

**INSTITUTO TECNOLÓGICO DE AERONÁUTICA**



**Pedro Teixeira Rodrigues**

**ESTIMATIVA PARAMÉTRICA DE CUSTO DE OBRAS  
COM O USO DE REDES NEURAS ARTIFICIAIS**

Trabalho de Graduação  
2020

**Curso de Engenharia Civil-Aeronáutica**

**Pedro Teixeira Rodrigues**

**ESTIMATIVA PARAMÉTRICA DE CUSTO DE OBRAS  
COM O USO DE REDES NEURAIS ARTIFICIAIS**

Orientadora

Prof<sup>a</sup> Maryangela Geimba Lima (ITA)

Coorientadora

Prof<sup>a</sup> Priscila Caterine de Brito Cataldi (ITA)

**ENGENHARIA CIVIL-AERONÁUTICA**

**SÃO JOSÉ DOS CAMPOS  
INSTITUTO TECNOLÓGICO DE AERONÁUTICA**

**Dados Internacionais de Catalogação-na-Publicação (CIP)**  
**Divisão de Informação e Documentação**

, Pedro Teixeira Rodrigues  
Estimativa paramétrica de custo de obras com o uso de redes neurais artificiais / Pedro Teixeira Rodrigues .  
São José dos Campos, 2020.  
50f.

Trabalho de Graduação – Curso de Engenharia Civil-Aeronáutica– Instituto Tecnológico de Aeronáutica, 2020. Orientadora: Prof<sup>a</sup> Maryangela Geimba Lima. Coorientadora: Prof<sup>a</sup> Priscila Caterine de Brito Cataldi.

1. . 2. . 3. . I. Instituto Tecnológico de Aeronáutica. II. Título.

## **REFERÊNCIA BIBLIOGRÁFICA**

, Pedro Teixeira Rodrigues. **Estimativa paramétrica de custo de obras com o uso de redes neurais artificiais**. 2020. 50f. Trabalho de Conclusão de Curso (Graduação) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

## **CESSÃO DE DIREITOS**

NOME DO AUTOR: Pedro Teixeira Rodrigues

TÍTULO DO TRABALHO: Estimativa paramétrica de custo de obras com o uso de redes neurais artificiais.

TIPO DO TRABALHO/ANO: Trabalho de Conclusão de Curso (Graduação) / 2020

É concedida ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias deste trabalho de graduação e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte deste trabalho de graduação pode ser reproduzida sem a autorização do autor.

---

Pedro Teixeira Rodrigues  
Rua Manoel Borba Gato, 900  
12.242-476 – São José dos Campos – São Paulo

# ESTIMATIVA PARAMÉTRICA DE CUSTO DE OBRAS COM O USO DE REDES NEURAIS ARTIFICIAIS

Essa publicação foi aceita como Relatório Final de Trabalho de Graduação



---

Pedro Teixeira Rodrigues

Autor



---

Maryangela Geimba Lima (ITA)

Orientadora



---

Priscila Caterine de Brito Cataldi (ITA)

Coorientadora



---

Prof. João Cláudio Bassan de Moraes  
Coordenador do Curso de Engenharia Civil-Aeronáutica

São José dos Campos, 16 de novembro de 2020.

*"Em seu último dia na Terra, a pessoa que você se tornou irá se encontrar com a pessoa que você poderia ter se tornado."*

# Agradecimentos

À Deus, Por me guiar pelo bom caminho.

À minha mãe Ana Amélia, Por todo o amor e carinho que sempre recebi e por me ensinar que o importante é ser feliz.

Ao meu pai Walter, Por ser meu exemplo de dedicação e disciplina e por sempre cuidar de mim com tanto afinho.

Ao Bibi, Por toda a paciência despendida ao longo do tempo e por ser o meu exemplo de bondade.

Aos meus amigos e familiares, Que, de perto ou de longe, estão torcendo pelo meu sucesso e eu pelo deles.

À Luli, Por sempre me incentivar a ser a minha melhor versão e por ser a minha referência de caráter e de excelência.

*“Never let the future disturb you.  
You will meet it, if you have to, with the same weapons of reason which today arm you  
against the present.”*  
— MARCUS AURELIUS

# Resumo

O objetivo do trabalho é estudar e analisar o custo de obras públicas a partir de redes neurais artificiais a partir do contexto orçamentário da Comissão de Obras do Departamento de Ciência e Tecnologia Aeroespacial, responsável pela execução de reformas e construções para organizações militares da Força Aérea Brasileira. A orçamentação de obras públicas é um exercício de previsão que tem como processo três etapas para garantir o detalhamento do orçamento a ser construído. A primeira etapa do processo é a estimativa de custos onde se define a ordem de grandeza do custo. Em seguida, é possível já estimar o valor de cada tipo de serviço, através do orçamento preliminar. Por fim, o orçamento é considerado finalizado após o cálculo do orçamento analítico.

A partir das características da obra, do contexto local e da tabela de descritivos de serviços contidos em cada projeto, o modelo matemático preditivo apresentado será capaz de mensurar a ordem de grandeza e o custo estimado para futuras obras da mesma natureza, colaborando primordialmente na etapa de estimativa de custos. É possível desenvolver o presente estudo de forma a impactar também o orçamento preliminar, definindo a contribuição orçamentária de cada tipo de serviço envolvido no processo.

Conforme detalhado nos objetivos do projeto, o trabalho visa modelar uma rede neural que se adeque ao contexto, à situação e às características da orçamentação de obras públicas que se relacionam com os projetos e serviços planejados pela Comissão de Obras do Departamento de Ciência e Tecnologia Aeroespacial. Dessa maneira, a integralidade da base de dados utilizada se originará exclusivamente dos arquivos da equipe responsável pela orçamentação dentro do instituto. Buscou-se levar em consideração a especificidade e a temporalidade de cada tipo de obra que foi levada em consideração na construção da base de dados da rede neural. Todo o processo foi desenvolvido a partir do tratamento das planilhas disponibilizadas e do algoritmo *Neural Net Fitting* do software *MATLAB* que desenvolve RNAs, conjunto de equações diferenciais não lineares com parâmetros ajustáveis através dos dados disponíveis, composta por várias unidades de processamento que são conectadas por canais de comunicação associados a determinado peso.

*Palavras-chave:* Estimativa Paramétrica, Orçamentação de Obras Públicas, Redes Neurais Artificiais, Orçamento

# Abstract

The objective of the work is to study and analyze parametric estimates of the cost of public works based on artificial neural networks from the budgetary context of the Works Commission of the Department of Aerospace Science and Technology (CO-DCTA), responsible for the execution of reforms and constructions for military organizations of the Brazilian Air Force (FAB).

The budgeting of public works is a forecasting exercise that has three steps that guarantee the improvement and detailing of the budget to be built. The first stage of the process consists of estimating costs where the order of magnitude of the initial cost is already defined. Then, it is possible to estimate the cost of each type of service involved in the project, through the preliminary budget. Finally, the budget is considered finalized after calculating the analytical budget.

Based on the characteristics of the work, the local context and the table of descriptions of services contained in each project, the predictive mathematical model presented will be able to measure the order of magnitude and the estimated cost for future works of the same nature, collaborating primarily in the stage cost estimation. Still, it is possible to develop the present study in order to also impact the preliminary budget, defining with greater support the budgetary contribution of each type of service involved in the process.

As detailed in the project objectives, the work aims to model a neural network that fits the context, the situation and the characteristics of the budgeting of public works that relate to the projects and services planned by the Works Commission of the Department of Aerospace Science and Technology. In this way, the completeness of the database used for the definition and choice of variables will originate exclusively from the files of the team responsible for budgeting within the institute. We sought to take into account the specificity and temporality of each type of work that was taken into account in the construction of the neural network database.

The whole process was developed from the treatment of the spreadsheets provided and the *Neural Net Fitting* algorithm of the *MATLAB* software that develops Artificial Neural Networks, a set of non-linear differential equations with adjustable parameters through the available data, composed of several processing units that are connected communication

channels associated with a certain weight.

Mathematically speaking, Artificial Neural Networks are a set of non-linear differential equations with parameters adjustable through the available data. It consists of several processing units that are connected by communication channels that are associated with a certain weight. Units do operations only on their local data, which is input received by their connections. The following work will be developed from a multi-layered neural network and will present the construction of the solution and the possibilities of future evolution for the project.

*Keywords:* Parametric Estimation, Public Works Budgeting, Artificial Neural Networks, Budget

# Lista de Figuras

FIGURA 2.1 – Custo do m <sup>2</sup> , de acordo com as características da edificação . . . . .	22
FIGURA 2.2 – Custo do m <sup>2</sup> (padrão comercial) . . . . .	23
FIGURA 2.3 – Orçamento preliminar: percentis relativos ao custo total . . . . .	24
FIGURA 3.1 – Modelo esquemático de uma unidade de processamento . . . . .	32
FIGURA 3.2 – Exemplo de rede neural composta de neurônios organizados em camadas. . . . .	33
FIGURA 4.1 – Janela inicial do <i>nftool</i> . . . . .	37
FIGURA 4.2 – Escolha dos <i>inputs e outputs</i> . . . . .	38
FIGURA 4.3 – Definição das porcentagens de segmentação da base de dados inicial	39
FIGURA 4.4 – Arquitetura da Rede Neural . . . . .	40
FIGURA 4.5 – Indicadores relativos ao treinamento da RNA . . . . .	41
FIGURA 4.6 – Histograma dos erros calculados ao longo do treinamento . . . . .	42
FIGURA 4.7 – Gráficos e valores das regressões lineares obtidas a partir do treinamento . . . . .	43
FIGURA 4.8 – Indicadores relativos ao treinamento da RNA - 2 <sup>a</sup> análise . . . . .	44
FIGURA 4.9 – Histograma dos erros calculados ao longo do treinamento - 2 <sup>a</sup> análise	45

# Lista de Tabelas

TABELA 3.1 – INCC acumulado anual e Relações da Rede Neural . . . . .	30
---	----

# Sumário

1	INTRODUÇÃO . . . . .	14
1.1	Motivação . . . . .	14
1.2	Objetivo . . . . .	15
1.3	Metodologia . . . . .	15
1.4	Descrição dos capítulos . . . . .	15
2	REVISÃO BIBLIOGRÁFICA . . . . .	17
2.1	Diretrizes orçamentárias e regulamentações . . . . .	17
2.2	Atributos do orçamento . . . . .	17
2.2.1	Aproximação . . . . .	18
2.2.2	Especificidade . . . . .	19
2.2.3	Temporalidade . . . . .	20
2.3	Graus do orçamento . . . . .	21
2.3.1	Estimativa de Custos . . . . .	21
2.3.2	Orçamento Preliminar . . . . .	23
2.3.3	Orçamento Analítico . . . . .	24
2.4	Estudos prévios de aprendizado de máquina em orçamentação de obras . . . . .	24
3	METODOLOGIA . . . . .	26
3.1	Escolha das variáveis . . . . .	26
3.2	Tratamento de dados . . . . .	28
3.3	Redes Neurais Artificiais . . . . .	31
3.3.1	Introdução . . . . .	31
3.3.2	Modelo Matemático . . . . .	31

---

3.3.3	Processo de aprendizagem . . . . .	33
3.3.4	Treinamento Supervisionado . . . . .	34
<b>3.4</b>	<b>Configuração computacional da Rede Neural . . . . .</b>	<b>35</b>
<b>3.5</b>	<b>Treinamento e inserção de dados . . . . .</b>	<b>35</b>
<b>3.6</b>	<b>Método de avaliação dos resultados . . . . .</b>	<b>36</b>
<b>4</b>	<b>ANÁLISE DOS RESULTADOS . . . . .</b>	<b>37</b>
<b>4.1</b>	<b>Treinamento da RNA no ambiente de simulação . . . . .</b>	<b>37</b>
<b>4.2</b>	<b>Discussão dos resultados . . . . .</b>	<b>41</b>
<b>5</b>	<b>CONCLUSÃO . . . . .</b>	<b>47</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>48</b>
	<b>ANEXO A – BASE DE DADOS UTILIZADA NA REDE NEURAL AR-</b>	
	<b>TIFICIAL . . . . .</b>	<b>50</b>

# 1 Introdução

## 1.1 Motivação

Um dos maiores fluxos financeiros anuais no Brasil é originado de licitações para realização de obras e serviços para a área pública. Em 2018, houveram quase cem mil licitações abertas e contratadas, com um valor total de R\$ 38,56 bilhões de reais. (BRASIL, 2018)

Devido ao relevante montante envolvido nos processos licitatórios brasileiros, é de suma importância que haja intenso planejamento, fiscalização e preparação das instituições para que o dinheiro público seja sempre alocado da melhor forma possível.

O fluxo licitatório nos estados, municípios e organizações públicas no Brasil se inicia a partir do mapeamento das necessidades das instituições, que não são possíveis de ser supridas a partir do conhecimento técnico e da força de trabalho dos servidores que ali trabalham. A partir daí inicia-se a etapa de orçamentação do serviço, que envolve a elaboração de planilhas e descritivos detalhados dos critérios técnicos e operacionais de serviço e os custos associados a cada item necessário para a realização do projeto. (BRASIL, 2010)

Além do conhecimento e da experiência da instituição no dimensionamento orçamentário, é de suma e obrigatória importância a realização de ampla pesquisa de mercado em relação a todos os serviços solicitados. Obedecidos todos os passos de entendimento e preparação do projeto, a licitação é então publicada e fica acessível a qualquer empresa que tenha intenção de concorrer pela execução do serviço, já com o orçamento de projeto completamente definido. O fornecedor vencedor do processo licitatório será aquele que atender a todos os critérios estabelecidos no edital e com condição técnica e financeira mais vantajosa para a Administração, dependendo da modalidade da licitação. (BRASIL, 2010)

Para garantir tanto a qualidade do projeto quanto o maior custo-benefício possível de gastos públicos é determinante a correta execução da orçamentação do projeto. Por ser uma área que envolve um alto volume de pesquisas, estimativas e comparativos, existe muito espaço para a aplicação de tecnologia, estatística e outros métodos de aprimora-

mento e predição de resultados, temas que serão abordados ao longo deste trabalho.

