



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE ENGENHARIA CIVIL**

BRUNO SOUSA DA SILVA

**ESTIMATIVA DE DESEMBOLSO MENSAL EM OBRAS DE
TERRAPLENAGEM COM USO DE REDE NEURAL ARTIFICIAL**

**CAMPINA GRANDE
2021**

BRUNO SOUSA DA SILVA

**ESTIMATIVA DE DESEMBOLSO MENSAL EM OBRAS DE
TERRAPLENAGEM COM USO DE REDE NEURAL ARTIFICIAL**

Trabalho de Conclusão de Curso
apresentado à Universidade
Federal de Campina Grande –
UFCG, para encerramento do
componente curricular e
conclusão da graduação em
Engenharia Civil.

Orientadora: Prof. Dr^a. Izabelle Marie Trindade Bezerra.

CAMPINA GRANDE

2021

BRUNO SOUSA DA SILVA

**ESTIMATIVA DE DESEMBOLSO MENSAL EM OBRAS DE
TERRAPLENAGEM COM USO DE REDE NEURAL ARTIFICIAL**

Aprovada em: ____ de _____ de ____.

Dr^a. Isabelle Marie Trindade Bezerra
(Orientadora)

Eng. Hélio da Silva Queiroz Júnior
(Coorientador)

Dr. Rodrigo Mendes Patrício Chagas
(Examinador Externo)

Dr. Walter Santa Cruz
(Examinador Interno)

RESUMO

O objetivo desse trabalho é desenvolver, aplicar e analisar os resultados de uma rede neural artificial (RNA) desenvolvida utilizando um software de simulação de matrizes com pacote para redes neurais artificiais, que seja capaz de realizar uma estimativa de custo mensal em uma obra de terraplenagem nos serviços de corte e aterro. O princípio consiste em entender a importância de cada parâmetro de entrada e saída; organizar todos os dados coletados e normalizar esses dados para que variem dentro do intervalo de 0 a 1. Foram estudadas várias arquiteturas, variando número de camadas, neurônios e função de ativação, com menor percentual de erro, para verificar a capacidade de previsão do volume de corte e aterro a ser utilizado no mês subsequente e, com isso, chegar ao valor de desembolso mensal a partir do valor pago por metro cúbico escavado ou compactado. Dessarte, foi escolhida uma obra de condomínio horizontal de padrão médio a alto composta por projetos e orçamentos, além de outros dados necessários para os parâmetros de entrada. Os parâmetros de entrada escolhidos foram localização da estaca, distância do ponto à estaca zero daquela localização, volume de corte de projeto, volume de aterro de projeto, mês de execução e inclinação. Enquanto isso, os parâmetros de saída foram volume de corte e aterro executado. Os resultados das RNA's foram comparados aos valores reais de duas formas: na primeira, os volumes de corte e aterro previstos foram comparados de estaca a estaca, já na segunda, os volumes de corte e aterro previstos foram comparados por mês e por rua, não mais por estaca. A arquitetura com melhor desempenho foi a RNA1, constituída de 02 (duas) camadas, 10 (dez) neurônios e função de ativação *Tansig-tansig*. Outra rede neural mostrou resultados parecidos aos da RNA1, porém, com 03 (três) camadas e 15 (quinze) neurônios e, portanto, necessitando de maior esforço da máquina para chegar ao mesmo resultado médio. Os valores de erros médios maiores que o intervalo admitido encontrados no volume de aterro podem ser explicados pela pouca quantidade de obras, para analisar e comparar, bem como a pouca quantidade de parâmetros de entrada disponíveis.

Palavras-chave: Movimentação de terra; Inteligência artificial; Orçamento.

ABSTRACT

The objective of this work is to develop, apply and analyze the results of an artificial neural network (ANN) developed using a matrix simulation software with a package for artificial neural networks, which is capable of performing a monthly cost estimate in an earthworks work. in cut and fill services. The principle is to understand the importance of each input and output parameter; organize all collected data and normalize these data so that they vary within the range of 0 to 1. Several architectures were studied, varying the number of layers, neurons and activation function, with a lower percentage of error, to verify the volume prediction capacity of cut and fill one to be used in the following month and, with this, reach the monthly disbursement value from the amount paid per cubic meter excavated or compacted. Thus, a medium to high standard horizontal condominium project was chosen, consisting of projects and budgets, in addition to other data provided for the input parameters. The chosen input parameters were stake location, distance from point to stake zero location, design cut volume, design backfill volume, month of execution, and large. Meanwhile, the output parameters were cut volume and landfill conducted. The results of the ANNs were compared to the actual values in two ways: in the first, the cut volumes and predicted landfill were compared from pile to pile, in the second, the compared volume was separated into months and by street, no longer by pile. The best performing architecture for RNA1, discovery of 02 (two) layers, 10 (ten) neurons and Tansig activation function. Another neural network showed results similar to those of RNA1, however, with 03 (three) layers and 15 (fifteen) neurons and, therefore, requiring a greater effort from the machine to reach the same average result. The average error values greater than the admitted range found in the landfill volume can be explained by the small amount of works to analyze and compare, as well as the small amount of input parameters available.

Keywords: Earthwork; Artificial intelligence; Budget.

AGRADECIMENTOS

À Deus, por sempre me dar forças em meio às dificuldades e por sempre me mostrar que eu posso ir além do que esperam de mim.

À minha amada mãe, que, apesar de tudo, sempre me apoiou e me estimulou incentivando a não desistir e sempre buscar os meus sonhos e alcançar os meus objetivos.

À minha amada e digníssima esposa por sempre se fazer presente nos momentos mais difíceis e no mais felizes da minha vida.

À minha orientadora e ao meu coorientador, que sempre tiveram a paciência de me auxiliar com todas as minhas dúvidas e com toda humildade me mostraram um caminho a ser seguido.

À toda a banca que com comentários muitos pertinentes me ajudaram a tornar esse trabalho ainda melhor.

Aos meus professores de forma geral, por terem, de alguma forma contribuído com a construção do meu aprendizado sempre procurando me passar o melhor deles.

Aos funcionários da Universidade Federal de Campina Grande - Campus Campina Grande, de todas as categorias, de igual modo, a todos os alunos.

A Universidade Federal de Campina Grande, por me proporcionar uma convivência tão maravilhosa com todas essas pessoas citadas anteriormente.

DEDICATÓRIA

Dedico este trabalho a Deus, a minha família, aos amigos e irmãos da Igreja Batista Cristo Vive e a todo o corpo de professores da Universidade Federal de Campina Grande.

SIGLAS

DNIT – Departamento Nacional de Infraestrutura e Transporte

RNA – Rede Neural Artificial

IA – Inteligência Artificial

MLP - Perceptrons Multicamadas

LISTA DE FIGURAS

Figura 1: Pá de Cavalo	10
Figura 2: Trator Holt-Caterpillar (1917)	10
Figura 3: Máquinas Motrizes: (a) Trator sobre rodas e (b) Trator sobre esteiras.....	12
Figura 4: Tratores-Escrêiperes de rodas.....	13
Figura 5: Escavo – Carregadoras: (a) Pá-Carregadeira, (b) Escavadeira (PC) e (c) Retro- escavadeira	13
Figura 6: Motoniveladora ou Patrol	14
Figura 7: Caminhão Caçamba	15
Figura 8: Unidades compactadoras: (a) Rolo pé de carneiro e (b) Rolo liso.	15
Figura 9: Modelo de neurônio artificial proposto por McCulloch e Pitts	18
Figura 10: Fluxo da metodologia do trabalho, adaptado	21
Figura 11: Arquitetura da RNA 1	24
Figura 12: Arquitetura da RNA 2.....	24
Figura 13: Arquitetura da RNA 3.....	25
Figura 14: Arquitetura da RNA 4.....	25
Figura 15: Arquitetura da RNA 5.....	25
Figura 16: Arquitetura da RNA 6.....	26
Figura 17: Arquitetura da RNA 7.....	26

LISTA DE TABELAS

Tabela 1: Porcentagem de erro por RNA	28
Tabela 2: Apresentação do erro por mês de execução	29
Tabela 3: Previsão de desembolso	35

