fuzzy**. Programa de Pós-Graduação em Engenharia Civil-Universidade Federal do Pará, 2017.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity (reprinted from bulletin of mathematical biophysics, vol 5, pg 115-133, 1943). **Bulletin of Mathematical Biology**, v. 52, n. 1--2, p. 99–115, 1990.

MINSKY, M.; PAPERT, S. A. Perceptrons: An introduction to computational geometry. [s.l: s.n.], 2017.

MONTEIRO, M. O. **Processos de Obras De Infra-Estruturas Viárias Municipais: Uma Análise dos Desvios de Custo e de Prazo**. n. December 2015, p. 180, 2010.

MOON, T.; SHIN, D. H. Forecasting Construction Cost Index Using Interrupted Time-Series. **KSCE Journal of Civil Engineering**, v. 22, n. 5, p. 1626–1633, 2018.

NAGHETTINI, M.; PINTO, E. J. DE A. **Hidrologia estatística**. [s.l.] CPRM, 2007.

NG, S. T. et al. The predictive ability of Bromilow ' s time # cost model The predictive ability of Bromilow ' s time – cost model. v. 6193, n. August 2014, p. 37–41, 2010.

OPENSTAX. **Neurons and Glial Cells**. Disponível em: <https://cnx.org/contents/GFy_h8cu@9.87:c9j4p0aj@3/Neurons-and-Glial-Cells#figch35_01_03>. Acesso em: 29 ago. 2019.

OYEGOKE, A. S.; AL KIYUMI, N. The causes, impacts and mitigations of delay in megaprojects in the Sultanate of Oman. **Journal of Financial Management of Property and Construction**, v. 22, n. 3, p. 286–302, 2017.

PETRUSEVA, S.; ZUJO, V.; ZILESKA-PANCOVSKA, V. Neural network prediction model for construction project duration. **International Journal of Engineering Research & Technology**, v. 2, n. 11, p. 1646–1654, 2013.

PRAÇA, F. S. G. Metodologia da pesquisa científica: Organização estrutural e os desafios para redigir o trabalho de conclusão. **Revista Eletrônica Diálogos Acadêmicos**, v. 08, n. 1, p. 72–87, 2015.

PROVDANOV, C. C.; FREITAS, E. C. DE. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. 2ª edição. Editora Feevale, 2013.

RIBEIRO, A. V. F. Laureate International Universities. **Technology**, n. 10, p. 1–4, 2012.

ROCHA, P. L. **Reconhecimento de Voz utilizando Seleção Dinâmica de Redes Neurais**. [s.l.] Universidade Federal do Maranhão, 2018.

ROSENBLATT, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. **Psychological Review**, v. 65, n. 6, p. 1–23, 1958.

SANTOS, P. H.; STARLING C. M. D.; ANDERY, P. R. P. Estudo Introdutório sobre Aditivos Contratuais em Obras Públicas de Edificações de Âmbito Municipal. **Construindo**, v.06, n.02, 2014.

SHAHANDASHTI, S. M.; ASHURI, B. Forecasting engineering news-record construction cost index using multivariate time series models. **Journal of Construction Engineering and Management**, v. 139, n. 9, p. 1237–1243, 2013.

SHAHANDASHTI, S. M.; ASHURI, B. Highway Construction Cost Forecasting Using Vector Error Correction Models. **Journal of Management in Engineering**, v. 32, n. 2, p. 1–8, 2016.

SILVA, I. N.; SPATTI, D.; FLAUZINO, R. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático**. 2 ed. ed. [s.l: s.n.], 2016.

SRI, C. et al. Structural damage identification based on autoencoder neural networks and deep learning. **Engineering Structures**, v. 172, n. May, p. 13–28, 2018.

SWEIS, G. et al. Delays in construction projects: The case of Jordan. **International Journal of Project Management**, v. 26, n. 6, p. 665–674, 2008.