## 1.2 Objetivo

O objetivo do trabalho é oferecer uma estimativa paramétrica de custo de obras públicas a partir de redes neurais artificiais. De forma mais específica, o projeto busca colaborar com a Comissão de Obras do Departamento de Ciência e Tecnologia Aeroespacial, por meio do treinamento do algoritmo a partir da base de orçamentos de obras, reformas e serviços historicamente executados pelas organizações militares da Força Aérea Brasileira (FAB).

De posse dos conhecimentos técnicos e da experiência dos colaboradores que já têm a orçamentação de projetos como prática diária e da tabela de descritivos de serviços contidos em cada projeto, o modelo matemático preditivo arquitetado será capaz de mensurar a ordem de grandeza e o custo estimado para futuras obras da mesma natureza.

## 1.3 Metodologia

O presente trabalho buscará colaborar com a precisão e a amplitude de análise da etapa de estimativa de custos da orçamentação licitatória. Através de uma Rede Neural Artificial treinada de acordo com a base de dados da CODCTA, o projeto visou mapear, definir e calibrar as variáveis específicas que podem ser catalogadas a partir dos contratos com os municípios e estados brasileiros.

Dessa forma, todo o processo relativo à estimativa inicial de custos, tão necessária para conhecimento da ordem de grandeza financeira do projeto, seria automatizado e abrangeria um número maior de variáveis, aumentando a precisão da etapa de orçamentação analítica como um todo.

Em colaboração com a CODCTA, é possível também entregar, com certa precisão, as porcentagens do orçamento total que deverão ser destinadas a cada grupo de serviços requisitados.

## 1.4 Descrição dos capítulos

O principal objetivo é propor uma solução que otimize o processo orçamentário para abertura de licitações. Para elucidar o desafio para o leitor, o capítulo 2 se iniciará por uma revisão bibliográfica das diretrizes e regulamentações existentes. Posteriormente, o texto seguirá apresentando o contexto do orçamentista e os processos envolvidos, definindo

e qualificando os atributos do orçamento a partir da discussão das variáveis envolvidas no projeto.

Apresentados todos os parâmetros envolvidos, a próxima etapa do projeto é esquematizar o processo de predição e construção do orçamento em si, lapidando-o para aproximar-se o máximo possível da realidade, através do capítulo 3. Iniciando pela estimativa em custos, passando pela versão preliminar do orçamento até a sua consolidação com o detalhamento analítico.

A partir da explicação detalhada do processo, o capítulo 4 tangibiliza como o trabalho em questão se encaixará na “linha de produção” do orçamento, comparando o nível preditivo potencial e a capacidade de automatização de parte do processo, avaliando por fim os resultados obtidos com o modelo.

Por fim, buscou-se detalhar o método construtivo da rede neural artificial e as premissas utilizadas para tal. Assim, foi possível treinar, validar e verificar a modelo matemático de acordo com a situação real apresentada de acordo com as conclusões apresentadas no capítulo 5.

## **2 Revisão Bibliográfica**

### **2.1 Diretrizes orçamentárias e regulamentações**

A execução desajustada ou incorreta da etapa de pesquisa orçamentária pode trazer consideráveis diferenças entre o valor de serviço da proposta vencedora e o valor orçado, trazendo sérias consequências como o desperdício de recursos públicos e/ou contratação de serviços de má qualidade.

Dentre as bibliografias que abordam a regulamentação do tema, destaca-se preliminarmente a Lei Nº 8.666 , de 21 de junho de 1993, cujo Artigo 15 define que “as compras, sempre que possível, deverão balizar-se pelos preços praticados no âmbito dos órgãos e entidades da Administração Pública e o seu registro será precedido de ampla pesquisa de mercado.” (BRASIL, 1993b)

O Sistema de Registro de Preços do Artigo 15 da Lei acima citada é regulamentado pelo Decreto Nº 7.892, de 23 de janeiro de 2013 que, no Artigo 5º, indica como competência do órgão gerenciador “a prática de todos os atos de controle e administração do Sistema de Registro de Preços, entre eles a realização de pesquisa de mercado para identificação do valor estimado da licitação e a consolidação dos dados das pesquisas de mercado realizadas pelos órgãos e entidades participantes.” (BRASIL, 1993a)

Além disso, é importante deixar claro que a devida pesquisa de mercado deve ser seguida de intenso detalhamento em planilhas de todos os custos envolvidos no projeto. No Artigo 40 da referida Lei Nº 8.666, o inciso XVII reitera, no parágrafo 2º, a necessidade de “orçamento estimado em planilhas de quantitativos e preços unitários”. (BRASIL, 1993b)

### **2.2 Atributos do orçamento**

Para que o projeto que almeja-se desenvolver neste trabalho tenha utilização prática e faça sentido no dia-a-dia do orçamentista, é importante entender todo o processo que permeia essa atividade e qual é a função que a rede neural artificial substitui ou aprimora.

Estimar custos de uma obra é um exercício de previsão. A previsão orçamentária

envolve etapas que são religiosamente seguidas para que não existam brechas e falhas no estudo de custos de uma determinada obra. Identificar, descrever, quantificar, analisar e definir o valor de cada fator influenciador são práticas essenciais para o desenvolvimento de um bom orçamento. (MATTOS, 2006, 286p.)

E, para que esse orçamento seja preciso e coerente com a realidade, sempre será necessária uma dose considerável de experiência em campo, somada a uma boa percepção das variáveis de projeto presentes no edital. Dessa forma, qualquer tipo de análise feita em escritório e realizada por softwares deve passar pelo filtro da realidade, isto é, todo resultado final deve ser associado a uma reflexão em relação à coerência do que foi atingido como número final e à capacidade do modelo retratar a realidade de projeto. (MATTOS, 2006, 286p.)

Esse modelo pode ser segmentado em três tipos de atributos orçamentários: aproximação, especificidade e temporalidade. Os próximos itens elucidarão alguns dos fatores mais comuns que são considerados “variáveis” de projeto e que precisam ser identificados e calibrados para a construção de um orçamento de qualidade. (MATTOS, 2006, 286p.)

### 2.2.1 Aproximação

Como todo o cálculo de custos do projeto é feito a partir de previsões e considerações prévias, é premissa de qualquer orçamento a existência de uma incerteza relacionada a ele. Tal incerteza decorre da variabilidade de preços de mão-de-obra, dos materiais a serem utilizados, dos equipamentos e dos custos indiretos. (MATTOS, 2006, 286p.)

A mão-de-obra é um fator que está diretamente relacionada à capacidade produtiva da força de trabalho despendida para execução de cada serviço da obra. Normalmente é um fator que é calculado pelo volume construtivo (em unidades de distância, área ou volume) que um trabalhador é capaz de desenvolver em 1 hora de labuta e, por isso, tem uma forte dependência com a experiência em campo.

Além disso, como a mão-de-obra é uma linha de custo que envolve basicamente o tempo de pessoas, uma boa parte desse valor é dedicado a encargos sociais e trabalhistas. Nesse item, leva-se em conta previsões como despesas com regulamentações trabalhistas, faltas justificadas (ou não), cálculo de aviso prévio e incidência de acidentes no trabalho. (MATTOS, 2006, 286p.)

O material empregado também é de suma importância para a determinação da estimativa básica dos custos da obra. O mercado está preparado para suprir as necessidades de todos os tipos de consumidores e é muito importante considerar nesse ponto a sensibilidade do nível de entrega despendido pelo potencial cliente, associado à garantia do uso de materiais de qualidade suficiente para que o projeto como um todo atinja o nível de

serviço pretendido. (MATTOS, 2006, 286p.)

Nesse item, o conhecimento do mercado e as parcerias contratuais da empresa têm grande relevância por serem traduzidas na utilização de materiais de melhor qualidade por preços mais baixos. Entretanto, o fator da incerteza do preço do material é um grande desafio para essa estimativa, pois os valores podem variar entre o momento da orçamentação e o real momento de compra e uso dos mesmos, bem como os impostos associados a essa aquisição.

Ademais, nem todos os materiais possuem o mesmo comportamento e a mesma constância de necessidade, o que traz uma variável extra a essa estimativa. Cada tipo de produto possui um determinado percentual de perda e desperdício e qualquer admissão média pode acarretar grandes desvios de valores. Existem ainda materiais que são adquiridos de forma sazonal e que têm duração de uso maior do que apenas um projeto, sendo considerados como reutilizáveis ou de longo uso. (MATTOS, 2006, 286p.)

Em relação ao equipamento que será utilizado ao longo do projeto, o fator que exprime de forma direta o valor a ser orçado é o custo horário de uso da máquina, possivelmente também associado a custos de operação e manutenção. Tais fatores decorrem da produtividade do equipamento que está relacionada a três fatores: disponibilidade mecânica (disponibilidade percentual de tempo do equipamento em suas devidas condições de operação), coeficiente de utilização (tempo efetivo de trabalho do equipamento) e do empolamento (variação volumétrica) do material escavado, quando esta for a finalidade da máquina.

Por fim, é importante salientar que todo projeto envolve também a sustentabilidade financeira do empreendimento que o produz e que o executa. Dessa forma, é importante contabilizar também os custos indiretos associados ao trabalho, como os salários e encargos de toda a equipe técnica, administrativa e de apoio que colabora ao redor do projeto e as despesas gerais associadas a cada etapa dos processos. Além disso, é necessário sempre ter uma verba adicional para custear possíveis imprevistos, ocorrências comuns em projetos de grande porte e que possuem uma duração relativamente extensa. Tal quantia é parte da composição dos benefícios e despesas indiretas (BDI) da obra. (MATTOS, 2006, 286p.)

### **2.2.2 Especificidade**

Um dos objetivos da ala orçamentária das empresas é buscar a máxima generalização dos processos e dos cálculos envolvidos no custeamento de obras. Conforme são identificadas similaridades entre áreas e fragmentos de diferentes projetos, o ideal é se buscar a replicação de análises e de considerações feitas para ambos. (MATTOS, 2006, 286p.)

Entretanto, é inevitável levar em consideração as peculiaridades de cada obra. Exis-

tem alguns variantes do problema que são específicos de cada projeto e que não podem entrar nas aproximações recorrentemente executadas. O primeiro ponto citado na literatura são as especificidades da empresa contratada e que desenvolveu o cálculo orçamentário. Como o intuito do presente trabalho é desenvolver um método para a previsão de orçamento total para a abertura de licitações (compras), tal fator não deve ser levado em consideração como específico. (MATTOS, 2006, 286p.)

Já a segunda área específica para cada obra é a condição local do projeto. Clima, vegetação, relevo, posição do lençol freático, tipo de solo, facilidade de acesso ao local, ao canteiro de obras e às fontes de matéria-prima, qualidade e oferta da mão-de-obra e dos equipamentos e alíquotas de impostos são fatores sensíveis à localização da obra e se caracterizam por se diferenciarem por cidades, estados e regiões.

Para metrificar e tangibilizar o problema, comumente utilizam-se pesquisas e sensos nacionais para tabelar e relativizar a diferenciação de custo e de porcentagem do orçamento total da obra de acordo com a região, em diferentes escalas de abrangência.

### 2.2.3 Temporalidade

Um dos grandes desafios para a parametrização de cálculos orçamentários é a sua obsolescência. Grande parte das variáveis de projeto, tanto aquelas que podem ter seus modelos de cálculo replicadas quanto aquelas que possuem certa especificidade estão sujeitos à ação do tempo. Essa variação pode ser melhor definida a partir de quatro possíveis razões, que contêm conjuntos de variáveis cujos valores estão diretamente relacionadas com o período de tempo analisado, sendo elas: custo dos insumos, impostos e encargos sociais e trabalhistas, métodos construtivos e os cenários financeiros e gerenciais.

Destes, apenas o último fator não é relevante para o dimensionamento do valor a ser utilizado como parâmetro do custo total do projeto a ser licitado. (MATTOS, 2006, 286p.)

A flutuação do custo dos insumos ao longo do tempo está diretamente relacionado ao cenário macroeconômico local/regional. Os valores dos materiais, equipamentos e mão-de-obra são reajustados ao longo do tempo, de acordo com a evolução dos índices de preço dos respectivos mercados.(MATTOS, 2006, 286p.)

Da mesma forma, os impostos e encargos tributários e trabalhistas são informações influenciadas pelo desenvolvimento e alterações oriundas do sistema tributário estadual e governamental. Portanto, são diferentes de acordo com a localidade e estão sujeitos a alterações de tempos em tempos.

Além disso, os métodos construtivos estão em constante evolução. A cada momento, novas tecnologias e novos procedimentos estão sendo desenvolvidos e aprimorados. Dessa forma, existem muitos tipos de equipamentos, máquina, técnicas e serviços que podem

ser substituídos ou terem seu custo horário alterados ao longo do tempo. (MATTOS, 2006, 286p.)

## 2.3 Graus do orçamento

O cálculo orçamentário de projetos estruturais pode ser feito e estratificado de acordo com o nível de detalhamento desejado, divididos em três níveis: estimativa de custos, orçamento preliminar e orçamento analítico ou detalhado.