LISTA DE GRÁFICOS

Gráfico 1: Mês 1 - Rua 05 – Corte	30
Gráfico 2: Mês 1 - Rua 06 – Corte	31
Gráfico 3: Mês 1 - Rua 07 – Corte	31
Gráfico 4: Mês 2 - Alça 03 – Corte	32
Gráfico 5: Mês 2 - Alça 04 – Corte	32
Gráfico 6: Mês 2 - Rua 15 – Corte	33
Gráfico 7: Mês 1 - Rua 05 – Aterro	33
Gráfico 8: Mês 1 - Rua 07 – Aterro	34
Gráfico 9: Mês 2 - Rua 15 – Aterro	34

SUMÁRIO

1. INTRODUÇÃO	7
2. OBJETIVOS	8
2.1. OBJETIVO GERAL	8
2.2. OBJETIVOS ESPECÍFICOS	8
3. REFERENCIAL TEÓRICO	9
3.1. OBRAS DE TERRAPLENAGEM	9
3.1.1. HISTÓRICO.....	10
3.2. GESTÃO DE TERRAPLENAGEM.....	16
3.3. REDE NEURAL ARTIFICIAL	17
3.4. USO DE REDE NEURAL NA CONSTRUÇÃO CIVIL.....	19
4. METODOLOGIAS	21
4.1. DESENVOLVIMENTO DOS MÉTODOS	22
4.1.1. SELEÇÃO E ORGANIZAÇÃO DOS PARÂMETROS	22
4.1.2. REDE NEURAL ARTIFICIAL	23
4.1.3. DESENVOLVIMENTO DAS RNAS.....	24
4.1.4. METODOLOGIA DE AVALIAÇÃO	26
5. RESULTADOS E DISCUSSÕES	28
5.1. APRESENTAÇÃO DOS RESULTADOS	28
5.1.1. ANÁLISE DE RESULTADOS POR ESTACAS	28
5.2. PREVISÃO DE DESEMBOLSO	35
6. CONCLUSÕES	36
REFERÊNCIAS	37
ANEXO I	39

1. INTRODUÇÃO

É senso comum e comprovado cientificamente que o cérebro humano é uma máquina extremamente poderosa e complexa, com a capacidade de processar uma enorme quantidade de informações em curtos espaços de tempo. A exemplo, o cérebro é capaz de reconhecer um rosto familiar dentre uma multidão de pessoas em milésimos de segundos (GONÇALVES, 2008).

Diante da capacidade inegável do cérebro humano, muitos cientistas tentaram por diversas vezes produzir algo semelhante a esta poderosa máquina. Daí, surge o conceito de Inteligência Artificial (IA) definido por Russell & Norvig (1995) como sistemas desenvolvidos que pensam e agem como humanos e, além disso, pensam e agem logicamente. Na tentativa de melhor definir o que seria uma IA, o cientista Alan Turing propôs, em 1950, um teste capaz de determinar se uma máquina demonstra inteligência artificial. Basicamente, Turing propôs que um ser humano, através de algum terminal, deveria entrevistar o sistema desenvolvido. Se após algum tempo o entrevistador não fosse capaz de perceber que o entrevistado era uma máquina então a hipótese da existência de IA estaria confirmada.

A Rede Neural Artificial (RNA) surge a partir de estudos como os citados anteriormente, principalmente no que diz respeito ao processo de aprendizagem por experiências ou aprendizado de máquinas. O aprendizado de máquinas é também uma área de pesquisa dentro da inteligência artificial que objetiva o desenvolvimento de programas com a capacidade de aprender baseado em suas próprias experiências (FACELI et al., 2011). Uma RNA bem estruturada, por exemplo, é capaz de realizar tarefas como classificação, processamento de imagens, reconhecimentos de padrões, entre outras.

Não é difícil encontrar estudos sobre RNA's direcionadas ao custo das obras ou edificações. Tal situação pode ser explicada uma vez que não é muito difícil encontrar obras com estimativas de custos falhas, mesmo existindo um estudo prévio. Com isso, surge a necessidade de um programa, rede ou tecnologia que traga um orçamento mais preciso para obra e que entenda como cada variável presente no dia a dia da construção civil pode influenciar nas flutuações dos preços de cada construção.

Autores de vários países, tais como: Dacoregio (2017), Adeli e Wu (1998), Diana, *et al.* (2020), encontraram bons resultados no que diz respeito a estimativas de custos de obras da construção civil, possibilitando e servindo de base para pesquisas futuras com previsão de custos usando redes neurais.

2. OBJETIVOS

2.1. OBJETIVO GERAL

O objetivo geral deste trabalho é elaborar uma RNA a fim de estimar o desembolso mensal de uma obra de terraplenagem, para os serviços de corte e aterro.

2.2. OBJETIVOS ESPECÍFICOS

- a. Selecionar orçamentos e dados de produção diária ou mensal de obras de terraplenagem;
- b. Analisar e selecionar os parâmetros que influenciam nos custos de obras de terraplenagem;
- c. Elaborar arquiteturas de RNA's usando os parâmetros selecionados como entradas a fim de obter a maior taxa de acerto nos parâmetros de saída;
- d. Realizar testes para verificar a rede que apresentou maior percentual de acerto;
- e. Estimar o desembolso mensal de uma obra de terraplenagem para os serviços de corte e aterro.

3. REFERENCIAL TEÓRICO

3.1. OBRAS DE TERRAPLENAGEM

Segundo Ricardo e Catalani (2000), a terraplenagem é definida como o conjunto de ações e operações necessárias à remoção do excesso de terra, seja do próprio terreno em que se esteja trabalhando, ou de jazidas próximas, para locais onde esta esteja em falta ou não, tendo em vista um determinado projeto a ser implantado. Portanto, construções em geral, como a construção de estradas, ferrovia, aeroporto, a edificação de uma fábrica ou de uma usina hidrelétrica, ou mesmo de um conjunto residencial, exigem a execução de serviços de terraplenagem.

De acordo com Vieira (2019), o objetivo de uma obra de terraplenagem é a compensação entre cortes e aterros de modo a evitar a importação de material. Quando não existe o equilíbrio entre o volume escavado e o compactado, há de se recorrer à importação de material oriundo de caixas de empréstimos, de jazidas, ou à exportação do material para locais adequados, a esse material dá-se o nome de bota-fora.

Segundo Falcão (2016), a terraplenagem ainda pode ser considerada uma das etapas mais importantes na construção de rodovias e estradas em geral. Do ponto de vista financeiro, esse serviço representa cerca de 20% do custo da obra de rodovia, dos quais 50% são gastos com aluguel e/ou manutenção de equipamentos. Do ponto de vista técnico, uma terraplenagem mal executada ou até mesmo mal fiscalizada, sem o uso de equipamentos corretos, pode ocasionar erosão do solo e até mesmo inviabilizar toda a construção e eficiência do pavimento.

Para o caso de condomínios horizontais e loteamentos, independente do padrão financeiro proposto, a movimentação de terra em vias e quadras também pode ser considerada um dos principais serviços, principalmente pelo alto custo da hora trabalhada de máquinas necessárias para este tipo de serviço, além da necessidade de mão de obra especializada, se tornando responsável por uma boa fatia do orçamento de toda a obra.

3.1.1. HISTÓRICO

As realizações de obras de terraplenagem vêm sendo executadas pelo homem há muitos séculos. Os canais de irrigação às margens dos rios Nilo e Eufrates, os aquedutos e estradas romanas, a construção de enormes pirâmides no antigo Egito, deixam claro que mesmo sem o auxílio das grandiosas máquinas que vêm sendo utilizadas desde o início do século XXI, o homem já executava obras de terraplenagem. Tudo isso ocorreu antes mesmo do homem definir esse conceito.

De acordo com Ricardo (2000), até meados do século XIX, o instrumento utilizado para auxiliar em obras de terraplenagem era ainda o “*horse-drawn scraper*” ou simplesmente “pá de cavalo”, feita por uma caçamba movida a tração animal dotada de uma lâmina de corte que escavava e transportava o material retirado, conforme ilustrada na Figura 1.