TCU-TRIBUNAL, D.C.D.U. (2013). **Obras Públicas: Recomendações Básicas para a Contratação e Fiscalização de Obras de Edificações Públicas**. Brasília.

TEREZA, M. et al. Gerenciamento de obras públicas. **Texto para discussão / Instituto de Pesquisa Econômica Aplicada**, p. 74, 2017.

UGUR, L. O. A Neuro-Adaptive Learning (NAL) Approach about Costs of Residential Buildings. v. 132, n. 3, p. 585–587, 2017.

VAHID, S. et al. Prediction of the durability of limestone aggregates using computational

techniques. **Neural Computing and Applications**, v. 29, n. 2, p. 423–433, 2018.

VAKHARIA, V.; GUJAR, R. Prediction of compressive strength and portland cement composition using cross-validation and feature ranking techniques. **Construction and Building Materials**, v. 225, p. 292–301, 2019.

WANJARI, S. P.; DOBARIYA, G. Identifying factors causing cost overrun of the construction projects in India. **Sadhana - Academy Proceedings in Engineering Sciences**, v. 41, n. 6, p. 679–693, 2016.

WIDROW, B.; HOFF, M. E. Adaptive Switching Circuit. **Technical Report**, v. 1553, 1960.

YANG, J. BIN; YANG, C. C.; KAO, C. K. Evaluating schedule delay causes for private participating public construction works under the Build-Operate-Transfer model. **International Journal of Project Management**, v. 28, n. 6, p. 569–579, 2010.

YUAN, Y. Step-sizes for the gradient method. **AMS IP Studies in advance Mathematics**, p. 785–796, 2008.

ZANELLA, L. C. H. **Metodologia de Pesquisa 2013 2ª edição reimpressa**. [s.l: s.n.].

ZHANG, R. et al. Forecasting Construction Cost Index based on visibility graph: A network approach. **Physica A: Statistical Mechanics and its Applications**, v. 493, p. 239–252, 2018.

ZHU, W.; FENG, W. **The application of genetic fuzzy neural network in project cost estimate**. n. 2007, p. 2–5, 2010.

Apêndice A: Código em Matlab para treinamento e teste da RNA utilizada

```

clear; clc
% Variáveis da matriz simulacao_custo_prazo.txt
% 1-Qtde de Vistorias
% 2-Área
% 3-Valor Previsto
% 4-Valor Contratado
% 5-Valor Final
% 6-Aditivo de Custo
% 7-Tempo Previsto (meses)
% 8-Tempo Real (meses)
% 9-Aditivo de Prazo (meses)

%Variáveis para a Fase de Treinamento
DADOS=load('simulacao_custo_prazo.txt');
%load('dados_bdi.mat');
%Dados=dados_bdi;
Dados=[DADOS(:,1:4) DADOS(:,7) DADOS(:,9)];
%Dados(:,5)=Dados(:,5)-Dados(:,3);
AB=max(Dados);
AC=min(Dados);
[l,c]=size(Dados);
index=randperm(l);
index_1=index(1:60);
index_2=index(61:end);

for i=1:l
    Dados(i,:)=(Dados(i, :)-AC)./(AB-AC);
end

x1=Dados(index_2,1:5);
[b,b1]=size(x1);
bias=-ones(b,1);
x=[bias'; x1'];
[n,m]=size(x);
%Inserindo a saída desejada d
d=Dados(index_2,6);
nne=5;           %número de neurônios de entrada
nnc=1;           %número de camadas ocultas
nno=8;           %número de neurônios da camada oculta
nns=1;           %número de neurônios da camada de saída
%Variáveis para a Fase de teste
xx1=Dados(index_1,1:5);
d1=Dados(index_1,6);
[bb,bb1]=size(xx1);
biass=-ones(bb,1);
xx=[biass'; xx1'];
eta=0.1;         %Taxa de aprendizagem
ep=9e-7;         %Precisão - Epsilon
g=inline('1./(1+exp(-2*u))'); %função de ativação
g1=inline('2*exp(-2*u)./((1+exp(-2*u)).^2)'); %derivada da função de
ativação
%Fase de Treinamento

w1=rand(nno,nne+1);
w2=rand(nns,nno+1);
epoca=0;