Cada um deles são adequados para um determinado momento do projeto e para uma função diferente. A estimativa de custos é uma breve avaliação com base em históricos de precificação, a partir de parametrizações comparativa. O método a ser desenvolvido no presente trabalho será uma sugestão de mecanismo preditivo para estimativa de custos a partir de uma rede neural artificial, utilizando o histórico de projetos como base de dados inicial do modelo. (MATTOS, 2006, 286p.)

O orçamento preliminar utiliza como base as estimativas produzidas no modelo anterior, mas com um levantamento de quantitativos mais preciso que leva também em consideração pesquisas de mercado e de preços dos insumos e serviços relacionados, aumentando o grau de precisão do cálculo.

Já o orçamento analítico é a fase final orçamentária. Conforme disposto nas regulamentações licitatórias, o orçamento final deve ser detalhado em planilhas a partir dos elementos construtivos requeridos e de extensa pesquisa de mercado.(MATTOS, 2006, 286p.)

### 2.3.1 Estimativa de Custos

Normalmente, as estimativas de custos iniciais são embasadas em métricas genéricas de fácil acesso popular que foram lapidadas ao longo do tempo por caracterizem fácil medição e traduzirem quantitativos relativamente aproximados do que será demandado em termos financeiros.

O indicador mais comum é o por custo por metro quadrado construído. O mais utilizado é o Custo Unitário Básico (CUB). Devido ao seu amplo uso, a responsabilidade pela padronização e regulamentação dos critérios de estimativas de custos, composição de orçamentos e avaliação global da obra é da Associação Brasileira de Normas Técnicas (ABNT). Os custos unitários de construção são mensalmente divulgados e geridos pelos Sindicatos da Indústria da Construção relativos a cada estado brasileiro, para cada padrão construtivo existente. (MATTOS, 2006, 286p.)

Atualmente, guia-se todo o processo pela NBR 12.721, que define os critérios de medi-

ção, cálculo e representatividade de materiais e serviços de acordo com os condicionantes construtivos, como a qualidade do material exigido, o padrão de acabamento e a disponibilidade de equipamentos e mão-de-obra qualificada. (MATTOS, 2006, 286p.)

O Custo Unitário Básico de cada projeto-padrão é calculado aplicando-se aos coeficientes constantes dos quadros da NBR 12.721 (lotes básicos) os preços unitários dos insumos (material e mão-de-obra) ali relacionados. Esses preços são resultantes de pesquisa mensal feita pelos Sindicatos (batizados de SINDUSCON na maioria dos Estados) junto a expressivo número de construtoras, que mensalmente informam os valores praticados. Quanto à mão-de-obra, é aplicado um percentual correspondente aos encargos trabalhistas e previdenciários, decorrentes da legislação própria e da Convenção Coletiva de Trabalho”. (MATTOS, 2006, 286p.)

O CUB é definido para cada insumo representativo coletado junto às construtoras, multiplicada pelo peso que lhe é atribuído de acordo com o padrão calculado. Nas figuras 2.1 e 2.2 encontram-se os custos divididos de acordo com a unidade autônoma (tipo de construção e número de quartos), número de pavimentos e padrão de acabamento.

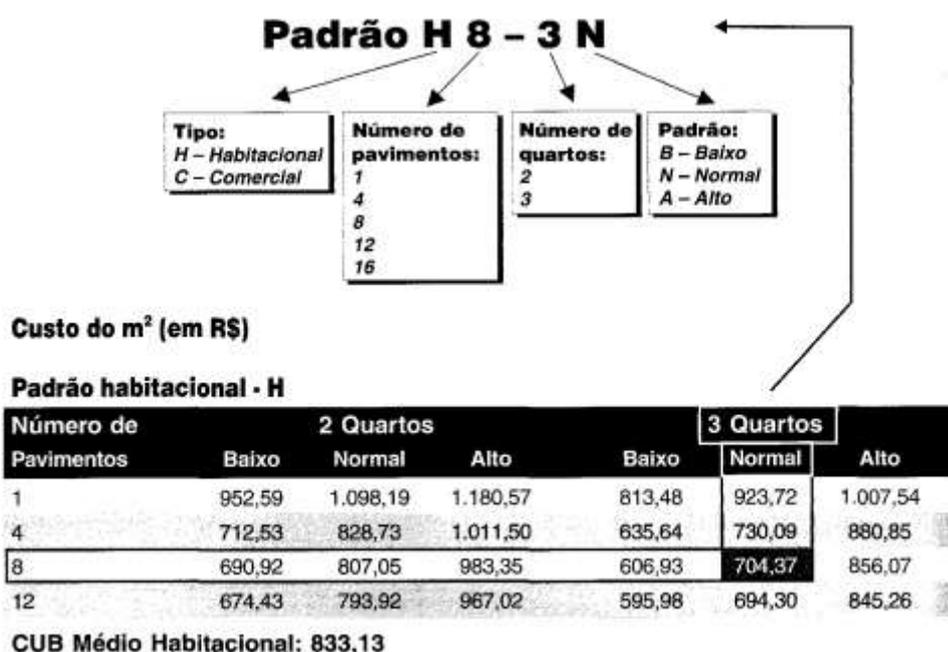


FIGURA 2.1 – Custo do m<sup>2</sup>, de acordo com as características da edificação

<b>Padrão comercial</b>						
Número de Pavimentos	Andares Livres – CL			Salas e Lojas – CS		
	Baixo	Normal	Alto	Baixo	Normal	Alto
4	540,54	601,82	783,60	580,71	643,05	841,38
8	607,16	668,12	845,96	641,04	701,03	892,59
12	553,22	611,32	777,33	588,58	645,48	826,79
16	531,14	591,71	745,74	567,13	623,66	797,58
<b>CUB Médio Andares Livres: 654,81</b>			<b>CUB Médio Salas e Lojas: 695,75</b>			
<b>Padrão galpão industrial (CG) e casa popular (CP1Q)</b>						
<b>CG – Padrão Galpão Industrial: 372,76</b>			<b>CP1Q – Casa Popular: 567,14</b>			

FIGURA 2.2 – Custo do m<sup>2</sup> (padrão comercial)

Para calcular o valor estimado da construção, multiplica-se o CUB correspondente pela área de construção. É importante ressaltar que o método do CUB é atualizado com o tempo, mas não leva em consideração as especificidades de construção que têm relação com a sua localidade.

Em relação a sua temporalidade, o CUB é atualizado mensalmente, fato que possibilita a análise de séries históricas de variação dos valores da unidade por mês. Disso decorre o Índice CUB, variação acumulada entre as mudanças de meses, em porcentagem. O índice é o indicador comparativo de preços da construção civil e os outros índices genéricos do mercado, como o IGP-M (Índice Geral de Preços - Mercado, da FGV).

### 2.3.2 Orçamento Preliminar

A principal diferença entre o orçamento preliminar e a estimativa de custos é o maior nível de detalhamento exposto no primeiro. Nele, já existe um levantamento mínimo de quantitativos e de custos dos serviços.

Além disso, os principais indicadores devem ser definidos e, conforme for aprimorada a estimativa inicial, vão se estabelecendo alguns indicadores-chave para a precisão do modelo preliminar. É interessante pontuar que a literatura de Mattos destaca a pouca flutuação desses indicadores ao longo do tempo, não importando um certo nível de variações devido às especificidades.

Uma prática recorrente e muito importante na orçamentação de obras para práticas licitatórias é a estimativa de custos segmentada por etapa. Os gastos financeiros esperados com cada etapa da obra são divididos de forma proporcional à sua relevância de investimento do responsável por executar o serviço. Tais percentuais constituem apenas um referencial para os reais custos parciais de obras, estando ainda sujeito a especificidades da localização do projeto. (MATTOS, 2006, 286p.)

ETAPA	% DO CUSTO TOTAL
Serviços preliminares	0,2 a 0,3%
Movimento de terra	0,0 a 1,0%
Fundações especiais	3,0 a 4,0%
Intra-estrutura	1,9 a 2,5%
Superestrutura	29,2 a 35,7%
Vedação	2,7 a 3,8%
Esquadrias	6,9 a 12,7%
Instalações Hidráulicas	10,8 a 12,5%
Instalações Elétricas	4,5 a 5,4%
Impermeabilização e Isolação térmica	1,3 a 2,6%
Revestimento (pisos, paredes, forros)	17,8 a 23,1%
Vidros	1,5 a 3,0%
Pintura	3,1 a 4,0%
Serviços complementares	0,2 a 0,8%
Elevadores	2,7 a 3,3%
TOTAL	100,0%

FIGURA 2.3 – Orçamento preliminar: percentis relativos ao custo total

### 2.3.3 Orçamento Analítico

A confecção do orçamento analítico é a mais detalhada do mercado. Ele é construído aliando o detalhamento dos custos e dos índices à intensa pesquisa de mercado para metrificar características recorrentes de obras que precisam devem complementar o modelo para que ele se aproxime ao máximo da realidade.

## 2.4 Estudos prévios de aprendizado de máquina em orçamentação de obras

Para contribuir com a orientação do projeto envolvendo Redes Neurais Artificiais para a composição de custos de obras públicas, envolveu-se uma intensa pesquisa por fontes contidas no acervo científico da área para que o trabalho em questão absorvesse os principais aprendizados já consolidados na área de aprendizado de máquinas utilizando redes neurais. Assim, dois artigos da comunidade científica brasileira se destacam por terem abordagens de solução semelhantes ao modelo matemático e a lógica de preparação da solução do problema.

A dissertação "Estimativa preliminar de custos de obras utilizando redes neurais artificiais" detalhou a pesquisa de métodos para estimativa de custos de novas obras e analisou as principais técnicas para resolução do problema de orçamentação preditiva, destacando as RNAs como mais precisas. (DACOREGIO, 2017)

O projeto em questão teve como base de entrada um conjunto de 40 elementos compostos por projetos (maior presença de dados qualitativos) e orçamentos, que foram organizados em grupos de serviços. O pré-tratamento da base de dados envolveu a atemporalização

dos valores orçamentários através de índices econômicos, em momento anterior à aplicação do algoritmo. (DACOREGIO, 2017)

Para as RNAs que compõem as obras completas utilizou-se 21 parâmetros direcionadores de custos. Inicialmente, as RNAs foram configuradas conforme indicações da literatura consultada. Essa configuração inicial foi ajustada por método de simulação, até que uma das arquiteturas resultasse em precisão considerada satisfatória. (DACOREGIO, 2017)

Complementando os possíveis modos de análise do mesmo tipo de problema, o desenvolvimento da tese "Aplicação de Redes Neurais Artificiais no contexto de custos de construção de rodovias" avalia a precisão de redes neurais artificiais a partir da variação de outros parâmetros do modelo matemático. (BARROS, 2019)

Utilizando uma amostra de 25 projetos, a análise da rede neural foi realizada a partir de uma arquitetura perceptron de múltiplas camadas e da construção da base de entrada com 11, 10 e 5 parâmetros de diferentes topologias a fim de verificar a robustez da ferramenta. (BARROS, 2019)

A validação das estimativas foi feita pela comparação entre o valor estimado pelas RNAs e o custo real das obras. Obteve-se o erro médio de custos de construção de rodovias. No modelo que atingiu o melhor resultado, após sucessivos testes, foram utilizados apenas 5 parâmetros de entrada, com 15 neurônios e função tangente hiperbólica na camada oculta e 1 neurônio na camada de saída, utilizando a função linear. (BARROS, 2019)

## 3 Metodologia

### 3.1 Escolha das variáveis

O processo de estruturação e validação de uma Rede Neural Artificial está intimamente relacionado às características da base de dados utilizada para o seu treinamento e validação. Conforme o conjunto de dados aumenta e se diferencia, maior é a capacidade da rede generalizar a sua solução e realmente trazer resultados mais próximos do desejado, por já ter aprendido com um número relevante de casos e por isso saber diferenciar as possíveis soluções para cada contexto. (COSTA, 1999)

Devido à necessidade acima explicitada, o projeto seguiu as seguintes etapas para a correta definição das variáveis a serem utilizadas como *input* no problema em questão: seleção e compilação das planilhas orçamentárias disponíveis, transformação dos dados brutos em variáveis conectadas com o problema e tratamento efetivo da base de dados obtida.

Conforme detalhado nos objetivos do projeto, o trabalho visa modelar uma rede neural que se adeque ao contexto, à situação e às características da orçamentação de obras públicas que se relacionam com os projetos e serviços planejados pela Comissão de Obras do Departamento de Ciência e Tecnologia Aeroespacial. Dessa maneira, a integridade da base de dados utilizada para a definição e escolha das variáveis se originará exclusivamente dos arquivos da equipe responsável pela orçamentação dentro do instituto. (SILVA, 2016)

Foram obtidos detalhamentos de obras com um alto nível de diversidade, envolvendo projetos construtivos em sua completude e reformas de edificações que já estão em uso. Os serviços descritos se referem a construções e serviços demandados, em sua maioria, pelos órgãos que compõem o DCTA e no restante por outras instituições da Força Aérea Brasileira (FAB). Para cada um deles, existem alguns dados que comutam entre todas os orçamentos feitos: descrição do tipo de projeto, data da execução do orçamento, local da obra, benefícios e despesas indiretas calculados, valor total do orçamento e os serviços a serem realizados na futura obra, já orçados. Após a devida verificação das planilhas disponibilizadas, foram selecionados 49 orçamentos de construções e reformas que compõem a base de dados deste projeto.