Figura 1: Pá de Cavalo



Fonte: Pavimentação/Terraplenagem (2021).

Com o surgimento da máquina a vapor, surgiram também as primeiras tentativas de utilizá-la na escavação e transporte de material. No final do século XIX já existiam escavadeiras montadas em vagões e usadas na construção ferroviária. Já no início do século

XX foi lançado o primeiro trator de esteiras movido a diesel, dando início a concepção e fabricação dos equipamentos de terraplenagem como o conhecemos. A Figura 2 mostra o trator Holt-Caterpillar (1917), um dos primeiros tratores da história.

Figura 2: Trator Holt-Caterpillar (1917)



Fonte: Caterpillar (2016).

As máquinas usadas no serviço de terraplenagem são divididas em dois grandes grupos, são eles: Máquinas Motrizes e Máquinas Operatrizes.

- Máquinas Motrizes:

Podem ser sobre rodas ou esteiras. As máquinas motrizes se caracterizam, principalmente, por transformar qualquer tipo de energia em trabalho mecânico. Geralmente são movidas por motores a diesel e são conhecidas como unidades de tração que podem empurrar outras máquinas, dando-lhes aumento de tração de carga ou até mesmo as fazendo realizar atividades que não exijam o transporte de terra. A Figura 3 mostra dois tipos de máquinas motrizes com lâminas de corte.

Figura 3: Máquinas Motrizes: (a) Trator sobre rodas e (b) Trator sobre esteiras.



Fonte: Caterpillar (2016).

- Máquinas Operatrizes:

As máquinas operatrizes, como o nome sugere, são máquinas que realizam os diversos serviços e operações dentro da terraplenagem. São máquinas empurradas, tracionadas ou manobradas pelas máquinas motrizes e possuem implementos que realizam o serviço desejado. Dentro do grupo existem 6 ramificações, são elas: unidades escavo-empurradoras, unidades escavo-transportadoras, unidades escavo-carregadoras, unidades aplainadoras, unidades de transporte e unidades compactadoras. Das quais:

a. Unidades escavo-empurradoras:

Os tratores apresentados na Figura 3, além de escavo-empurradoras, também podem ser considerados como unidades escavo-transportadoras. São unidades capazes de escavar, empurrar e até mesmo derrubar árvores. Portanto, além de motrizes, são também classificadas como operatrizes.

b. Unidades escavo-transportadoras:

São máquinas não muito utilizadas em obras de pequeno e médio porte. Têm como principais funções: escavar, carregar e transportar materiais de consistências médias por distâncias pequenas. A Figura 4 apresenta o Motoscraper Caterpillar, um exemplo de unidades escavo-transportadoras.

Figura 4: Tratores-Escrêiperes de rodas

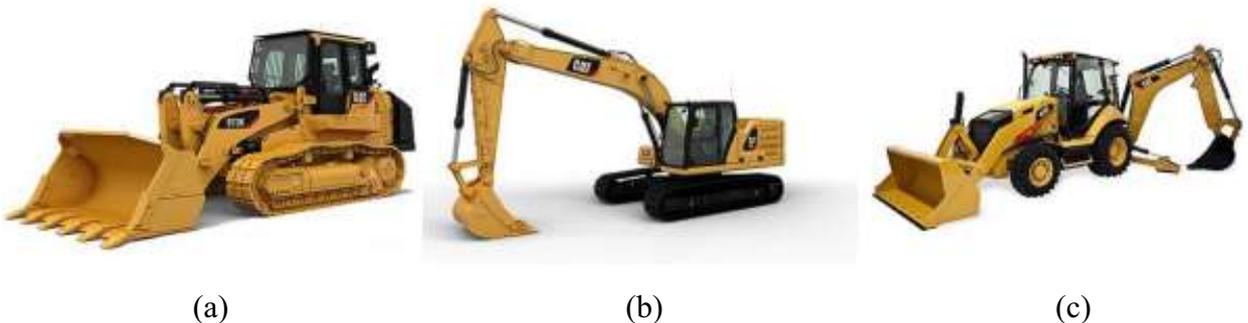


Fonte: Caterpillar (2016).

c. Unidades escavo-carregadoras:

São unidades que têm como principais atividades: escavar e carregar o material para outras unidades de transportes. São tratores de pneus ou esteiras com capacidade de escavar, carregar e levantar material até 3,00 metros de altura. A Figura 5 apresenta alguns exemplos de unidades escavo-carregadoras.

Figura 5: Escavo – Carregadoras: (a) Pá-Carregadeira, (b) Escavadeira (PC) e (c) Retro-Escavadeira.



Fonte: Caterpillar (2016).

d. Unidades aplainadoras:

Conhecidas como motoniveladoras ou Patrol, são máquinas usadas em serviços de acabamento, tombamento, espalhamento e trabalhos em talude lateral. É uma máquina muito

usual e imprescindível em obras de terraplenagem. A Figura 6 mostra a motoniveladora finalizando uma camada de pavimentação.

Figura 6: Motoniveladora ou Patrol



Fonte: Acervo Pessoal (2021).

e. Unidades de transporte:

Equipamentos destinados ao transporte de material em primeira, segunda ou terceira categoria, destinados a aterros ou bota-fora. Os equipamentos mais conhecidos são as caçambas ou caminhão caçamba, como mostra a Figura 7.

Figura 7: Caminhão Caçamba



Fonte: Acervo Pessoal (2021).

f. Unidades compactadoras:

Estas unidades têm como objetivo a compactação das camadas de aterros ou de camadas de pavimentação de forma a reduzir o índice de vazios daquela camada. A Figura 8 mostra os dois tipos de rolo: rolo pé de carneiro e liso, respectivamente.



(a)



(b)

Figura 8: Unidades compactadoras: (a) Rolo pé de carneiro e (b) Rolo liso.

Fonte: Acervo Pessoal (2021).

Destas, as máquinas mais utilizadas em obras de pequeno e médio portes para movimentação de terra (corte e aterro) são: escavadeira e retroescavadeira, motoniveladora, caminhão caçamba e rolo pé de carneiro, as quais serão sempre citadas e usadas neste trabalho.

3.2. GESTÃO DE TERRAPLENAGEM

De uma forma geral, gestão de obras pode ser definida como uma coordenação dos insumos que fazem parte de um empreendimento, além do desenvolvimento das atividades necessárias à implantação destes, objetivando atender interesses de terceiros, sejam de proprietários ou de clientes (MICALLI, 2000).

Em serviços de terraplenagem, é fácil identificar a utilização de equipamentos complexos e muito diversificados, como exemplificado no tópico anterior; tal distribuição de máquinas demanda elevado custo de operação. Diante disto, é de grande importância a correta aplicação e manuseio desses equipamentos, fazendo-se necessário o uso de planejamento e gestão de obra, de modo que sejam previamente conhecidos todos os custos necessários à realização da obra de terraplenagem (SOUZA e FALCÃO, 2014).

Uma característica marcante na gestão da terraplenagem é a redução de desperdícios em todas as etapas da obra. Considera-se desperdício toda e qualquer movimentação de terra que possa ser evitada ou realizada com uma quantidade menor de hora-máquina. Além disso, é considerado desperdício o superdimensionamento da quantidade de equipamentos necessários para a realização do serviço, gerando ociosidade.

A gestão das máquinas, equipamentos e pessoas envolvidas na obra de terraplenagem, assim como o dimensionamento de equipes, a coordenação e elaboração dos projetos, o controle do estoque de insumos, entre outros, afetam diretamente o orçamento da obra, podendo ser a diferença entre lucro e prejuízo do empreendimento. Portanto, todas essas atividades devem ser respeitadas e executadas antes do início de qualquer tipo de atividade.

É a partir desse cenário que vem a importância da boa elaboração do orçamento paramétrico de toda a obra antes de qualquer tomada de decisão, pois antes de iniciar uma obra ou assinar um contrato o gestor deve ter em mente todas as variáveis que podem afetar o custo total da sua empreitada e, conseqüentemente, o seu lucro. Essa é uma etapa que deve ser rápida e precisa, pois, por exemplo, pode ser o diferencial em uma licitação. O modelo matemático de rede neurais artificiais pode auxiliar ao trazer soluções para esse tipo de problema.