```

```

eqm=1000000;           %Erro quadratico médio
e=1;
t=1;
while (e>=ep) && (epoca<100000)
    eqmanterior=eqm;
    eqm=0;
    for i=1:m
        i1=w1*x(:,i);           %entrada da camada intermediaria
        y1=g(i1);               %saida do neuronio da camada intermediaria
        y11=[-1 y1']';         %saida com bias
        i2=w2*y11;              %entrada da camada de saida
        y2(i)=g(i2);            %saida da rede
        ee=d(i)-y2(i);
        delta2=ee*g1(i2);
        w2=w2+eta*delta2*y11';
        for j=1:nno
            delta1(j)=0;
            delta1(j)=delta2*w2(j+1)*g1(i1(j));
        end
        w1=w1+eta*delta1'*x(:,i)';
    end
    for j=1:m
        i1=w1*x(:,j);
        y1=g(i1);
        y11=[-1 y1']';
        i2=w2*y11;
        y2(j)=g(i2);
        ee=d(j)-y2(j);
        eqm=eqm+ee^2;

    end
    eqm=eqm/m;
    epoca=epoca+1;
    eqmt(epoca)=eqm;
    e=abs(eqm-eqmanterior)
    erro(epoca)=e;
    eqmanterior=eqm;
end

for i=1:bb
    I1=w1*xx(:,i);
    Y1=g(I1);
    Y11=[-1 Y1'];
    I2=w2*Y11';
    Y2(i)=g(I2);
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% Correlações%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
rho_rna = corr(d1,Y2')

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% desfazendo a normalização
Saida_RNA=Y2'.*(AB(6)-AC(6))+AC(6);
Saida_desejada=d1.*(AB(6)-AC(6))+AC(6);
MAPE=mean(100*abs((Saida_RNA-Saida_desejada)./Saida_desejada))

```

Apêndice B: Cálculo de Todos os Erros Percentuais

Figura B1: Cálculo dos Erros percentuais e do MAPE para previsão de custo na fase de treinamento

Amostras	Valor Real	Saída da Rede	Erro Percentual
1	208539370	201472623,3	3,388687089
2	185892483	171293288,6	7,853569017
3	152552809	160372167,1	5,125673002
4	209071757	229099197,1	9,579218361
5	247034126	267139228,7	8,138593263
6	299597035	275476013,4	8,051154973
7	100947671	145913304,3	44,54350745
8	403777236	442158705,7	9,505605147
9	265650808	241790124,1	8,981973005
10	261598233	259683194,8	0,732053174
11	226295105	209194870,3	7,556608299
12	149989594	162771951,2	8,522162667
13	124845218	113824191,8	8,827752012
14	132465939	120716302,6	8,869930241
15	137681056	125710685,3	8,69427581
16	312498310	293937045,2	5,93963687
17	425245954	402807260,9	5,276638832
18	166945472	154177369,9	7,648068418
19	210690604	201498394,1	4,362894142
20	490534954	482564840,2	1,624779992
21	634374644	584304679,1	7,892806776
22	854344318	854500821,6	0,018318558
23	842781084	819607584,3	2,74964639
24	254377364	273523767,6	7,526771759
25	486709150	509431963,8	4,66866378
26	140060261	151345726,9	8,057578819
27	185374351	191051509,4	3,062537192
28	529589449	518845506,7	2,028730429
29	306890100	280999114,8	8,436565788
30	122694288	112875020,9	8,00303526
31	141079732	148683345,6	5,389586059
32	132506448	121217439,4	8,519591927
33	127919735	139592802,3	9,125306022
34	320194724	295278774,5	7,781499074
35	343414666	316955150,8	7,704829706
36	316299454	343079466,5	8,466664172
37	389103260	380938451,7	2,098365424
38	426096464	391183509,9	8,193673739
39	374472754	344003690,1	8,13652356
40	260705265	277644689,7	6,497538396
41	245450202	255183572,9	3,965517589
42	197846889	200459084,9	1,320311825
43	200729331	186178966	7,248748834
44	147898802	160872611,2	8,772085373
45	221859738	218031693,3	1,72543459
46	512591317	480229162,3	6,313441846
47	447147192	442397736,2	1,062168326
48	140859577	149396368,1	6,060497464
49	139999136	128531282,4	8,191374549
50	161842370	147834525,1	8,655239593
51	130273162	174812516,5	34,18920201
52	119554639	110009746,1	7,983707711
53	180600450	164381947,9	8,980322072
54	258255936	235492074,6	8,814458134
55	579150602	599231148,7	3,467240928
56	238509601	217813863,1	8,677108942
57	115137329	154015778,5	33,76702402
⋮	⋮	⋮	⋮
985	218716973	220035456,5	0,602826349
986	538809143	557654588,8	3,497610611
987	207719155	216105775,6	4,037480627
988	212877751	218842369,8	2,801898631
989	453196456	475361272,1	4,89077436
990	167469615	181078523,2	8,126195448
991	226456621	247147041,1	9,13659313
992	118644035	108529577,8	8,525044865
993	796240096	775569496,2	2,596025982
994	139788570	128158315,2	8,319889672
MAPE			9,62%