Ainda, os orçamentos aproveitados possuem uma grande riqueza de detalhamento dos serviços a serem fornecidos, segmentados em dez possíveis tipos que podem ou não serem requisitados em cada projeto. São eles:

1. Serviços técnico-profissionais
2. Serviços preliminares
3. Fundações e estruturas
4. Arquitetura e elementos de urbanismo
5. Instalações hidráulicas e sanitárias
6. Instalações elétricas e eletrônicas
7. Instalações mecânicas e utilidades
8. Instalação de prevenção e combate a incêndio
9. Serviços complementares
10. Serviços auxiliares e administrativos

Cada tipo de serviço e instalação possui uma determinada fração do orçamento destinada a sua execução que por sua vez representa uma certa porcentagem do orçamento total que está sendo destinada ao trabalho em questão.

O intenso detalhamento dos orçamentos analíticos empregados traz alguns desafios para a construção do modelo matemático deste trabalho. A alta especificidade dos tipos de dados trabalhados tem como ponto positivo a maior possibilidade dos mesmos serem capazes de produzir uma rede neural bem ajustada para o problema em questão, que conseguirá definir as principais variantes de orçamentação de obras para o contexto da CODCTA por ter sido treinada a partir delas. Em contrapartida, o modelo provavelmente terá maiores dificuldades de precisão para encontrar respostas para problemas mais variados que envolvem estimativas paramétricas de orçamentos. (SILVA, 2016) Tal consequência pode ser ilustrada através da pesquisa pública de eventuais precificações de obras. Nestas, a maioria das informações têm menor grau de especificidade e abordam contextos mais genéricos das obras.

Um outro fator que também demandou uma análise mais aprofundada foi o dos aspectos qualitativos dos orçamentos apresentados. Não haviam informações já setorializadas sobre os objetos que foram construídos ou reformados. Tais informações enriquecem consideravelmente a rede neural por serem capazes de correlacionar de forma mais assertiva o contexto real do problema com os seus respectivos custos de operação. Dessa forma,

houve a necessidade de executar a segmentação prévia dos serviços de acordo com o seu tamanho, a sua duração e complexidade, variáveis que interferem na definição dos custos de uma obra e de seu canteiro.

Dessa forma, as variáveis selecionadas para compor o conjunto de *inputs* do problema são:

- Tipo do orçamento (construção ou reforma)
- Mês e ano do orçamento
- Localização da obra (por região)
- Porte da obra
- Tempo relativo de duração da obra
- BDI calculado
- Tipos de serviço necessários e respectiva relevância frente ao trabalho total demandado

Todos os fatores acima contribuirão para o cálculo do *output* final da rede neural que é o orçamento aproximado demandado para a execução do serviço, contribuindo para a validação da ordem de grandeza final do orçamento analiticamente calculado.

## 3.2 Tratamento de dados

As variáveis escolhidas são apresentadas em diferentes formatos, de acordo com o seu tipo e a sua forma de representação. A disparidade entre esses formatos traz um desafio de aprendizagem para as redes neurais, por essas serem ajustadas a partir da variação numérica dos *inputs* selecionados. (SILVA, 2016)

Dessa forma, o tratamento dos dados selecionados torna-se essencial para a eficiência do modelo proposto. O processo inicial de tratamento consiste na observação criteriosa acerca dos tipos de dados do problema. Anseia-se por transformá-los em um conjunto padronizado de valores quantitativos. Para isso, é importante construir relações bem definidas entre a característica do orçamento qualitativa e o valor quantitativo obtido. Ainda, deve ser levado em consideração no processo a máxima generalização das variáveis, para que seja possível adicionar novas unidades dentro da base de dados que consigam influir positivamente para a acurácia da rede neural, simulando uma possível necessidade do operador do modelo.

O primeiro passo executado para iniciar o tratamento dos dados das 49 obras disponibilizadas foi a compilação dos dados correspondentes às variáveis selecionados em uma única planilha-base. Com a base única criada, iniciou-se os aprimoramentos em seus dados, descritos e justificados nos próximos parágrafos. A base de dados inicial explorada neste trabalho está apresentada no Anexo A.

O tempo de duração previsto de obras é uma informação essencial, por afetar vários custos orçamentados recorrentes que dependem do período de duração da obra. As obras analisadas tinham tempo de duração que variava entre 1 e 15 meses, que foram classificadas entre obras de curto (1 a 3 meses), médio (4 a 8 meses) e longa duração (9 ou mais meses) e posteriormente transformadas em um valor entre 0 e 1, em que 1 é o valor relacionado a obras com a duração máxima prevista na base de dados.

A segunda segmentação executada se refere ao tamanho (porte) de cada obra/serviço. Pela base de dados se referir a um conjunto de informações que possuem orçamentos muito dispare, definiu-se o porte da obra como pequeno, médio e grande porte. Obras de pequeno porte se referem a construções e reformas que possuem custo menor que R\$ 300.000,00. As obras entre R\$ 300.000,00 e R\$ 1.000.000,00 foram classificadas como de médio porte e as que possuem orçamento total superior a R\$ 1.000.000,00 serão consideradas de grande porte.

As classificações utilizadas foram sugeridas apenas para viabilizar análises futuras a partir do agrupamento dos dados com os quais esteja sendo trabalhado e não será aplicada como segmentação da base de dados utilizada no modelamento matemático.

Para considerar a influência do local de execução do serviço, será utilizado o Sistema Nacional de Pesquisa de Custos e Índices da Construção Civil - SINAPI. Cada região brasileira possui um resultado do SINAPI relativo aos custos locais de edificações. Para o artigo em questão, utilizaremos o Índice SINAPI de julho de 2014 como referência. O índice é calculado a partir do custo médio do metro quadrado na referida região na data descrita. A partir da relativização do valor do custo médio (em reais) para julho de 2014, obtém-se os seguintes resultados do SINAPI por região:

- Região Norte: 476,52
- Região Nordeste: 481,01
- Região Sudeste: 484,34
- Região Sul: 466,77
- Região Centro-Oeste: 488,67

Visando o melhor ajuste possível da rede neural a partir do tratamento dos dados iniciais, toma-se a Região Sudeste como referência para a transformação dos índices acima

representados em variáveis relativizadas. Assim, tem-se que cada região se traduzirá nos seguintes resultados na base de dados tratada:

- Região Norte: 0,984
- Região Nordeste: 0,993
- Região Sudeste: 1,000
- Região Sul: 0,964
- Região Centro-Oeste: 1,009

A evolução da precificação dos itens que compõem orçamentos de obras públicas está intimamente correlacionada com o período e o ano de realização dos projetos. Torna-se portanto indispensável a devida correção monetária dos preços observados em anos diferentes para que seja capaz de obter-se um bom aprendizado da rede neural, com comparações calibradas pelo ano de acontecimento. O principal e mais utilizado indicador da construção civil é o INCC (Índice Nacional do Custo de Construção), calculado pela Fundação Getúlio Vargas anualmente. Assim, considerando como base o ano de 2014, a variável do problema relativa à correção monetária será considerada como a multiplicação dos INCC acumulados anuais relativos aos anos anteriores à realização da obra até 2014. A tabela 3.1 apresenta o INCC acumulado anual e o valor consolidado que é acrescido aos cálculos orçamentários de obras por ano de realização:

TABELA 3.1 – INCC acumulado anual e Relações da Rede Neural

Ano de execução da obra	INCC acumulado do ano anterior	Variável a ser inserida na RNA
2015	6,94 %	1,0694
2016	7,49 %	1,1495
2017	6,1 %	1,2196
2018	4,24 %	1,2713
2019	3,83 %	1,32
2020	7,31 %	1,3746

Os dados que restam ser tratados são os que formam a composição de serviços contidos em cada orçamento. Tais dados são inicialmente apresentados em reais e dependem dos objetivos e condições de contorno de cada obra. Entretanto, para a previsão orçamentária em questão, é interessante sugerir, para o usuário final, noções da segmentação orçamentária por tipo de serviço executado para as diferentes características das obras. Por estas terem o seu valor final de custo total da obra muito diferentes entre si, optou-se pela representação dos orçamentos de cada serviço pela porcentagem do custo total da obra.

## 3.3 Redes Neurais Artificiais

### 3.3.1 Introdução

Redes Neurais Artificiais são uma forma de inteligência artificial, isto é, um modelo de simulação da aprendizagem humana a partir de experiências prévias e é cada vez mais estudada e aprimorada pela sociedade científica, devido à sua vasta aplicabilidade para resolver problemas do cotidiano. (ALMEIDA, 1995)

Os principais tipos de problemas que as RNAs ajudam a resolver são: classificação de padrões, aproximação de funções, segmentação de classes e predição de séries temporais. No trabalho em questão, todo o estudo será direcionado para a aproximação de funções, isto é, para a construção de um modelo matemático ajustado a partir dos dados de entrada que consiga prever o orçamento final demandado apenas de posse dos dados de entrada que descrevem a nova obra a ser verificada. (ALMEIDA, 1995)

### 3.3.2 Modelo Matemático

Matematicamente falando, Redes Neurais Artificiais são um conjunto de equações diferenciais não lineares com parâmetros ajustáveis através dos dados disponíveis. É composta por várias unidades de processamento que são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. (COSTA, 1999)

Por ser um método que utiliza aprendizado de máquina, as RNA's são classificadas como "inteligentes" por se valerem dos resultados pré-obtidos em sua inicialização para ajustar os parâmetros (pesos) e obter a melhor função de aproximação possível para o contexto abordado. A figura 3.1 apresenta o modelo esquemático de desenvolvimento de uma rede neural artificial. Posteriormente, será apresentado também o detalhamento de seus componentes. (CARVALHO, 2013)

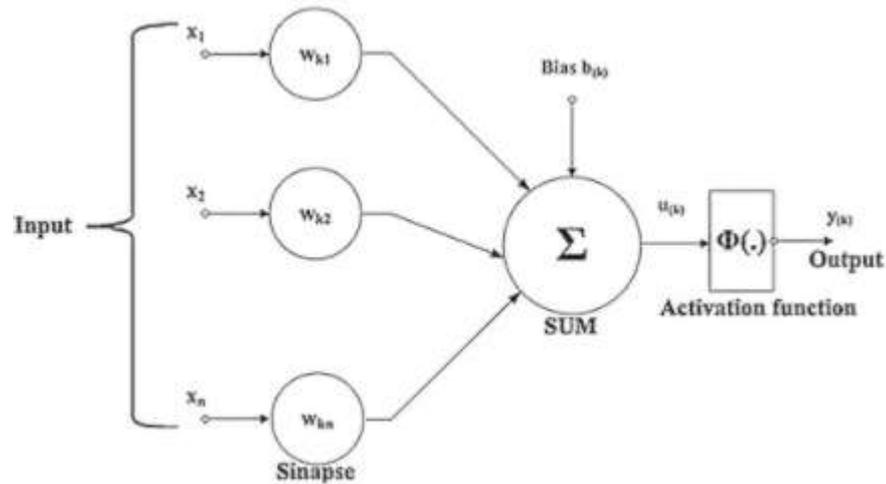


FIGURA 3.1 – Modelo esquemático de uma unidade de processamento

Inicialmente, são apresentados à rede neural os *inputs* necessários para o seu treinamento através de um vetor de entrada. Os dados iniciais são assimilados pelos elementos de processamento simples da rede, denominados sinapses (ou neurônios). O neurônio é composto por um peso e um *bias*. O *input* é multiplicado pelo peso que indica a sua influência na saída da unidade. O *bias* é um valor constante adicionado à multiplicação anterior que tem por função acrescentar graus de liberdade extras para o neurônio é consequentemente para a rede neural, permitindo resultados mais adaptáveis à base de treinamento. (CARVALHO, 2013)

Após o devido processamento nos neurônios, ocorre a soma ponderada dos sinais obtidos. Essa soma é o parâmetro ao qual será aplicada a função de ativação, cujo objetivo é limitar a saída do neurônio em uma determinada faixa de valores para que seja possível identificar a qualidade do *output* obtido. Os neurônios são apresentados e organizados em “camadas”, conectadas umas às outras, como apresentado no exemplo da figura 3.2. (CARVALHO, 2013)

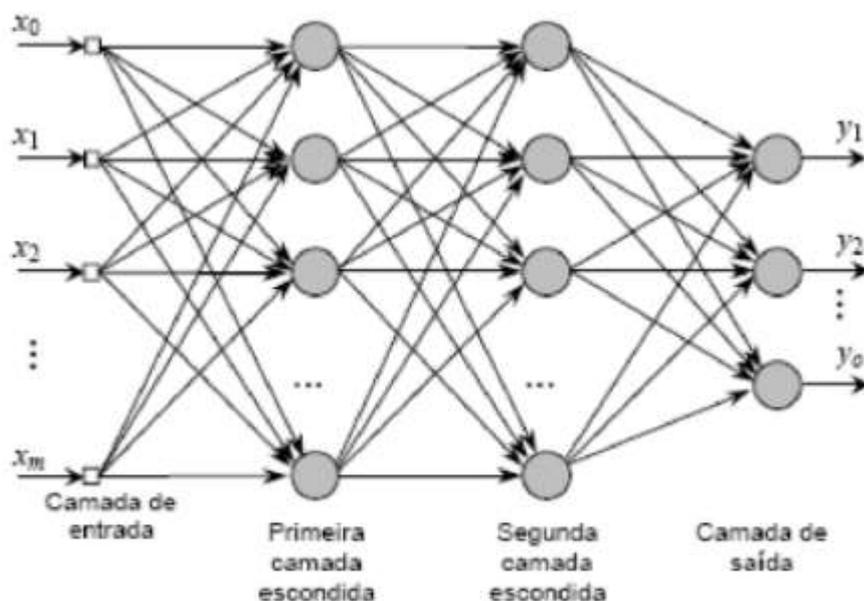


FIGURA 3.2 – Exemplo de rede neural composta de neurônios organizados em camadas.