3.3. REDE NEURAL ARTIFICIAL

Os neurônios ou células nervosas são a unidade básica da neuroanatomia e apresentam a propriedade de responder às alterações do meio em que se encontram (estímulos) a partir de modificações da diferença de potencial elétrico, que existe entre as superfícies interna e externa da membrana celular. Eles reagem prontamente a estes estímulos e a mudança de potencial propaga-se a outros neurônios, músculos ou glândulas (impulso nervoso) (FURTADO, 2019).

Segundo Finocchio (2014), redes neurais artificiais são sistemas que mimetizam o comportamento e a estrutura do cérebro humano, todavia possuem um conjunto muito limitado de neurônios. Esses neurônios, por sua vez, processam paralelamente os dados e os propagam a partir de uma complexa malha de interconexão. Analogamente ao cérebro humano, as RNA's têm a capacidade de interagir com o meio externo e adaptar-se a ele.

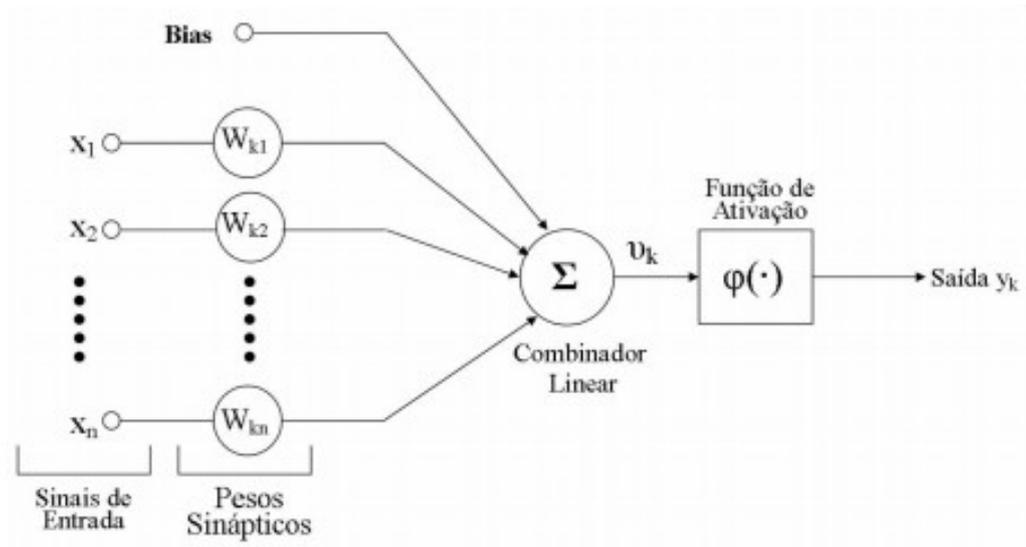
Uma rede neural artificial (RNA) é um sistema composto por vários neurônios. Esses neurônios estão ligados por conexões, chamadas de conexões sinápticas. Alguns neurônios recebem excitações do exterior e são chamados neurônios de entrada, correspondendo aos neurônios dos órgãos dos sentidos. Outros têm suas respostas usadas para alterar de alguma forma o mundo exterior e são chamados neurônios de saída, correspondentes aos motoneurônios: neurônios biológicos que excitam os músculos. Os neurônios que não são de entrada e de saída são conhecidos como neurônios internos. Estes neurônios internos à rede têm grande importância e são conhecidos na literatura saxônica como "Heiden", fazendo com que alguns traduzam como "escondidos" (BARRETO, 2002).

O modelo matemático mais bem aceito foi proposto por McCulloch e Pitts (1943), conhecido como Perceptron, o qual implementa, de maneira simplificada, os componentes e o funcionamento de um neurônio biológico.

Neste modelo, os impulsos elétricos provenientes de outros neurônios são representados pelos chamados sinais de entrada (x_j). Dentre os vários estímulos recebidos, alguns excitarão mais e outros menos o neurônio receptor, essa medida de quão excitatório é o estímulo é representada no modelo de McCulloch e Pitts através dos pesos sinápticos: quanto maior o valor do peso, mais excitatório é o estímulo. Os pesos sinápticos são representados por w_{kj} , em que k representa o índice do neurônio em questão e "j" se refere ao terminal de entrada da sinapse, o qual o peso sináptico se refere (McCULLOCH E PITTS, 1943).

A soma é representada por uma composição de dois módulos, o primeiro é uma junção aditiva, somatório dos estímulos (sinais de entrada) multiplicado pelo seu fator excitatório (pesos sinápticos), e posteriormente uma função de ativação, que definirá, com base nas entradas e pesos sinápticos, qual será a saída do neurônio, como apresentado na Equação I. O axônio é aqui representado pela saída (y_k) obtida pela aplicação da função de ativação. A Figura 9 apresenta o modelo de neurônio artificial proposto por McCulloch e Pitts (1943).

Figura 9: Modelo de neurônio artificial proposto por McCulloch e Pitts



Fonte: McCulloch e Pitts (1943).

Em termos matemáticos, o neurônio artificial i pode ser representado como:

$$u_k = \sum_{j=1}^m (X_j * W_{kj}) \quad (1)$$

Onde m é o número de sinais de entrada incidentes no neurônio k e posteriormente a aplicação da função de ativação, explicitado na Equação II.

$$y_k = \varphi(u_k) \quad (2)$$

Esta é a forma mais simples de rede neural, usada para classificação de padrões linearmente separáveis.

As RNAs são consideradas por muitos um método empírico, uma vez que não existem regras ou padrões absolutos para a configuração das redes e, por consequência, diversos parâmetros são estabelecidos por tentativas (GÜNAYDIN e DOGAN, 2004). Faz parte da hipótese indutiva que se alguns métodos de estimativa de custo forem comprovados

matematicamente e levem a certas estimativas precisas, então outro método de estimativa (RNA's), mesmo que considerado um método empírico, também pode ser considerado eficaz para o objetivo de estimar custo de novas obras, uma vez que alcançam os mesmos efeitos (DACOREGIO, 2017).

Dentro do universo das redes neurais artificiais pode-se elencar, pelo menos, três principais estratégias de treinamento: aprendizado supervisionado, aprendizado por reforço e aprendizado não supervisionado e essas referem-se diretamente à “independência da rede”. No aprendizado supervisionado, segundo NAVARRO (2014), sempre que for inserida uma entrada à rede, será necessário conferir se a saída obtida confere com a saída esperada para aquela entrada. Em caso de negativa, a rede deverá ajustar os pesos de forma que armazene o conhecimento desejado. Para o aprendizado com reforço, existe a presença de uma rede crítica que avalia a saída fornecida pela rede através da criação de uma função custo e aplica um procedimento que adapta os pesos estabelecidos de modo a minimizar o valor da função custo. Em resumo, se a resposta estiver dentro dos padrões estabelecidos é gerado um incremento ao peso do neurônio. Em contrapartida às outras duas estratégias, segundo NISHIDA (1998), o aprendizado não supervisionado permite à RNA aprender sem a necessidade de um conjunto de respostas conhecidas ou desejadas. Para este tipo de treinamento os pesos são ajustados ao passo que a rede vai sendo alimentada de padrões de entradas.

Com a evolução dos estudos dos mais variados tipos de RNA's, surge a ideia de elaboração de redes não lineares (capazes de classificar padrões não linearmente separáveis - os quais caem em posições de um hiperplano que não podem ser separados por uma linha reta) e essas redes precisam ser treinadas por processos mais elaborados (NISHIDA, 1998). Em 1986 Rumelhart e alguns colaboradores apresentam o algoritmo *backpropagation*, capaz de ajustar pesos em uma rede com mais de uma camada de neurônios. Assim, surgem os perceptrons multicamadas (MLP) – equações capazes de prever as curvas de aprendizagem a partir de variáveis neurológicas - utilizados na estrutura da maioria das redes neurais supervisionadas (Navarro, 2014).