Fonte: (Autora,2020)

Figura B2: Cálculo dos Erros percentuais e do MAPE para previsão de custo na fase de teste

Amostra	Dados Reais	Saída da Rede	Erro Percentual
1	242601916	241436433,2	0,480409556
2	424972693	450865933,6	6,092918692
3	276151793	299021866,4	8,281703746
4	286445886	308924416,3	7,84739158
5	263907421	255695744,8	3,111574561
6	449393139	620718092,6	38,12362467
7	145242497	134107221,2	7,666678835
8	144987295	133552006,3	7,887097044
9	119332660	109651106,1	8,113079769
10	370700131	339589700,4	8,392344111
11	577395027	531819403,6	7,893317622
12	381328004	349280189,4	8,404264634
13	275144749	267740234,8	2,691134116
14	174383430	159846206,5	8,336355992
15	328901885	330021536,7	0,340421174
16	276104260	297071016,3	7,593782237
17	479516346	464218108,2	3,190347518
18	125299529	114565339,3	8,566823671
19	190077983	175606157,9	7,613625143
20	133027026	122607524,4	7,832620101
21	510600769	471406408,2	7,676126476
22	338664398	366547811,8	8,233346616
23	340362996	333912068,1	1,895308244
24	108830793	149450073,6	37,32333426
25	274666129	252843867,1	7,94501381
26	441935040	445482869,9	0,802794425
27	672027810	698978100,6	4,010293952
28	920340570	939827979,5	2,117412854
29	241245045	261596694,4	8,436090132
⋮	⋮	⋮	⋮
84	559204299	602065278,5	7,664636973
85	931584459	939070695,7	0,803602571
86	308179484	282976192,8	8,178121017
87	192814317	198233286,1	2,8104599
88	487191116	509871840	4,655405907
89	317507893	334340278,1	5,30140681
90	135433895	134470244	0,711528672
91	457528314	485597555,9	6,13497374
92	327563340	301830208,5	7,85592537
93	362168173	332512853,4	8,188273242
94	211217490	207106086,7	1,946525964
95	181975182	176146402,4	3,203062908
96	297609834	270989727,1	8,944632809
97	113815271	104345603,1	8,320208578
98	238516178	250590724,1	5,062359359
99	413548324	409690231,3	0,932924267
100	170215764	183991790,2	8,093272824
MAPE			9,14%

Fonte: (Autora,2020)

Figura B3: Cálculo dos Erros percentuais e do MAPE para previsão de aditivo de custo na fase de treino