Comumente, as camadas de uma rede neural artificial são classificadas em três diferentes tipos: a camada de entrada, onde os *inputs* são apresentados à rede, a(s) camada(s) intermediária(s) ou escondida(s), responsáveis pela maior parte do processamento envolvido no modelo matemático, e a camada de saída, em que o resultado final do processo é apresentado.

### 3.3.3 Processo de aprendizagem

Dispostas as apresentações dos componentes da rede neural, define-se então o processo de aprendizagem do sistema, propriedade fundamental e caracterizadora do modelo em questão. A capacidade de compreender os dados a ele apresentado e, findado a iteração inicial dos mesmos através das camadas, comparar o *output* definido com o valor esperado traz um importante poder de melhoria da aproximação definida. (DATA..., 2019)

O fluxo acima descrito é repetido até que se atinjam aproximações suficientemente concisas com o que espera-se da rede neural. O aprendizado é dito concluído quando a rede atinge uma solução generalizada para uma classe de problemas. Existem várias formas de se desenvolver o processo de aprendizagem e sua diferença principal consiste na forma como as variáveis da RNA (pesos e *bias*) são modificadas ao longo do treinamento. Em geral, o tipo de aprendizado de uma rede neural pode ser classificado entre supervisionado e não-supervisionado. (CARVALHO, 2013)

O supervisionamento ocorre a partir de um conjunto de dados de entrada previamente definidos. Almeja-se encontrar uma função que seja capaz de prever futuros problemas

com valores iniciais desconhecidos. Nesse tipo de aprendizagem pode-se estimar números reais ou valores dentro de um conjunto finito, condicionado ao contexto e ambiente. A aprendizagem supervisionada é capaz de analisar as características de cada *input* e retornar resultados relativamente precisos, de acordo com a ordem de grandeza do erro esperado. (COSTA, 1999)

Por sua vez, no processo de aprendizagem não-supervisionado o conjunto de dados utilizado não possui nenhum tipo de rótulo. O objetivo do método é descobrir similaridades entre os dados analisados a fim de reconhecer padrões e disparidades a fim de criar agrupamentos a partir destas características. Dessa forma, cada agrupamento será formado a partir de características semelhantes, sendo capazes de ter um afinamento dos tipos de dados existentes, finalmente tratados. (SILVA, 2016)

O presente trabalho, por dispor de valores esperados dos *outputs* da rede, terá enfoque no aprendizado supervisionado.

### 3.3.4 Treinamento Supervisionado

O treinamento supervisionado para o modelo de rede neural em questão consiste no sequencial ajuste dos pesos e da função de ativação de cada unidade para que a aproximação obtida esteja suficientemente próxima à desejada. (CARVALHO, 2013)

Para a adaptação da função de ativação, o processo consiste em aprimorar a calibração dos relacionamentos entre a amplitude de variação dos somatórios dos neurônios e a amplitude de valores obtidos a partir da função utilizada. (COSTA, 1999)

A ação posterior à apresentação do vetor de entrada à rede envolve a utilização do resultado final obtido. Após medir a distância entre a resposta atual e a desejada, são realizados os ajustes apropriados nos pesos das conexões de modo a reduzir esta distância até que um nível satisfatório previamente determinado seja atingido.

É possível segmentar as etapas do processo de treinamento em alguns passos. A rede neural é iniciada com todas as suas conexões possuindo pesos aleatórios e já com o nível máximo de erro apropriado definido. O *output* gerado é comparado com o valor desejado a partir do erro médio. Caso este esteja maior do que o limite estabelecido, calcula-se novamente os pesos de todas as conexões, a partir da seguinte relação:

$$W_{novo} = W_{antigo} + V_{aprendizado} * Erro_{medio} \quad (3.1)$$

O procedimento é repetido sucessivas vezes, até alcançarmos o nível de aproximação apropriado. A função de ativação é escolhida analisando os aspectos e aplicações em contexto dos métodos disponibilizados no software utilizado.

### 3.4 Configuração computacional da Rede Neural

Todo o processo citado no item 4.1 está contido no algoritmo do Neural Net Fitting do software *MATLAB*. Dentre as várias classes de rede neural existentes, trabalharemos com uma rede neural multi-camadas, que é o tipo mais comum de rede neural adotadas para resolver o problema em questão, juntamente com o aplicativo selecionado, instalado na versão *MATLAB Online R2020a*. (PACHECO, 2014)

Os dados de entrada e de saída são importados em um arquivo de texto para o ambiente do software. Para que seja possível utilizar a função do *MATLAB* de rede neural para ajuste de curvas, foi necessário segmentar a base importada em duas bases: a matriz de *inputs* e a matriz-coluna de *outputs*. Em problemas de ajuste, o programa colaborará com a criação, treinamento e avaliação da performance da RNA a partir do erro médio quadrático e análises de regressão. (PACHECO, 2014)

A arquitetura do modelo disponibilizado no *MATLAB* é caracterizada por uma rede neural de duas camadas, sendo a primeira delas com a função de ativação sigmóide e a segunda com a função linear, sendo essa recomendada para problemas de ajuste multidimensional, desde que os dados de entrada tenham sido tratados e haja um número suficiente de neurônios na camada intermediária.

Dessa forma, definindo a matriz de entrada e o vetor de saída, segmenta-se a base de dados em três partes: treinamento, validação e teste. A base de treinamento será apresentada à rede neural e se ajustará ao seus erros. A de validação é responsável por mensurar a generalização com a qual a rede está contribuindo e, simultaneamente, treiná-la para melhorar a sua eficiência. Já a base de teste não tem função para o treinamento e apenas nos informa a performance da rede ao longo do treinamento e da validação. (PACHECO, 2014)

### 3.5 Treinamento e inserção de dados

A partir desse ponto, o último passo necessário para treinarmos a rede neural é o de escolher o método de treinamento. O *MATLAB* oferece a oportunidade de se utilizar 3 métodos: Levenberg-Marquardt, Bayesian Regularization, Scaled Conjugate Gradient.

O método Levenberg-Marquardt frequentemente é considerado como o mais rápido dos algoritmos de treinamento retropropagação do erro, porém requer mais memória computacional do que os outros algoritmos.

A Bayesian Regularization minimiza a combinação dos erros quadráticos e os pesos, para então produzir uma rede generalizada e com respostas mais suaves (MACKAY, 1992;

FORESSE e HAGAN, 1997).

Já o algoritmo Scaled Conjugate Gradient requer menos memória. O treinamento para automaticamente quando a generalização para de melhorar, conforme indicado por um aumento no erro quadrático médio das amostras de validação.

O método Levenberg-Marquardt é o mais adequado quando se preza pela velocidade do treinamento, enquanto o Scaled Conjugate Gradient é o mais indicado para casos em que o fator limitante é a memória computacional. Partindo da premissa da existência do limitante computacional e de velocidade de convergência, o resultado ótimo para a predição em questão é o método Bayesian Regularization. (RODRIGUES, 2020)

### **3.6 Método de avaliação dos resultados**

Após a realização das devidas configurações (seleção dos dados de entrada, definição do número de neurônios na camada escondida, segmentação da base de dados em treinamento, validação e teste e escolha do método de treinamento Bayesian Regularization, a rede neural pode então ser treinada. Para a devida mensuração da qualidade do resultado final, retorna-se para as três segmentações o erro quadrático médio e o valor de R. (SILVA, 2016)

Ainda, é possível avaliar o resultado obtido a partir do número de interações necessárias para a convergência, o tempo decorrido, a performance, o gradiente e o erro calculado.

## 4 Análise dos resultados

### 4.1 Treinamento da RNA no ambiente de simulação

Para executar o ajuste da curva da Rede Neural a partir dos dados de entrada, realizou-se a importação da base de dados para o *MATLAB (Versão Online R2020b)* a partir de um arquivo .csv. A base em questão é inicialmente destrinchada em duas bases: a matriz de entrada, com 14 variáveis e o vetor de saída.

Com a base de dados devidamente preparada, inicia-se a configuração do *nftool* ferramenta de ajuste da rede neural, a partir da interface gráfica que surge ao abrir janela.

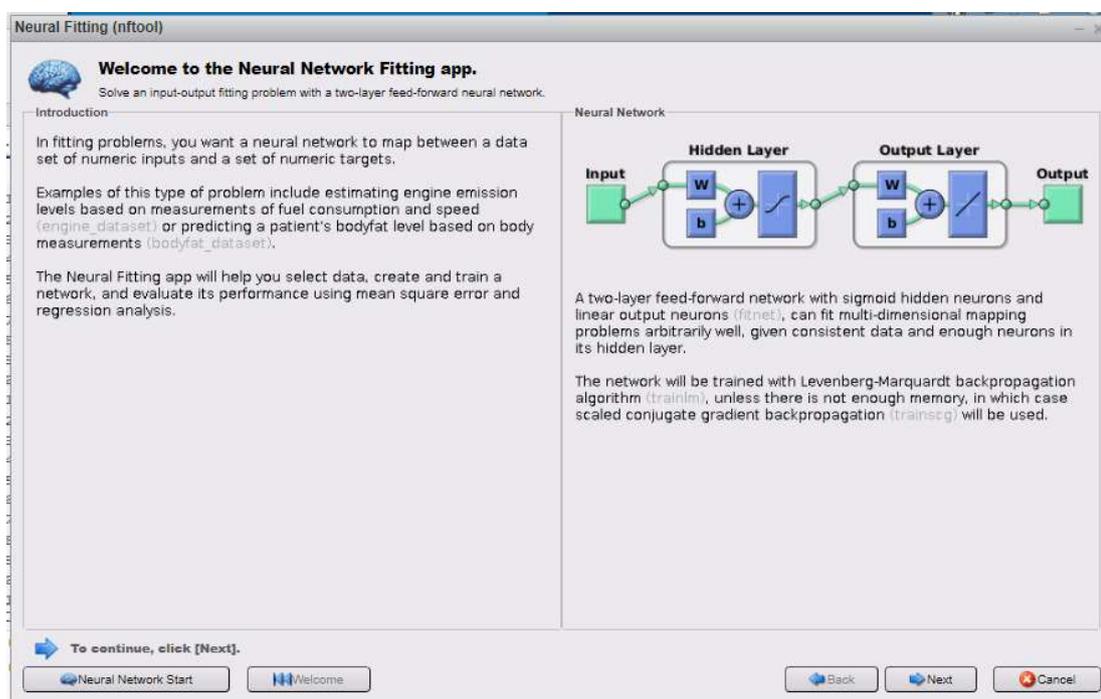
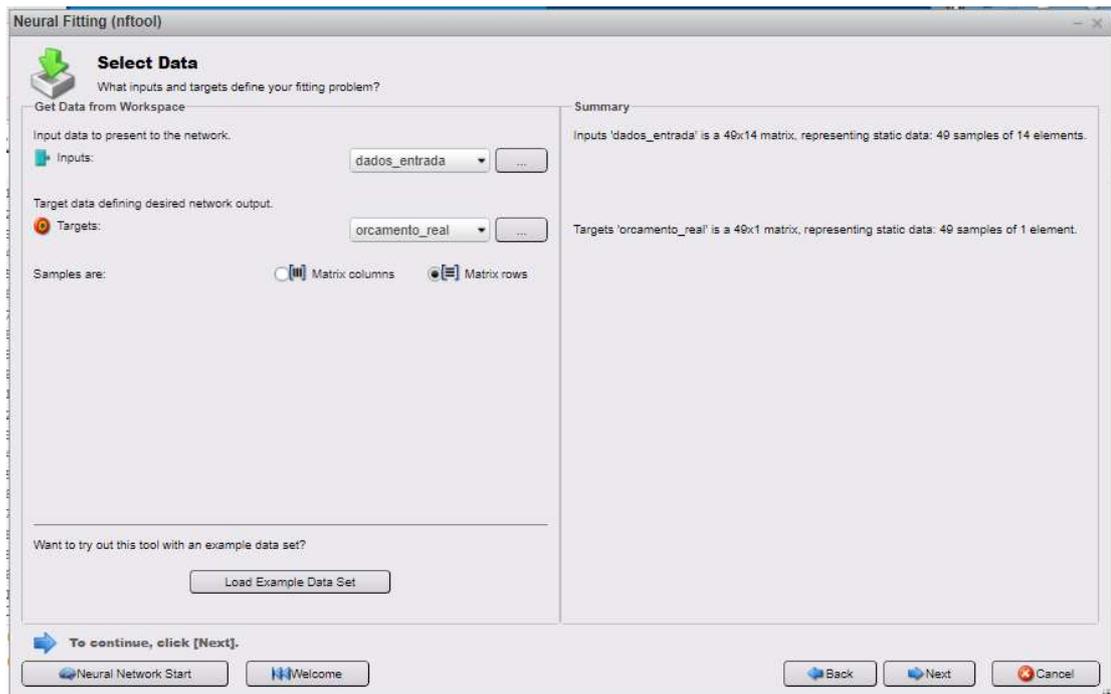


FIGURA 4.1 – Janela inicial do *nftool*

Ao clicar em “*Next*”, é possível selecionar a matriz de Inputs e o vetor de outputs desejados (alvos) ao qual devemos nos aproximar. Por fim, seleciona-se a forma de ordenação dos dados (colunas ou linhas).