3.4. USO DE REDE NEURAL NA CONSTRUÇÃO CIVIL

A estimativa de custos no campo da construção civil é um problema complexo e sobrecarregado pela falta de dados, incertezas e riscos, mas, tanto quanto complexo, é de suma importância para o sucesso de um projeto de construção civil (DIANA, *et al*, 2020). Em

obras de terraplenagem, a previsão de custos se torna ainda mais desafiadora devido à grande variedade de fatores que podem influenciar no preço final da construção, especialmente no Brasil, onde se tem climas, solos e vegetações tão diferentes por todo território nacional.

O uso de redes neurais artificiais surge como potencial alternativo para uma estimativa de custo precisa, com menor quantidade de dados, ajudando os empreendedores, empresas e investidores a tomarem decisões tendo como base uma previsão confiável e certa de custos. O fato de os custos contratados serem frequentemente excedidos também evidencia a discussão de que a previsão de custos em muitos projetos é inadequada, significando que a estimativa não é baseada em métodos cientificamente comprovados e, sim, em aplicação de modelos de baixa precisão ou modelos inadequados para o caso em consideração (DIANA, *et al*, 2020).

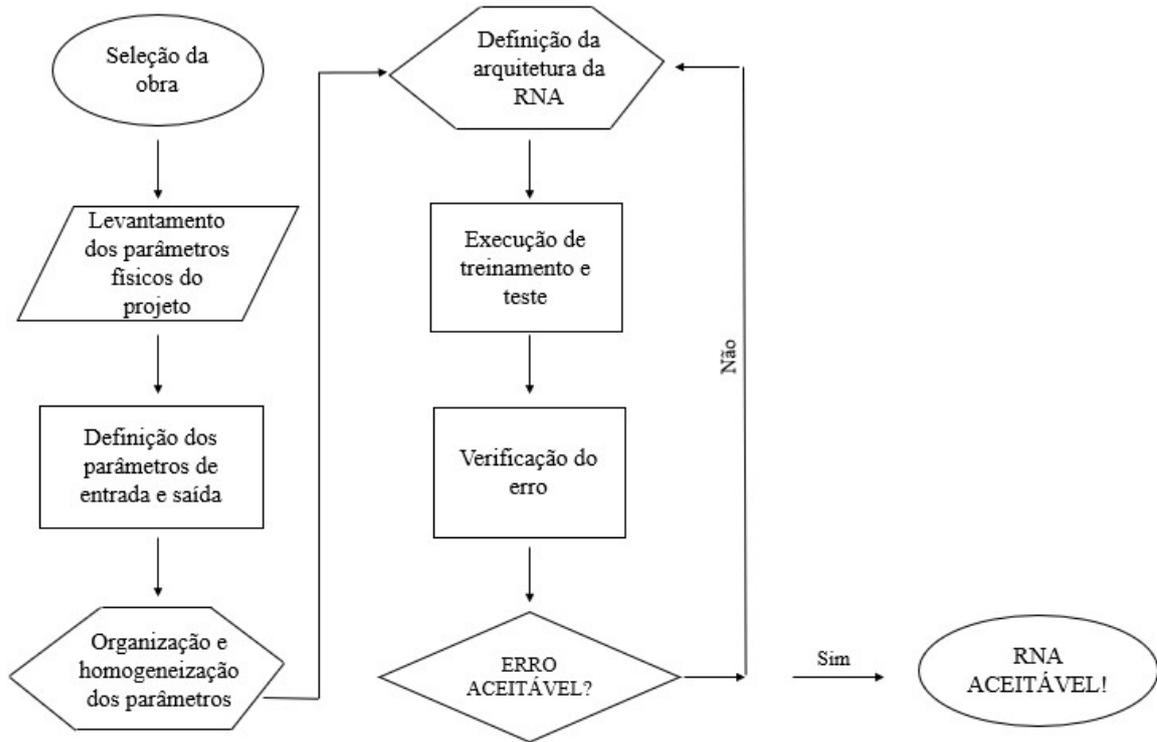
Pesquisas que usam a rede neural para estimativa de custo de projetos de terraplenagem, ainda não são comuns no Brasil. Porém, artigos com essa temática podem ser encontrados em publicações internacionais, a exemplo de El-Fitory, *et al*. (2014), que trouxeram uma estimativa de custo de projetos de rodovias da Líbia usando RNA e encontraram um erro médio de cerca de 1,5% em suas projeções ou até mesmo Pesko *et al*. (2017) que na República da Sérvia analisaram um total de 166 projetos executados pelo mesmo investidor ao decorrer de sete anos e encontraram um erro médio de 25,38% para estimativa de custo de estradas urbanas, além de Juszczuk, Leśniak e Zima (2018) que com a análise de 10 projetos conseguiram prever os custos de construções de campos esportivos com um erro médio menor que 15%, indicando-nos um norte a seguir e um campo a explorar.

Fora do âmbito da terraplenagem é possível citar o trabalho desenvolvido por Dacoregio (2017) que usando rede neural supervisionada e com o banco de dados de 40 obras prediais obtidas da Universidade Federal de Santa Catarina (UFSC) conseguiu um erro médio para a estimativa de custo de 17,22%. Da mesma forma, Biondi Neto *et al*. (2004), analisou 52 projetos e com o uso da rede neural pôde prever o custo do m² em obras residenciais com porcentagem de erro médio de apenas 1,5%. Pesquisas dessa natureza comprovam o potencial do uso da rede neural dentro da construção civil e estimulam o seu uso em novos estudos.

4. METODOLOGIA

O presente trabalho foi desenvolvido seguindo as etapas apresentadas no fluxograma da Figura 10.

Figura 10: Fluxo da metodologia do trabalho, adaptado.



Fonte: Elaborado pelo autor (2021).

A RNA foi treinada e testada utilizando dados de uma obra particular de condomínio horizontal de padrão médio a alto, situada no estado da Paraíba. Os dados utilizados foram obtidos a partir de estudos preliminares e coletados ao decorrer das atividades programadas, de modo que cada mês trabalhado, de um total de oito meses, serviram como base para treino ou teste do sistema. Os dados passaram por um processo de análise, formatação e normalização dos modelos para realização de análise comparativa. Após isto, foi elaborado um método intuitivo a fim de alcançar os melhores resultados possíveis na pesquisa.

4.1.DESENVOLVIMENTO DOS MÉTODOS

4.1.1. SELEÇÃO E ORGANIZAÇÃO DOS PARÂMETROS

- Seleção dos dados a serem utilizados

A obra selecionada faz parte de um projeto de vários condomínios realizados por todo o país por uma empresa privada loteadora. A utilização desses dados garante confiabilidade, pois são todos de uma obra já executada, o que promove maior precisão à pesquisa. É importante salientar que o fato de se trabalhar com obras de terraplenagem em condomínios horizontais garante certa homogeneidade nos serviços, uma vez que as tipologias desses tipos de construções são muito parecidas.

- Seleção dos parâmetros de entrada e saída

No modelo de contrato da obra escolhida, a execução do serviço de terraplenagem, para o corte, é paga dividindo todo o volume escavado no mês em porcentagens de equivalência de material de primeira, segunda e terceira categoria, cada um desses com seu respectivo valor de metro cúbico. O serviço de aterro é pago de acordo com a quantidade de metros cúbicos compactados a 95% do proctor normal. Baseado nisso, foi definido que os parâmetros de saída da RNA desenvolvida seriam o volume de corte e aterro executado no mês pois, assim, se torna fácil transformar esses volumes em valor de desembolso mensal, um dos objetivos deste trabalho.

Quanto aos parâmetros de entrada, baseado em estudos do contrato, experiências profissionais anteriores e na limitação de dados presenciada, foram definidos como sendo localização da estaca estudada, distância entre estacas acumulativas por rua, volume de corte e aterro previsto em projeto, mês de execução e inclinações dos perfis.

- Homogeneização dos parâmetros

Uma vez selecionada a obra e de posse dos dados mensais de produção e desembolso, uma espécie de filtro de homogeneização foi aplicada. É de essencial importância que os dados usados para a elaboração da RNA sejam referentes a um mesmo serviço, independentemente de suas quantidades. Portanto, um serviço realizado durante a etapa de terraplenagem que não foi executado nos demais meses coletados foi excluído do banco de dados.