Amostra	Dados Reais	Saída da RNA	Erro percentual
1	409858,79	452733,4449	10,46083576
2	1118234,02	1067592,915	4,52866787
3	2419893,19	3288766,524	35,9054415
4	643259,91	408992,0502	36,4188497
5	730663,89	681697,0482	6,701691767
6	266524,4	167950,5497	36,98492531
7	1797455,5	826385,2098	54,0247194
8	2857333,75	3248934,11	13,70509694
9	927910,28	591157,5342	36,2915201
10	708807,27	642908,4834	9,29713752
11	430936,9	652887,8035	51,50426977
12	650833,66	522529,7835	19,71377395
13	2555603,53	2018423,88	21,01967866
14	1176262,98	822023,6075	30,11566108
15	770782,14	537246,6596	30,29850696
16	670619,9	663494,886	1,062451924
17	620654,25	703383,3385	13,32933569
18	313035,57	199656,3245	36,21928508
19	840323,28	721317,6095	14,16189142
20	374671,96	500005,1909	33,45145735
21	694956,42	544913,0848	21,59032291
22	823711,69	775312,119	5,875790235
23	854474,74	823201,4974	3,659937635
24	481837,18	575084,4177	19,3524372
25	998165,95	1133528,685	13,56114532
26	445622,62	751142,3817	68,5602005
27	2643665,46	2917196,432	10,34665604
28	502936,56	449524,1527	10,62010829
29	1217148,49	1002910,902	17,60159827
30	782294,4	736363,9692	5,871246272
31	1633350,62	2218297,447	35,81269204
32	707120,79	790458,5698	11,78550835
33	300564,09	499196,0629	66,0863954
34	501762,16	508814,1828	1,405451307
35	1739571,53	2732117,557	57,0569252
36	551127,97	552836,4557	0,309998
37	426729,56	270111,1855	36,70202141
38	769439,67	607284,2687	21,07447895
39	857949,81	1002613,467	16,8615524
40	3520816,97	2269213,126	35,54867677
41	846777,47	752379,4629	11,14791199
42	2780695,02	2882826,726	3,672884143
43	482359,26	814068,1136	68,76800782
⋮	⋮	⋮	⋮
831	1172925,03	830485,6416	29,19533471
832	655391,51	1238520,393	88,97412823
833	1591228,08	1188550,834	25,30606712
834	448731,9	459801,5609	2,466876309
835	414584,21	499416,607	20,46204244
836	637296,94	619922,0487	2,726341554
837	516321,14	418329,4117	18,97883326
838	1045744,55	995586,5903	4,796387389
839	2385618,59	2722791,307	14,13355506
840	792955,7	797897,357	0,623194584
841	2153394,9	802426,386	62,73668216
842	3547534,62	3779807,139	6,547434884
843	1189123,77	1133033,327	4,716955827
844	480494,16	549721,3774	14,40750443
845	342770,99	403715,3514	17,77990647
846	603998,67	812015,9579	34,44002416
847	978347,19	811630,5894	17,04063775
848	556931,75	538922,8694	3,233588432
849	398366,66	463102,7747	16,25038469
MAPE			37,03

Fonte: (Autora,2020)

Figura B4: Cálculo dos Erros percentuais e do MAPE para previsão de aditivo de custo na fase de teste