FIGURA 4.2 – Escolha dos *inputs* e *outputs*

Apresenta-se então as porcentagens de valores do conjunto de dados de entrada que serão utilizadas para treino, validação e teste, sendo possível editar as porcentagens de validação e de teste, mas sempre com a porcentagem para os dados de teste com um valor mais elevado que o restante, pois são esses dados que serão treinados pela RNA. No trabalho em questão, todas as possíveis distribuições de formatos de segmentação da base de dados entre as três etapas do processo foram testadas. O modelo utilizará 70% da base como treino, 15% como validação e os 15% restantes como base de testes, valores que propiciaram as melhores condições de ajuste. A validação consiste em medir o erro que a rede comete quando generaliza e permite controlar o processo do treino que termina quando este erro é suficientemente reduzido. O erro no subconjunto de teste não tem influência sobre o processo do treino e permite uma medida independente do desempenho da rede treinada. (SILVA, 2016)

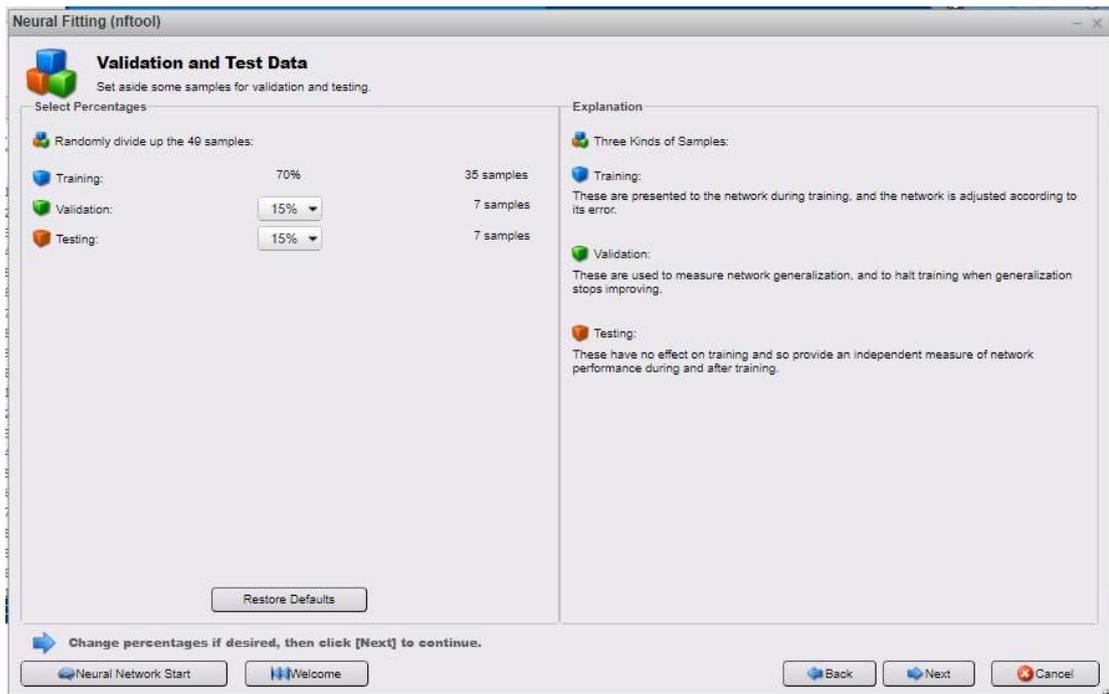


FIGURA 4.3 – Definição das porcentagens de segmentação da base de dados inicial

O último ajuste necessário é a escolha do número de neurônios pelos quais a rede neural será composta. Esse número pode ser reajustado de acordo com a performance do modelo após o treinamento. Para o trabalho em questão, por conter um número relevante de variáveis de entrada, variou-se também o número de neurônios utilizados no treinamento da rede neural a fim de avaliar qual configuração trazia os melhores resultados possíveis para o modelo. A partir dos sucessivos testes, definiu-se como 20 o número ótimo de neurônios.

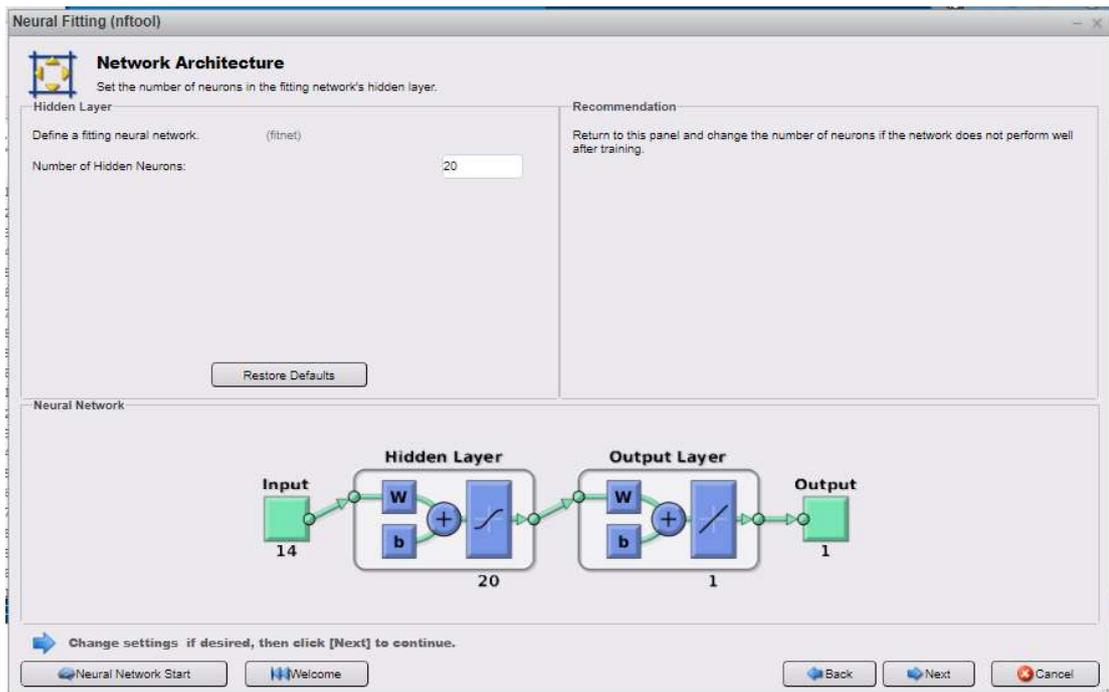


FIGURA 4.4 – Arquitetura da Rede Neural

Realiza-se o treinamento da rede neural arquitetada a partir do algoritmo “*Bayesian Regularization*”. O progresso do treino pode ser acompanhado através da variação dos parâmetros ao longo do tempo. Estes parâmetros têm valores limites, terminando o treino quando é atingido um destes valores limite. (SILVA, 2016) O comportamento e os resultados da rede neural do projeto podem ser observados na figura 4.5.

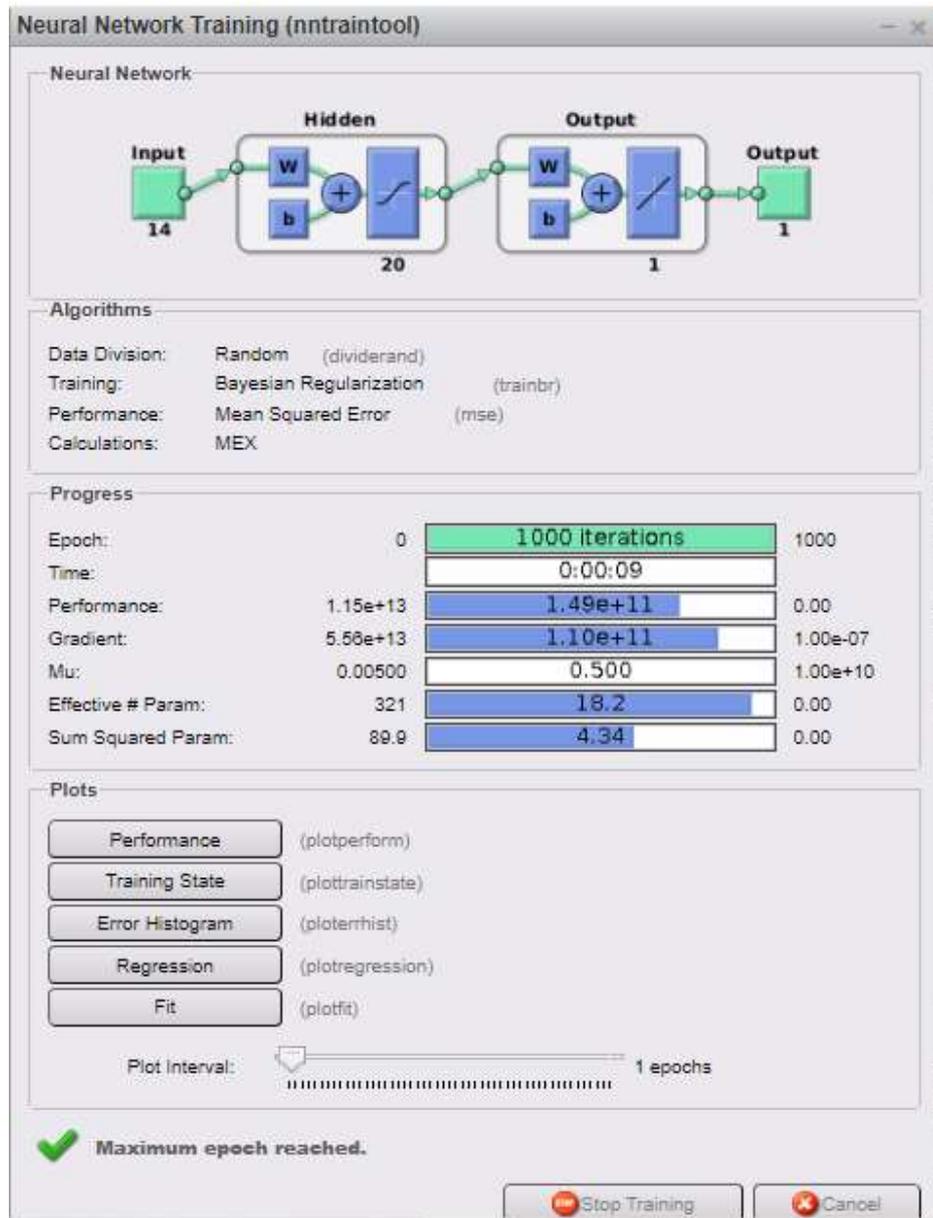


FIGURA 4.5 – Indicadores relativos ao treinamento da RNA

Os principais parâmetros que influenciam a qualidade do treinamento são a performance e a qualidade das regressões obtidas. A performance está relacionada com o erro quadrático médio, enquanto a qualidade das regressões pode ser avaliada a partir do valor de R, que é melhor quanto mais próximo de 1 a variável for.

## 4.2 Discussão dos resultados

O modelo final não apresentou bons resultados tendo em vista o erro quadrático médio. Isso decorreu devido à grande pulverização da base de dados: por conter um número reduzidos de dados que possuem outputs desejados muito altos (da ordem de milhões) e

muito baixos (próximos a vinte mil reais), houveram alguns erros calculados de módulo alto que contribuíram significativamente para o erro quadrático médio geral, como mostra o histograma da figura 4.6.

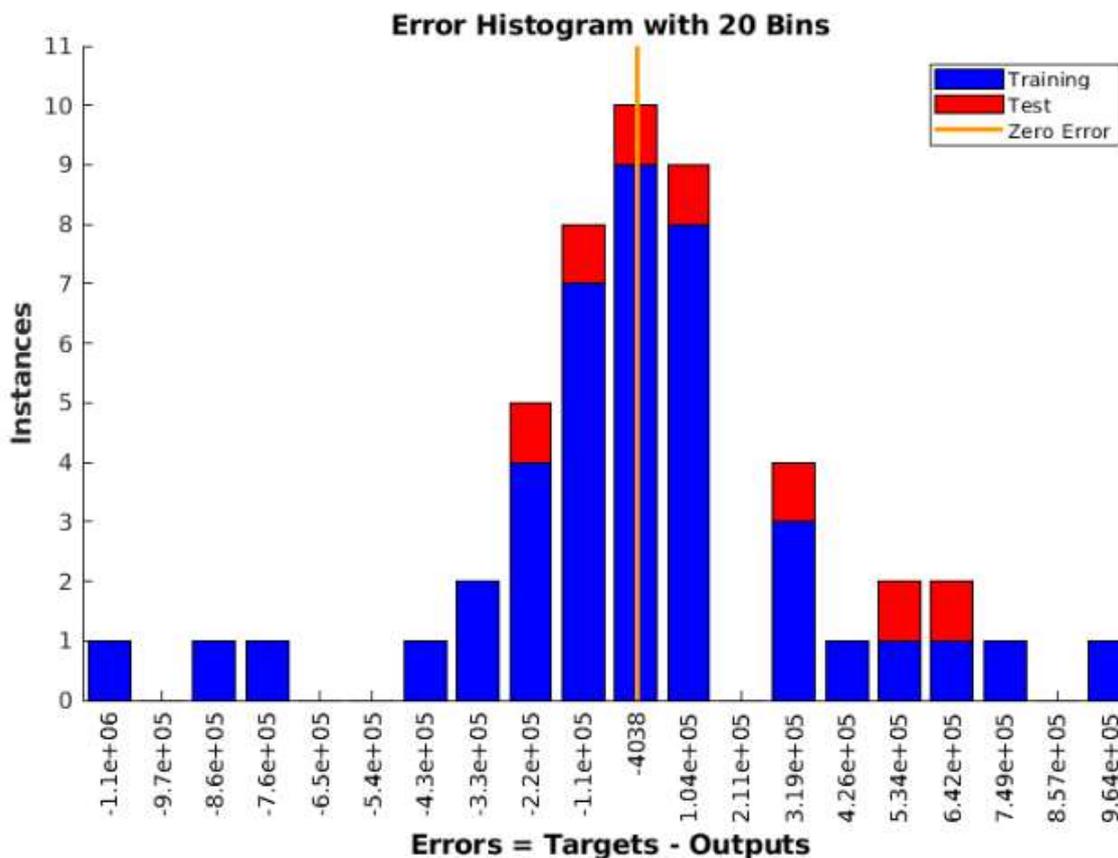


FIGURA 4.6 – Histograma dos erros calculados ao longo do treinamento

Em relação ao valor de R, foram obtidos bons valores para as etapas de treinamento e de teste que alcançaram os valores de 0.95533 e de 0.9637, respectivamente. O valor de R para o ajuste como um todo ficou em 0.9594. Os gráficos resultantes das regressões lineares realizadas trazem uma análise visual do ajuste obtido, conforme apresentado na figura 4.7:

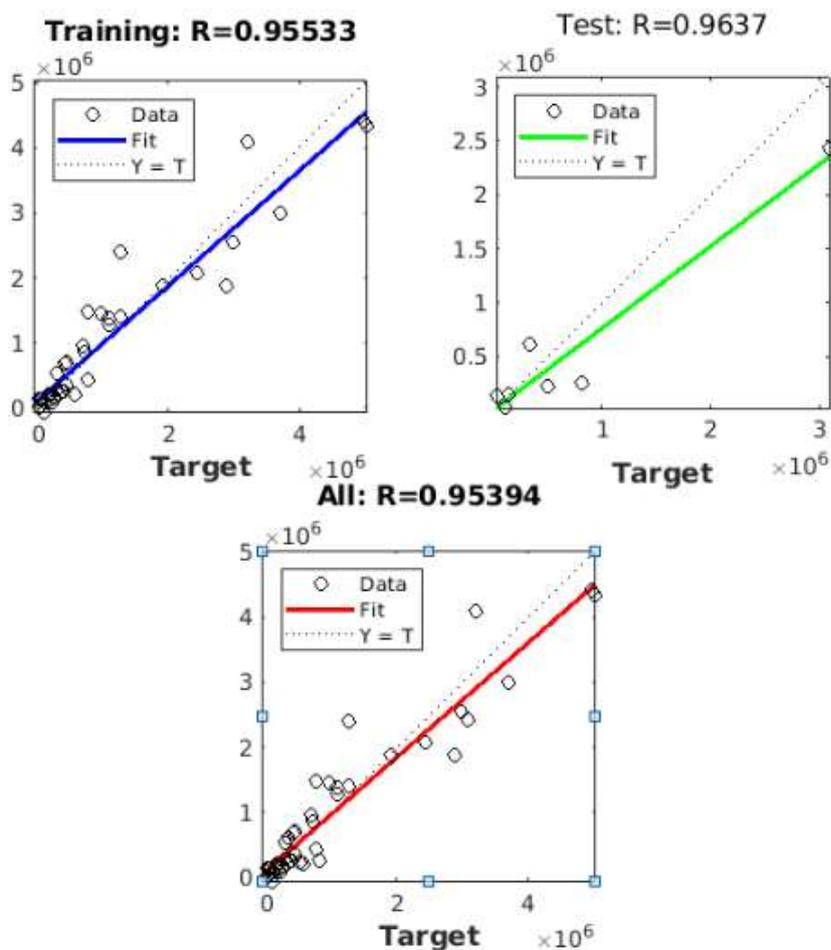


FIGURA 4.7 – Gráficos e valores das regressões lineares obtidas a partir do treinamento

Uma segunda análise foi feita a partir da redução do número de variáveis ofertadas pela base de dados iniciais. Como a parte dos dados que compunha as porcentagens do orçamento total eram referentes a serviços de grande abrangência, tomou-se como adaptação a redução para apenas uma coluna de porcentagem do orçamento total que está relacionada com o acabamento e o nível de detalhismo da obra.

Todo o processo acontecerá da mesma forma, a partir do mesmo tipo de treinamento "Bayesian Regulation" utilizado na 1ª análise devido à inalteração do formato da base de dados requisitada. (RODRIGUES, 2020) e com uma camada de 15 neurônios, a partir da verificação do número ótimo de neurônios na camada escondida por meio de sucessivos testes.

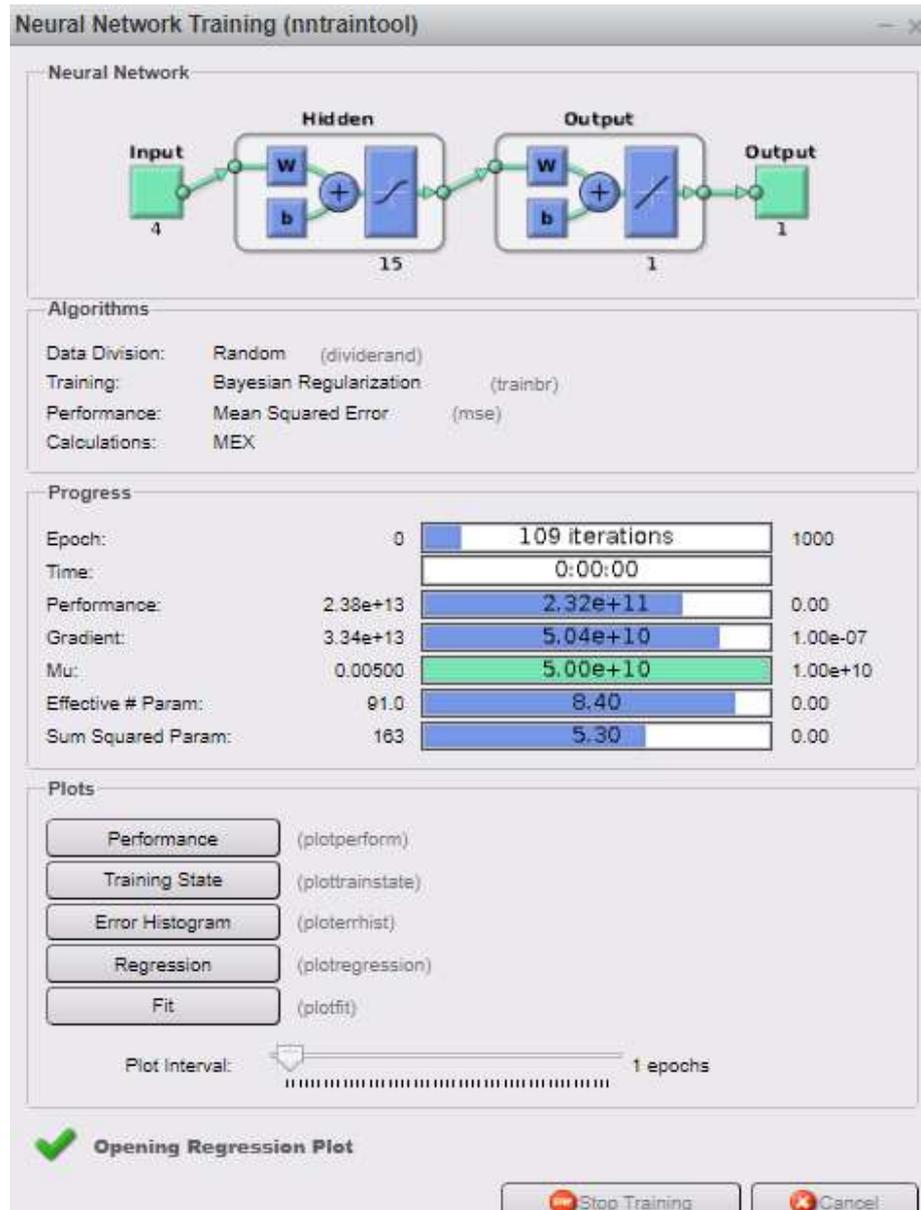


FIGURA 4.8 – Indicadores relativos ao treinamento da RNA - 2ª análise

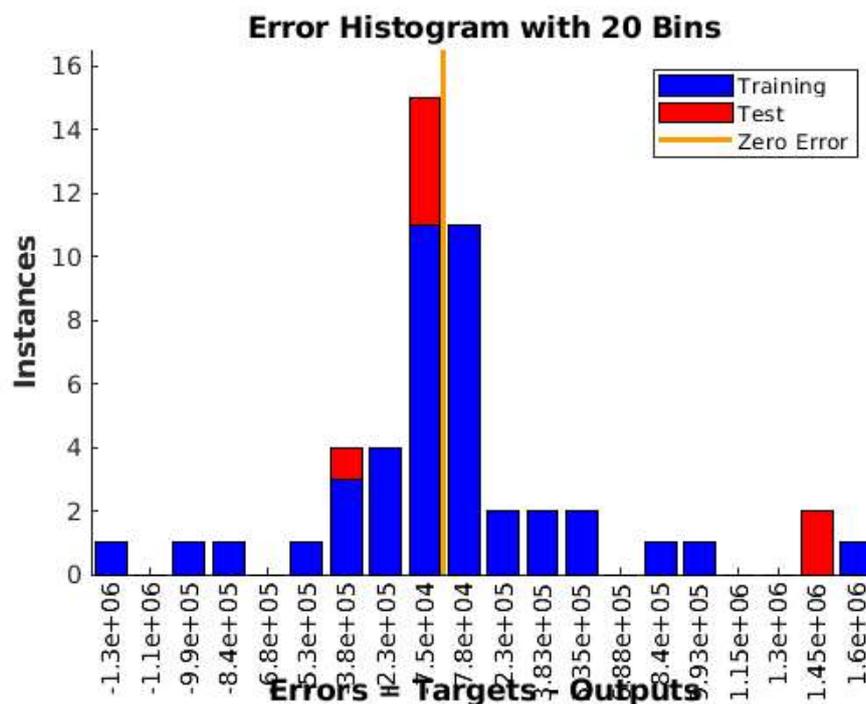


FIGURA 4.9 – Histograma dos erros calculados ao longo do treinamento - 2ª análise

Ao final dos treinamentos e testes, o resultado obtido para os valores dos pesos e bias definidos nas camadas escondidas podem ser visualizados pela janela de comandos do *MATLAB*. A capacidade de testarmos e calcularmos novos outputs a partir da entrada de novos inputs foi um dos fatores preponderantes para a escolha do software, visto o interesse do projeto em ser capaz de se tornar uma ferramenta preditora da ordem de grandeza do custo final de obras.

Ao final dos treinamentos e testes, o resultado obtido para os valores dos pesos e bias definidos nas camadas escondidas podem ser visualizados a partir dos comandos *net.LW*, *net.IW* e *net.b*.

A capacidade de testarmos e calcularmos novos outputs a partir da entrada de novos inputs foi um dos fatores preponderantes para a escolha do software, visto o interesse do projeto em ser capaz de se tornar uma ferramenta preditora da ordem de grandeza do custo final de obras. (GONÇALVES, 2010)

O ajuste da rede neural foi prejudicado pela grande abrangência dos dados e pela precária clusterização dos mesmos, impedindo que os resultados trouxessem aprimoramentos de boa qualidade. Apesar disso, o processo já foi pensado e os dados já foram tratados de forma que esse fator não impeça a evolução do trabalho e seja simples a adição de mais informações e de mais dados, bastando treinar novamente a rede neural.

Portanto, a pesquisa em questão deve ser considerada apenas como o passo inicial

para a construção de um bom estimador de custos de obras públicas. Os trabalhos futuros que desta decorrem podem ser aprimorados a partir de dois principais caminhos: o enriquecimento da base de dados e o aprofundamento dos resultados obtidos via rede neural.

O desafio do enriquecimento dos dados de entrada da rede se mistura principalmente com o problema de se medir a especificidade de um determinado projeto. A rede neural pode ser muito poderosa nesse sentido através da sua capacidade de identificar padrões entre os dados de entrada que, por sua vez, traduzem alguns fatores numéricos do contexto da obra em questão, isto é, a medição sistêmica de informações inicialmente qualitativas podem ser convertidas, a partir dos devidos agrupamentos e ponderações, em fatores quantitativos. (GONÇALVES, 2010)

Além disso, a base de dados trabalhada ao longo do artigo é formada por orçamentações já consolidadas e executadas, ou seja, a rede neural já recebeu dados pré-tratados. Como exemplo, ao receber um projeto para a reforma de um galpão, as informações não continham o estado do galpão atual ou o tipo de solo no qual deveriam se firmar as fundações, mas já haviam os dados diretos do que precisava ser feito para resolver o problema daquele projeto em específico (descritivo de serviços envolvidos). A falta das conexões que fizeram com que os orçamentistas fizessem cada um dos dimensionamentos prejudica o poder preditivo do trabalho.

## 5 Conclusão

A pesquisa de mercado para verificação dos valores adequados para a licitação de obras públicas é uma etapa essencial do processo. Através dela, a instituição responsável pela abertura do chamado público tem a capacidade de informar um preço justo de contratação estatisticamente subsidiado e de identificar possíveis sobrepreços nas ofertas recebidas, impedindo a sua contratação. Dessa forma, as estimativas que acontecem de forma prévia à finalização do orçamento analítico auxiliam o gestor a identificar possíveis necessidades de negociação dos contratos bem como dão insumos para a correta seleção da proposta mais vantajosa para a sociedade impactada.

Uma aplicação interessante da compilação e processualização dos dados via rede neural é a possibilidade de não apenas agregar ao processo de estimativa de custos orçamentários, mas também colaborar com o orçamento preliminar. De acordo com o tipo de serviço pretendido, é possível também estimar a porcentagem regular do orçamento que deverá ser alocada para cada tipo de serviço a partir das distribuições das porcentagens de entrada verificadas.