Com os dados já homogêneos, se fez necessário parametrizá-los e fazê-los variar dentro do intervalo de 0 a 1, com a função de diminuir a demanda computacional. Para tanto, foi selecionado o maior número de cada item objeto do estudo e o valor encontrado foi considerado como correspondente ao número 1,0000. Por sua vez, o menor número encontrado foi adotado como sendo correspondente a 0,0000. Assim, qualquer valor encontrado no estudo deve variar do menor ao maior número encontrado, portanto variar de 0,0000 a 1,0000.

Com os dados homogêneos e parametrizados, foi realizado um estudo em cada conjunto de dados na tentativa de entender quais os parâmetros mais afetam ou influenciam o custo da obra. O estudo foi feito de forma empírica através do conhecimento do dia a dia da obra específica e em conversas com engenheiros mais experientes. Com isso, a terraplenagem considerada para elaboração da RNA foi apenas a executada nas ruas do condomínio, descartando a executada em quadras por se ter poucos dados sobre este serviço e por não aparecerem em todos os meses usados para essa pesquisa.

4.1.2. REDE NEURAL ARTIFICIAL

- Definição da RNA

A arquitetura das RNA's desenvolvidas seguiu o modelo de neurônio artificial proposto por McCulloch e Pitts (1943), e já apresentado neste trabalho, com: parâmetros de entrada, pesos sinápticos, combinador linear, função de ativação e parâmetros de saída. De forma empírica, sete diferentes arquiteturas de RNA's foram desenvolvidas variando a função de ativação, número de camadas e/ou a quantidade de neurônios.

- Treinamento

Uma vez desenvolvida a arquitetura, a RNA foi treinada a partir de um projeto de terraplenagem com orçamento final já conhecido. À medida que a RNA era treinada, os pesos definidos na arquitetura eram modificados a fim de encontrar o menor erro possível no dado de saída.

- Teste

Cada RNA foi testada dez vezes a fim de descobrir o erro médio encontrado na previsão de desembolso da rede. Dos oito meses de dados coletados entre corte e aterro, dois deles foram separados e usados para teste da rede. Por fim, o sistema que apresentou um menor erro percentual foi escolhido como a RNA a ser utilizada.

Os resultados obtidos em cada RNA foram comparados ao valor do orçamento previamente conhecido. Caso a diferença em módulo apresentada fosse menor ou igual ao aceitável, que foi definido pelo desenvolvedor como sendo de 20%, então a RNA estaria pronta para uso. O valor de erro aceitável de 20% está baseado nos resultados encontrados por Pesko *et al.* (2017) e Dacoregio (2017) 17,22%, que desenvolveram trabalhos semelhantes.

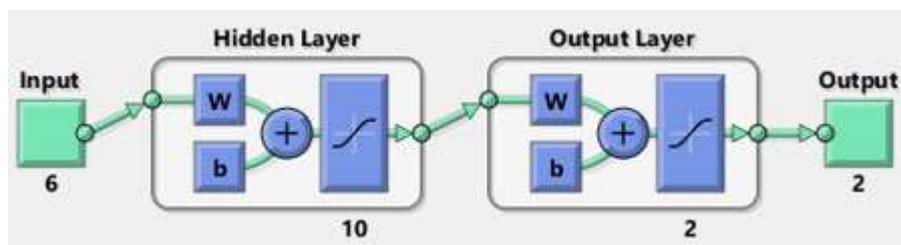
Ao fim do teste aplicado em cada rede neural é possível verificar o gráfico de regressão linear (R). Na estatística, a **regressão linear** é uma equação para se estimar o valor esperado de uma variável de saída, dados os valores de algumas outras variáveis de entrada. Em resumo, o valor de R de uma rede neural deve representar a porcentagem de acertos das saídas da RNA comparados aos resultados já conhecidos fornecidos na montagem da rede.

4.1.3. DESENVOLVIMENTO DAS RNAS

As RNA's para teste foram desenvolvidas assim:

RNA1 (Figura 11) foi desenvolvida com duas camadas, dez neurônios na primeira camada e com a combinação das funções *Tansig-tansig*;

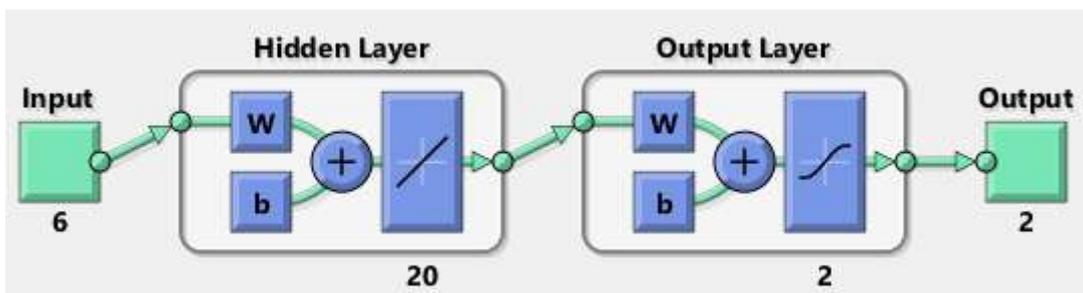
Figura 11: Arquitetura da RNA 1



Fonte: Software (2021).

RNA2 (Figura 12), com duas camadas, vinte neurônios na primeira camada e com a combinação das funções *Purelin-tansig*;

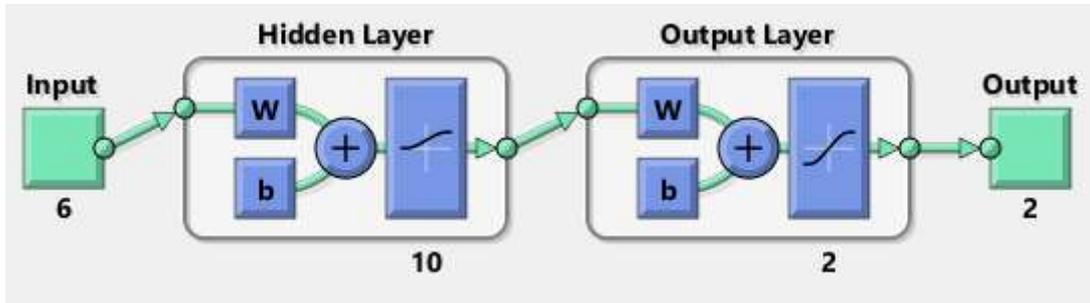
Figura 12: Arquitetura da RNA 2



Fonte: Software (2021).

RNA3 (Figura 13), com duas camadas, dez neurônios na primeira camada e com a combinação das funções *logsig-tansig*;

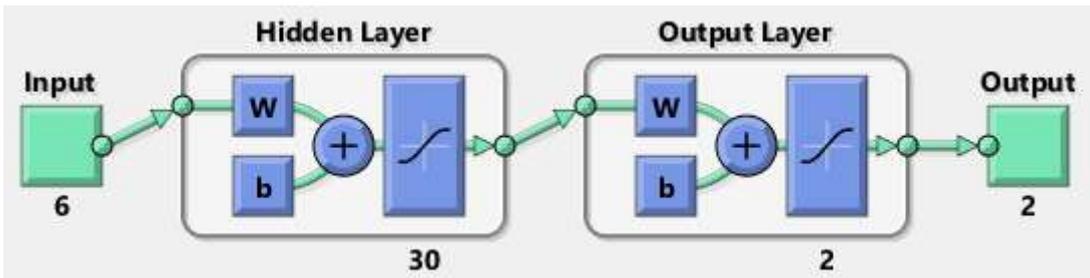
Figura 13: Arquitetura da RNA 3



Fonte: Software (2021).