Amostras	Dados Reais	Saída da RNA	Erro Percentual
1	376740,01	485848,7405	28,96128036
2	1014671,59	795889,5377	21,56185848
3	432414,48	474467,1958	9,72509426
4	2207709,29	1599566,308	27,54633432
5	3098174,18	3662103,072	18,20197507
6	758957,86	581019,8421	23,4450458
7	360566,18	394996,183	9,54887201
8	1187367,78	853697,3174	28,1016942
9	2272798,09	1869416,665	17,74822969
10	395477,44	575211,4458	45,44734733
11	658239,35	830531,018	26,17462296
12	412740,18	293422,3077	28,90871256
13	330566,75	392286,9416	18,6710223
14	669687,31	546724,0115	18,36130037
15	367034,93	264441,4765	27,9519591
16	1827334,88	2269466,152	24,19541579
17	1118234,02	1065306,44	4,733139829
18	840309,44	425208,2831	49,39800688
19	449469,88	566114,3645	25,95156866
20	273967,98	424526,2757	54,95470518
21	2926913,78	3760273,382	28,47229761
22	1183291,05	1509143,873	27,53784227
23	777700,45	728733,6858	6,296352819
24	846777,47	752629,8527	11,11834226
25	4332118,11	5578178,668	28,76330992
26	228460,93	531457,4867	132,6251087
27	592652,72	676041,9936	14,07051225
28	336612,17	482322,2331	43,28722371
29	1014671,59	796955,7807	21,45677591
30	3049768,55	3914028,699	28,33854882
31	1433913,63	1338365,315	6,663463768
32	507791,49	418808,2363	17,52358113
33	313035,57	225563,0992	27,94330075
34	901949,19	857246,9023	4,956186913
35	356706,73	256830,9701	27,99940442
36	1428557,8	1663175,499	16,42339561
37	1063801,12	1198555,813	12,66728245
38	987186,3	733323,3158	25,71581314
39	955043,42	1228785,305	28,6627685
40	573497,97	681813,448	18,88681106
41	624328,97	668918,9729	7,142068526
42	773138,09	584888,7287	24,34873715
43	770645,23	659410,4442	14,43398097
44	1199029,35	1544123,785	28,78114992
45	958340,1	734969,5505	23,30806668
46	454894,77	513683,8712	12,9236705
47	791336,06	967563,843	22,26965153
⋮	⋮	⋮	⋮
59	3710980,15	1912130,973	48,47369439
60	1936176,63	1949959,407	0,711855336
61	479476,43	509691,9177	6,301767049
62	1172925,03	830485,6416	29,19533471
63	655391,51	1247794,053	90,38910848
64	1591228,08	1188550,834	25,30606712
65	448731,9	459801,5609	2,466876309
66	414584,21	499416,607	20,46204244
67	637296,94	619922,0487	2,726341554
68	516321,14	418329,4117	18,97883326
69	1045744,55	995586,5903	4,796387389
70	2385618,59	2722791,307	14,1335506
71	792955,7	797897,357	0,623194584
72	2153394,9	771956,2734	64,15166241
73	3547534,62	3779807,139	6,547434884
74	1189123,77	1133033,327	4,716955827
75	480494,16	549721,3774	14,40750443
76	342770,99	403715,3514	17,77990647
77	603998,67	433667,4073	28,20060228
78	978347,19	811630,5894	17,04063775
79	556931,75	538922,8694	3,233588432
80	398366,66	463102,7747	16,25038469
MAPE			29,34%

Fonte: (Autora,2020)

Figura B5: Cálculo dos Erros percentuais e do MAPE para previsão de Prazo na fase de treino

Amostras	Dados Reais	Saída da RNA	Erro Percentual
1	44	53,4211915	21,41179886
2	17	24,06772256	41,57483856
4	24	23,08330446	3,819564754
5	32	32,25799233	0,806226017
6	44	27,63104383	37,20217312
7	33	37,66656317	14,14110052
8	31	33,41835005	7,801129188
9	22	22,43210429	1,964110414
10	45	54,72534648	21,61188107
11	25	20,01989562	19,92041751
12	37	35,08959068	5,16326842
13	24	18,95476349	21,02181879
14	34	27,22757503	19,91889697
15	37	33,9773562	8,169307567
16	18	20,58455584	14,35864355
17	29	34,99059376	20,65721986
18	41	37,54541003	8,425829204
19	19	29,67651304	56,19217389
20	32	28,93454101	9,579559342
21	44	53,10440633	20,69183257
22	24	32,93561206	37,2317169
23	43	41,8658471	2,637564877
⋮	⋮	⋮	⋮
765	18	26,8446457	49,13692058
766	29	32,96330577	13,66657162
767	29	34,31003814	18,31047636
768	22	17,3949676	20,93196546
769	35	35,96333221	2,752377754
770	23	18,04607646	21,53879798
771	30	36,1923436	20,64114534
772	21	23,03631282	9,696727719
773	24	33,84646476	41,02693649
774	16	25,80579973	61,28624831
775	24	18,87959886	21,33500475
776	20	27,79281703	38,96408514
777	31	24,46061783	21,09478119
778	25	19,8519035	20,592386
779	25	28,82922627	15,31690507
780	27	29,42400237	8,977786537
781	32	28,87465557	9,766701338
782	45	35,7521471	20,55078423
783	43	34,89524352	18,84827089
784	34	31,48504279	7,396932957
785	38	38,48894536	1,286698327
786	30	25,94797252	13,50675825
787	39	41,24652762	5,760327231
788	31	24,28221838	21,6702633
789	25	19,74840605	21,0063758
MAPE			22,28%