O presente trabalho buscou compreender e analisar a viabilidade e o impacto estatístico do modelamento preditivo da orçamentação de obras públicas a partir de redes neurais artificiais, desenvolvendo como protótipo final da pesquisa os melhores resultados obtidos e a explicação de todo o processo. Para este resultado, avaliou-se também a sua aplicabilidade e os caminhos de melhoria.

Como sugestão de melhoria dos resultados obtidos via RNA, sugere-se uma análise mais detalhada dos dados de entrada relativos à porcentagem solicitada de orçamento para cada um dos dez tipos de serviços. Tais dados podem ser analisados em um cenário mais aprofundado a partir da construção de fortes correlações entre os tipos de obras e serviços solicitados e a porcentagem de relevância de cada área do serviço para o conjunto final. Ao avaliar o quanto a orçamentação do mesmo está acima ou abaixo da média de custo geral para o mesmo grupo, é possível entender inclusive quais são os setores que possuem a maior disparidade orçamentária em relação ao histórico de projetos do tipo, lapidando ainda mais o algoritmo de decisão e recomendação.

# Referências

- ALMEIDA, F. C. de. Uma visão geral do potencial e do funcionamento do uso de redes neurais em administração, através de exemplos e ilustrações mais acessíveis ao leitor não-familiarizado com conceitos de informática. **Revista de administração de empresas**, v. 35, n. 1, p. 46–55, jan./fev. 1995. Disponível em: <<https://www.scielo.br/pdf/rae/v35n1/a07v35n1.pdf>>. Acesso em: 15 out. 2020.
- BARROS, L. B. **Aplicação de Redes Neurais Artificiais no contexto de custos de construção de rodovias. 2019.** Dissertação (Mestrado em Estruturas e Construção Civil) — Universidade de Brasília, Brasília, 2019.
- BRASIL. **Decreto nº 7.892, de 23 de janeiro de 2013. Regulamenta o Sistema de Registro de Preços previsto no art. 15 da Lei nº 8.666, de 21 de junho de 1993.** Decreto — *Diário Oficial da União*, Brasília, DF, edição 17, Seção 1.p.2, 24 jan 2013, 1993.
- BRASIL. **Poder Legislativo. Lei nº 8.666, de 21 de junho de 1993.** Pesquisa de Mercado — *Diário Oficial da União*, Brasília, DF, 1993.
- BRASIL. **Tribunal de Contas da União – Licitações e Contratos. Orientações e Jurisprudência do TCU.** TCU, Brasília, 2010.
- BRASIL. **Portal da Transparência do Governo Federal: banco de dados.** portal, Brasília, 2018. Disponível em: <<http://www.portaltransparencia.gov.br>>.
- CARVALHO, A. P. de Leon F. de. Redes neurais artificiais multi layer perceptron treinadas com backpropagation. **Instituto De Ciências Matemáticas e de Computação - Universidade de São Paulo**, 2013. Disponível em: <<https://sites.icmc.usp.br/andre/research/neural/>>. Acesso em: 15 out. 2020.
- COSTA, J. A. F. **Classificação automática e análise de dados por redes neurais auto-organizáveis. 1999. 345 f.** Tese (Doutorado) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1999.
- DACOREGIO, F. A. **Estimativa preliminar de custos de obras utilizando redes neurais artificiais.** Dissertação (Mestrado em Engenharia Civil) - Centro Tecnológico, Universidade Federal de Santa Catarina — Universidade Federal de Santa Catarina, Florianópolis, 2017.
- DATA SCIENCE ACADEMY. **Deep Learning Book**, 2019, [S.l.]:, 2019. Disponível em: <<http://www.deeplearningbook.com.br/>>. Acesso em: 15 out. 2020.

GONÇALVES, R. M. *et al.* modelagem preditiva de linha de costa utilizando redes neurais artificiais. **Boletim de Ciências Geodésicas**, Curitiba, v.16,n.3,p.420-444, jul/set. 2010, 2010. Disponível em:

<[https://www.scielo.br/scielo.php?script=sci\\_arttextpid=S1982-21702010000300004](https://www.scielo.br/scielo.php?script=sci_arttextpid=S1982-21702010000300004)>.  
Acesso em: 15 out. 2020.

MATTOS, A. D. **Como preparar orçamento de obras : dicas para orçamentistas, estudos de caso, exemplos.** [S.l.]: PINI, 2006, 286p.

PACHECO, A. G. C. **Redes Neurais Artificiais utilizando MATLAB.** Universidade Federal do Espírito Santo, Vitória, 2014. Disponível em:

<<http://computacaointeligente.com.br/assets/files/tutorial-rna-matlab.pdf>>.

RODRIGUES, P. T. **Relatório de Estágio - Aplicação de redes neurais como ferramenta de apoio na definição da dosagem de coagulantes em ETAs.** Divisão de Engenharia Civil, Sao José dos Campos, 2020.

SILVA, S. R. Schimidt, f. redução de variáveis de entrada de redes neurais artificiais a partir de dados de análise de componentes principais na modelagem de oxigênio dissolvido. **Química Nova**, v.39, n.3, p.273-278, 2016. Disponível em:

<[https://www.scielo.br/scielo.php?script=sci\\_arttextpid=S0100-40422016000300273](https://www.scielo.br/scielo.php?script=sci_arttextpid=S0100-40422016000300273)>.  
Acesso em: 22 out. 2020.

# **Anexo A - Base de dados utilizada na Rede Neural Artificial**

Tabela contendo os principais valores da base de dados utilizada como entrada da Rede Neural Artificial.

Nome do orçamento	Tipo de orçamento	Data	Local	Porte da obra	Tempo relativo de duração do serviço (meses)	Orçamento total da obra	Orçamento corrigido	BDI
Pista de atletismo	Construção	Setembro 2020	São Paulo	Grande	6	1003694,42	730171,9919	26,07%
Casematã	Reforma	Agosto 2020	São Paulo	Médio	3	312343,76	227255,2001	28,80%
Centro de controle do CLIBI	Reforma	[HTML]FFF Agosto 2020	São Paulo	Médio	3	456139	353658,5188	27,11%
Banda de música DCTA	Construção	Março 2020	São Paulo	Médio	6	986703,17	717811,1232	0,2707
Prédio da direção do IEAV	Construção	Janeiro 2020	São Paulo	Médio	2	1652558,68	1202210,592	0,2354
Pavilhão Logístico DACO-MX	Construção	Dezembro 2019	Amazonas	Grande	6	4482489,04	3395825,03	0,2833
Cabine de medição e subestação do hospital da Força Aérea de Brasília	Construção	Dezembro 2019	Distrito Federal	Grande	8	6068163,72	4597093,727	0,2663
Rolo Pivotal I910D	Construção	Fevereiro 2019	São Paulo	Pequeno	1	19853,8	15040,75758	0,2632
Subestação do prédio da CODCIA	Reforma	Novembro 2020	São Paulo	Pequeno	1	117180,23	89246,78452	0,2689
Terminal de passageiros do DCTA	Construção	Novembro 2017	São Paulo	Médio	10	926786,9	674222,974	0,2601
Prédio Ala Zero	Reforma	Maio 2019	São Paulo	Grande	8	1432044,01	1041789,610	0,2618
Centro de Lançamento de Alcântara - Grupo 1	Reforma	Setembro 2019	Maranhão	Grande	15	4154412,09	3022270,253	0,274
Centro de Lançamento de Alcântara - Grupo 2	Reforma	Setembro 2019	Maranhão	Grande	8	3722121,11	2819788,72	0,2744
Centro de Lançamento de Alcântara - Grupo 3	Reforma	Setembro 2019	Maranhão	Grande	6	2310946,75	1750717,235	0,2756
Centro de Lançamento de Alcântara - Grupo 4	Reforma	Setembro 2019	Maranhão	Grande	15	5993082,54	4540214,045	0,2735
Laboratório de Guerra Eletrônica IAOP	Reforma	Abril 2020	São Paulo	Pequeno	2	274921,91	200001,3895	0,266
Ala de internação do Hospital da Força Aérea de Brasília	Reforma	Dezembro 2019	Distrito Federal	Grande	8	2955578,29	2239071,462	0,2711
Recuperação do sistema de proteção contra descargas atmosféricas do Hospital da Força Aérea de Brasília	Reforma	Fevereiro 2020	Distrito Federal	Médio	6	911077,29	662791,4781	0,2646
Adaptação de drenagem para alargamento da via do H30D	Reforma	Dezembro 2018	São Paulo	Pequeno	1	19853,8	15616,92755	0,2632
Manutenção dos postos de serviços	Reforma	Outubro 2019	São Paulo	Pequeno	2	52885,75	40064,96212	0,2656
Cobertura de Quadra Poliesportiva do CPOR	Construção	Agosto 2017	São Paulo	Grande	5	1186940,39	977647,0892	0,2726
Recuperação da Granita Elevada	Reforma	Fevereiro 2019	São Paulo	Pequeno	2	38150,8	28902,12121	0,2911
Revitalização do Prédio da Smau	Reforma	Abril 2018	Distrito Federal	Grande	10	3441000,09	270692,913	0,2579
Redeação do Sistema de Proteção Contra Descargas Atmosféricas	Reforma	Maio 2018	São Paulo	Pequeno	3	219492,47	172651,9862	0,2801
Ampliação do Estoque do Rancho	Reforma	Março 2019	São Paulo	Médio	6	609297,45	522952,6136	0,2837
Instalação de Grupo Gerador no Rancho	Reforma	Abril 2018	São Paulo	Médio	4	517241,37	406860,1982	0,3088
Recuperação Estrutural e Impermeabilização do Reservatório "B" da ETA	Reforma	Maio 2018	São Paulo	Médio	3	375410,22	295266,3266	0,3789
Adequação da Rede de Esgoto do H18B	Reforma	Novembro 2015	São Paulo	Pequeno	3	126389,42	118187,2265	0,259
Adequação da Rede de Esgoto do H25C	Reforma	Novembro 2015	São Paulo	Pequeno	1	61864,64	57848,85973	0,2595
Adequação da Rede de Esgoto do H32A	Reforma	Novembro 2015	São Paulo	Pequeno	4	167231,06	156378,3991	0,251
Adequação da Rede de Esgoto do H23A	Reforma	Novembro 2015	São Paulo	Pequeno	4	170909,08	159817,7296	0,2546
Adequação da Rede de Esgoto do H21A	Reforma	Novembro 2015	São Paulo	Pequeno	4	147140,72	137591,8459	0,2588
Reforma Previdal para Serviço Contra Incêndio e Operações	Reforma	Novembro 2017	São Paulo	Médio	4	620904,56	509105,0836	0,2794
Construção de Muro Perimetral do Putim	Construção	Fevereiro 2017	São Paulo	Médio	4	992463,05	813761,1102	0,2836
ICEA - Serviço de Confecção e Instalação de Pedestal para suporte de acilão tipo Bandeirante - EMB 110	Construção	Fevereiro 2017	São Paulo	Pequeno	6	237465,17	194707,4205	0,2724
Projeto da rede elétrica de alimentação das unidades residenciais dos Blocos HISA-C, PD-288 e 205	Construção	Maio 2018	São Paulo	Médio	5	521690,45	410350,8285	0,2913
IAE - Substituição da Rede de Água entre o trevo do H1 e a área operacional	Construção	Abril 2016	São Paulo	Médio	6	443674,93	385972,1009	0,2957
Impermeabilização da Laje de Cobertura dos prédios Anexos ao Comando de Aeronáutica, Esplanada dos Ministérios - Bloco M	Reforma	Outubro 2017	Distrito Federal	Grande	3	356525,77	292330,0836	0,2841
Reforma da Cobertura do Prédio ITA (Engenharia Eletrônica e Ciências da Computação) - DCTA	Reforma	Junho 2018	São Paulo	Grande	3	1256212,01	988131,8414	0,2729
Implantação de Infraestrutura (rede de água fria, esgoto, água pluvial, pavimentação e reservatório elevado) para Construção da Nova Sede do CTORAR/IE-SJ	Construção	Maio 2017	São Paulo	Grande	8	3515452,05	2882463,144	0,273
Reforma da Edificação GAC - PAC	Reforma	Abril 2019	São Paulo	Pequeno	3	78847,03	59732,59848	0,3047
Serviço de Instalação de Grupo Gerador na Divisão de Saúde	Reforma	Agosto 2018	São Paulo	Médio	4	401093,31	315498,5527	0,3079
Rede Elétrica de Alimentação dos Blocos H17 B e C	Reforma	Abril 2019	São Paulo	Médio	5	497855,4	377163,1818	0,2867
Reforma das Instalações Elétricas do Bloco H-20B	Reforma	Agosto 2017	São Paulo	Pequeno	2	141589,51	110950,0394	0,2929
Reforma da casa de máquinas da estação de captação de água	Reforma	Maio 2018	São Paulo	Pequeno	4	237855,17	187096,0198	0,2963
Reforma da Laje de Paralelismo (PRVF-15)	Reforma	Fevereiro 2017	São Paulo	Médio	4	364994,43	299273,8849	0,2898
Reforço estrutural do Estande de Tiro	Reforma	Março 2017	São Paulo	Grande	8	1536098,19	1259477,033	0,2796
Reforma WC inferior	Reforma	Março 2020	São Paulo	Pequeno	1	82313,4	59881,71101	0,2913
Reforma WC superior	Reforma	Março 2020	São Paulo	Pequeno	1	86374,95	62836,42514	0,2917