RNA4 (Figura 14), com duas camadas, trinta neurônios na primeira camada e com a combinação das funções *Tansig-tansig*;

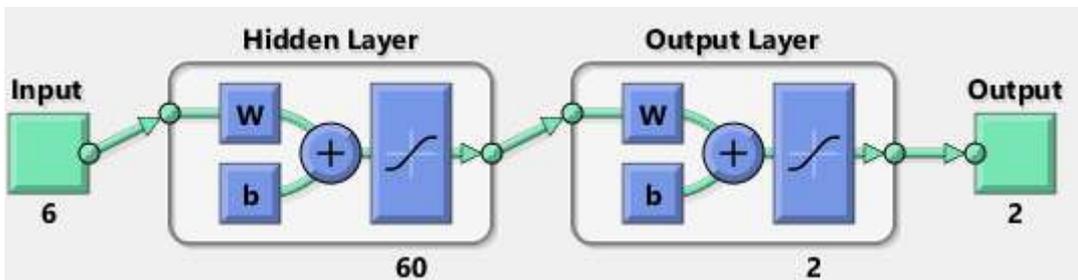
Figura 14: Arquitetura da RNA 4



Fonte: Software (2021).

RNA5 (Figura 15), com duas camadas, sessenta neurônios na primeira camada e com a combinação das funções *Tansig-tansig*;

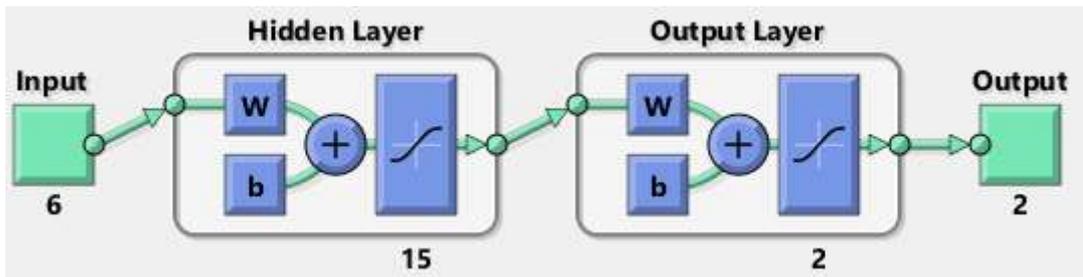
Figura 15: Arquitetura da RNA 5



Fonte: Software (2021).

RNA6 (Figura 16), com duas camadas, quinze neurônios na primeira camada e com a combinação das funções *Tansig-tansig*;

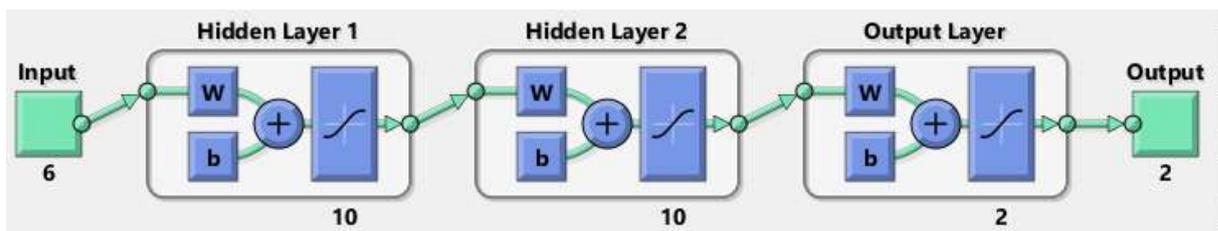
Figura 16: Arquitetura da RNA 6



Fonte: Software (2021).

RNA7 (Figura 17), com três camadas, dez neurônios na primeira e segunda camadas e com a combinação das funções *Tansig-tansig*. A última camada de todas as redes, bem como a camada de saída, é composta por dois neurônios que corresponde as saídas definidas nesse estudo, volume de corte e volume de aterro.

Figura 17: Arquitetura da RNA 7



Fonte: Software (2021).

4.1.4. METODOLOGIA DE AVALIAÇÃO

Após realizados todos os dez testes em cada uma das setes RNA's desenvolvidas, de posse dos dados de saída, foram realizados dois tipos de análises com o intuito de aferir a porcentagem de erro de cada rede.

Na primeira delas, nomeada de “análise por estaca”, cada valor de saída foi comparado aos valores já conhecidos dos dados separados para teste. De modo que um valor de saída na RNA tenta prever um outro valor já conhecido. Esses foram comparados aos seus correspondentes estabelecidos: Se o valor encontrado na saída da RNA variasse não mais que 20% do valor real, então seria admitido como resultado “verdadeiro” ou “satisfatório”. Do contrário, seria considerado como “falso” ou “insatisfatório”. Após aplicado essa análise em todos os dados de saída, somou-se a quantidade de valores classificados como “verdadeiros” e a razão desses em relação ao todo foi dada como a porcentagem de erro da RNA, podendo variar de 0 a 100%.

Na segunda análise, nomeada de “análise por trecho”, por sua vez, os valores não foram mais analisados de forma separada, mas sim em conjunto. De modo que se uma rua “J” qualquer possuir cinco estacas e ao decorrer de um mês “B” foram executados Xm^3 de corte e Ym^3 de aterro, então a análise de erro de previsão da RNA não se dará mais em cada estaca da rua “J”, mas sim no volume total de corte e aterro executado no mês “B” dentro das cinco estacas da rua em questão. Erros maiores que 100% foram apresentados apenas com “>100%”.

4.1.5. DESEMBOLSO

Por fim, de posse das previsões do volume de corte e aterro dadas pela RNA que apresente a menor porcentagem de erro, o desembolso real será dado da mesma forma que estabelecida no contrato da execução do projeto analisado, onde:

- Corte: O volume total de corte observado será dividido em material de primeira, segunda e terceira categoria e em porcentagens de cada um deles fixas de 70%, 25% e 5%, respectivamente. O metro cúbico de material de primeira categoria foi considerado igual a R\$3,41, o de segunda R\$9,65 e o de terceira R\$120,00.
- Aterro: Para aterro, foi contabilizado apenas o volume que atingiu 95% da compactação em energia proctor normal e o seu metro cúbico foi considerado igual a R\$8,62.

5. RESULTADOS E DISCUSSÕES

5.1. APRESENTAÇÃO DOS RESULTADOS

5.1.1. ANÁLISE DE RESULTADOS POR ESTACAS

A partir dos resultados obtidos para as sete RNA's foram determinados o percentual de erro para cada uma delas, conforme pode ser observado na Tabela 1.

Tabela 1: Porcentagem de erro por RNA

Rede Neural	Erro em Corte (%)	Erro em Aterro (%)	R médio (%)
RNA1	92	97	97,2
RNA2	100	100	97,67
RNA3	100	100	70
RNA4	86	99	98,1
RNA5	84	99	98
RNA6	80,5	99	95,6
RNA7	75	94	96,6

Fonte: Elaborado pelo autor (2021).

Como visto, o R médio obtido de cada RNA se mostrou bem satisfatório na grande maioria dos casos com o menor R de 95,6% encontrado nos testes da RNA6 - com exceção da RNA3 que apresentou um valor de 70%, bem abaixo da média das demais redes neurais. No entanto, para este tipo de análise, o percentual de acertos não se mostrou proporcional aos valores de R encontrados de modo que, baseado neste tipo de análise aplicada, nenhuma rede neural conseguiu prever de forma satisfatória o volume de corte e aterro com os parâmetros de entrada fornecidos.

A altíssima porcentagem de erro encontrada pode ser atribuída a alguns fatores: Pouca variedade de projetos disponíveis para análise, uma vez que apenas um projeto de

terraplenagem foi analisado; Baixo número de dados encontrados, já que o projeto selecionado não tinha um controle de todas as variáveis que podem influenciar na produção e custo de uma obra dessa natureza; Parâmetros de entradas insuficientes para cumprir o objetivo proposto, necessitando de informações mais detalhadas; Baixo valor em metro cúbico de corte e aterro por estacas, fazendo que qualquer pequena variância do resultado de saída se mostre um grande erro quando comparado ao valor real.

5.1.2. ANÁLISE DE RESULTADOS POR TRECHO

Dado a alta porcentagem de erro da primeira análise, um novo tipo foi realizado baseado nas dificuldades encontradas e os seus resultados estão apresentados na Tabela 2.