Fonte: (Autora,2020)

Figura B6: Cálculo dos Erros percentuais e do MAPE para previsão de Prazo na fase de teste

Amostras	Dados Reais	Saída da RNA	Erro Percentual
1	36	32,6929852	9,186152226
2	28	28,62096246	2,217723082
3	16	13,1027243	18,10797313
4	44	41,62644742	5,394437676
5	17	23,83629215	40,21348324
6	19	15,64511882	17,65726937
7	47	42,02911637	10,57634815
8	29	26,91188465	7,200397754
9	22	31,90057592	45,00261784
10	35	38,46705626	9,905875022
11	44	28,22161605	35,85996352
12	37	31,61257941	14,56059619
13	40	37,04211295	7,394717628
14	24	27,96899836	16,53749318
15	38	44,81619508	17,93735548
16	18	21,3072481	18,37360054
17	39	42,28569503	8,424859057
18	44	28,90032041	34,31745362
19	27	38,8518088	43,89558815
20	23	23,93527251	4,066402238
21	38	44,5435198	17,21978894
22	41	44,50551098	8,55002677
23	43	37,28446409	13,29194398
24	63	34,83363642	44,70851362
25	29	28,86204447	0,475708737
26	22	33,04534791	50,20612686
27	46	48,02162865	4,394844885
28	26	29,97521463	15,28928705
29	51	32,90634125	35,47776226
30	47	38,59850881	17,87551317
31	34	35,23251452	3,625042706
32	42	38,66747374	7,934586343
33	23	27,1133408	17,88409043
34	49	42,56653207	13,12952638
35	44	41,67552459	5,28289867
36	30	30,18440283	0,614676093
37	27	24,53134479	9,143167428
38	37	37,61431298	1,660305343
39	18	27,20856178	51,15867654
40	41	35,46107409	13,50957538
41	35	36,32656595	3,790188421
42	27	38,18945118	41,44241178
43	21	21,25093742	1,194940094
44	27	35,81651163	32,65374679
45	29	33,17632582	14,40112352
46	27	35,33625582	30,87502155
47	32	37,88969605	18,40530016
48	28	23,05284074	17,66842594
49	16	22,2577179	39,1107369
50	76	39,58919767	47,90895043
51	21	17,07790521	18,67664184
52	48	41,81457423	12,8863037
53	24	20,77166736	13,451386
54	18	30,62163596	70,1201998
55	36	37,18670463	3,296401759
56	20	27,44170419	37,20852097
57	29	30,88631056	6,504519185
58	16	23,44769425	46,54808909
59	27	28,00305868	3,715032141
60	21	20,10115438	4,280217239
MAPE			19,30%

Fonte: (Autora,2020)

Figura B7: Cálculo dos Erros percentuais e do MAPE para previsão de Aditivo de Prazo na fase de treino

Amostras	Dados Reais	Saída da RNA	Erro Percentual
1	17	13,60753813	19,95565803
2	13	15,31111667	17,77782051
3	15	19,24109401	28,27396008
4	23	19,54423055	15,02508459
5	13	16,74029782	28,77152171
6	35	48,46917592	38,48335976
7	23	19,1304506	16,82412782
8	9	12,3020971	36,68996778
9	16	18,38382902	14,89893135
10	18	15,76791171	12,4004905
11	32	44,34700281	38,58438379
12	16	21,04716774	31,54479837
13	10	13,86474655	38,64746555
14	23	23,81248448	3,532541207
15	17	19,64262195	15,54483499
16	29	24,6109295	15,13472587
17	13	16,76724506	28,97880813
18	13	16,57506635	27,50051038
⋮	⋮	⋮	⋮
763	13	17,94241779	38,01859836
764	11	13,54387631	23,12614823
765	32	44,21724442	38,17888881
766	31	25,20658618	18,68843169
767	23	23,8373058	3,640460012
768	16	14,64899334	8,443791609
769	21	20,28782605	3,391304529
770	20	14,38110031	28,09449844
771	15	27,02179824	80,14532159
772	10	13,88792509	38,87925087
773	21	16,18940799	22,90758098
774	11	14,3449945	30,40904095
775	14	14,10347777	0,739126893
776	16	17,11935428	6,995964249
777	24	20,37345633	15,11059861
778	22	19,30829966	12,23500153
779	18	17,20869558	4,396135652
780	13	15,25669684	17,35920648
781	7	12,98482936	85,49756224
782	19	14,9686723	21,21751421
783	24	19,15529013	20,18629114
784	17	13,42239232	21,04475105
785	12	16,35282771	36,27356424
786	10	11,04458367	10,44583667
787	32	19,69214595	38,4620439
788	13	16,65275841	28,09814159
789	10	16,29152703	62,91527032
MAPE			39,99%

Fonte: (Autora,2020)

Figura B8: Cálculo dos Erros percentuais e do MAPE para previsão de Aditivo de Prazo na fase de teste

Amostras	Dados Reais	Saída da RNA	Erro Percentual
1	10	18,42151133	84,21511331
2	16	19,80581922	23,78637009
3	13	17,92548614	37,88835493
4	18	16,80927929	6,615115065
5	13	12,8947277	0,809786894
6	26	35,89024646	38,03940948
7	18	24,48350475	36,01947083
8	26	19,90848123	23,42891834
9	29	20,64193827	28,82090252
10	30	36,88847468	22,96158228
11	11	14,54973971	32,27036097
12	7	14,35431473	105,061639
13	34	47,12869814	38,61381805
14	18	16,62171616	7,657132436
15	24	15,87907338	33,83719424
16	8	24,66531451	208,3164314
17	11	14,28771669	29,8883335
18	13	16,61079544	27,77534952
19	10	20,471127	104,71127
⋮	⋮	⋮	⋮
35	21	21,41600674	1,980984467
36	13	17,03173584	31,01335258
37	39	53,87323585	38,13650218
38	14	8,661244413	38,13396848
39	25	17,88998483	28,44006068
40	22	15,69274665	28,6693334
41	11	14,77247884	34,2952622
42	16	14,77338677	7,666332698
43	14	16,84792269	20,34230493
44	34	23,54909197	30,7379648
45	14	17,46509743	24,75069594
46	7	15,72667221	124,6667458
47	27	17,67367635	34,54193943
48	13	13,49240509	3,787731468
49	16	25,12386522	57,02415765
50	17	17,78484021	4,616707143
51	9	15,54641078	72,73789753
52	21	22,74905617	8,328838916
53	18	19,28945771	7,163653959
54	19	20,81174436	9,535496634
55	20	19,65321266	1,733936692
56	25	18,18033217	27,27867133
57	9	14,51753393	61,3059325
58	27	17,48844408	35,22798488
59	15	17,45096668	16,33977788
60	32	44,20609078	38,14403368
MAPE			39,36%

Fonte: (Autora,2020)