Tabela 2: Apresentação do erro por mês de execução

REDE NEURAL	MÊS				R MÉDIO (%)
	MÊS 1		Mês 2		
	Erro em Corte (%)	Erro em Aterro (%)	Erro em Corte (%)	Erro em Aterro (%)	
RNA1	7,0	32,0	14,11	26,0	97,2
RNA2	100,0	>100,0	100,0	>100,0	97,67
RNA3	>100,0	>100,0	>100,0	>100,0	70
RNA4	34,0	>100,0	46,0	62,0	98,1
RNA5	28,0	>100,0	60,0	61,0	98
RNA6	23,0	>100,0	31,0	40,0	95,6
RNA7	16,0	>100	26,0	52,0	96,6

Fonte: Elaborado pelo autor (2021).

Em média, a RNA que apresentou melhor precisão na previsão de movimento de terra foi a RNA1 com erro médio de 7,0% no primeiro mês e 14,11% no segundo mês, para volume de corte além de 32,0% para o primeiro mês e 26,0% no segundo mês, para execução de aterro. A RNA7 apresentou resultado semelhante para corte, porém com uma quantidade de camadas e neurônios maior do que a RNA1, levando mais tempo para ser processada pelo software.

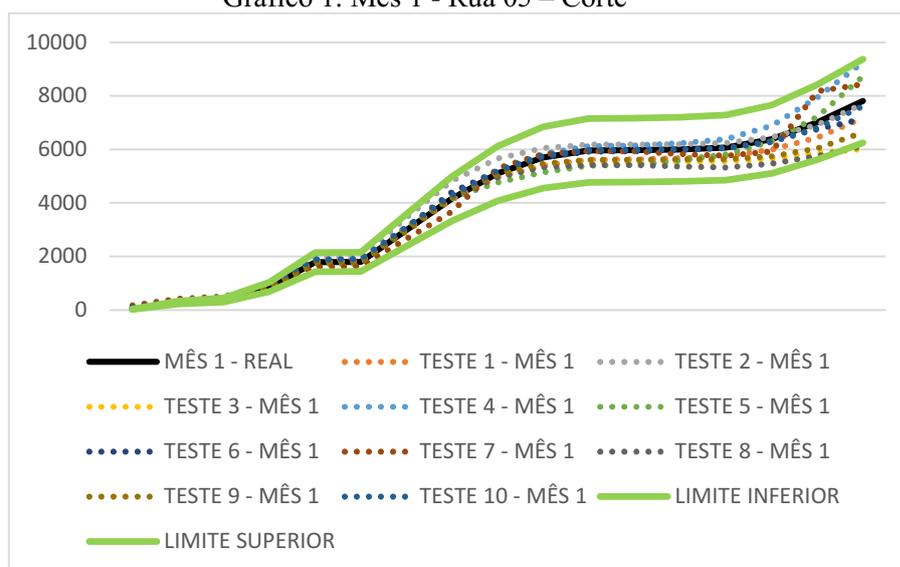
Portanto, para esse tipo de análise, a rede com melhor desempenho foi a RNA1, os gráficos com as regressões para cada teste da RNA1 encontram-se no Anexo I.

Percebe-se que o segundo método de análise trouxe resultados bem mais efetivos mostrando-se, para este caso, a melhor forma de estudo. Quando se compara os dois tipos de análises na tentativa de entender melhor os seus desempenhos, percebe-se que a única diferença entre elas está no valor em metro cúbico de corte e aterro que a rede tem que prever.

Na análise por estaca, a rede deveria prever o valor de corte e aterro estaca por estaca, independentemente da localização por ruas o que, pela característica do projeto, se mostravam valores muito baixos. Na análise por trecho, em contrapartida, o estudo passou a ser no volume de movimentação de terra por rua dentro de um determinado mês. Dessa forma, foi preciso somar os valores de corte e aterro em todas as estacas da rua tornando o valor a ser comparado ao real bem maior do que o usado na análise por estacas e, assim, permitindo maiores variâncias nos resultados.

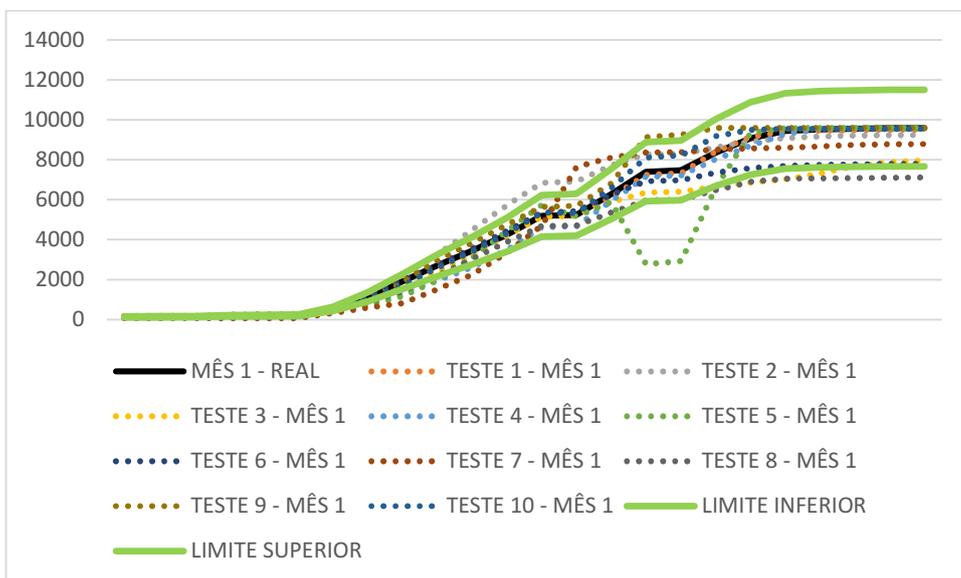
Os gráficos 1 ao 6, apresentados a seguir, mostram a análise do volume de corte por rua e como os valores dos testes, com exceção dos gráficos 5 e 6, mostraram a maioria dos dados variando dentro da margem de erro permitida de 20% - indicador definido empiricamente pelo autor. O eixo “y” indica o volume de corte em metro cúbico acumulado e o eixo “x” a distância em metros ao decorrer do trecho em análise.

Gráfico 1: Mês 1 - Rua 05 – Corte



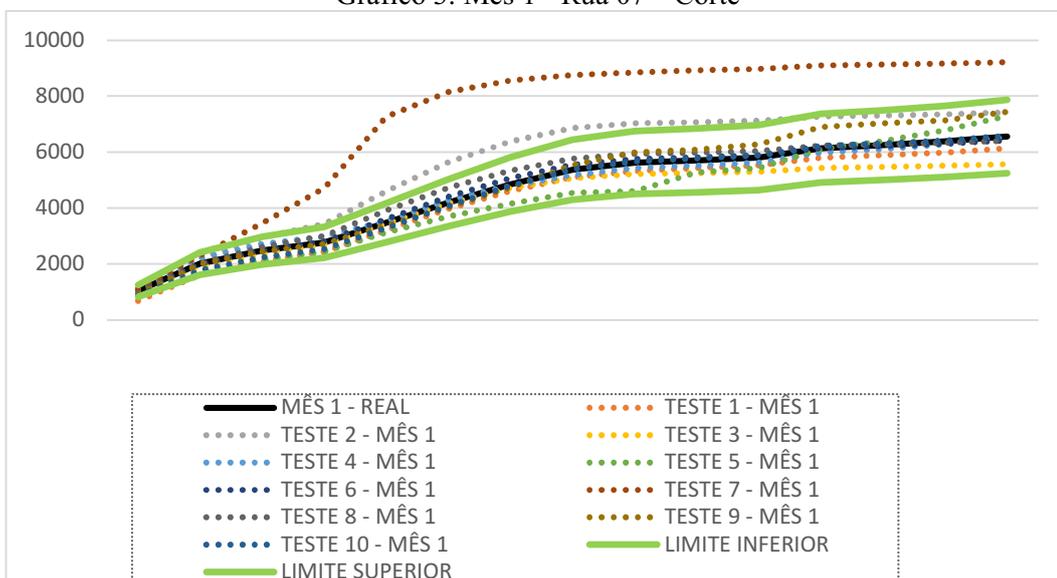
Fonte: Elaborado pelo autor (2021).

Gráfico 2: Mês 1 - Rua 06 – Corte



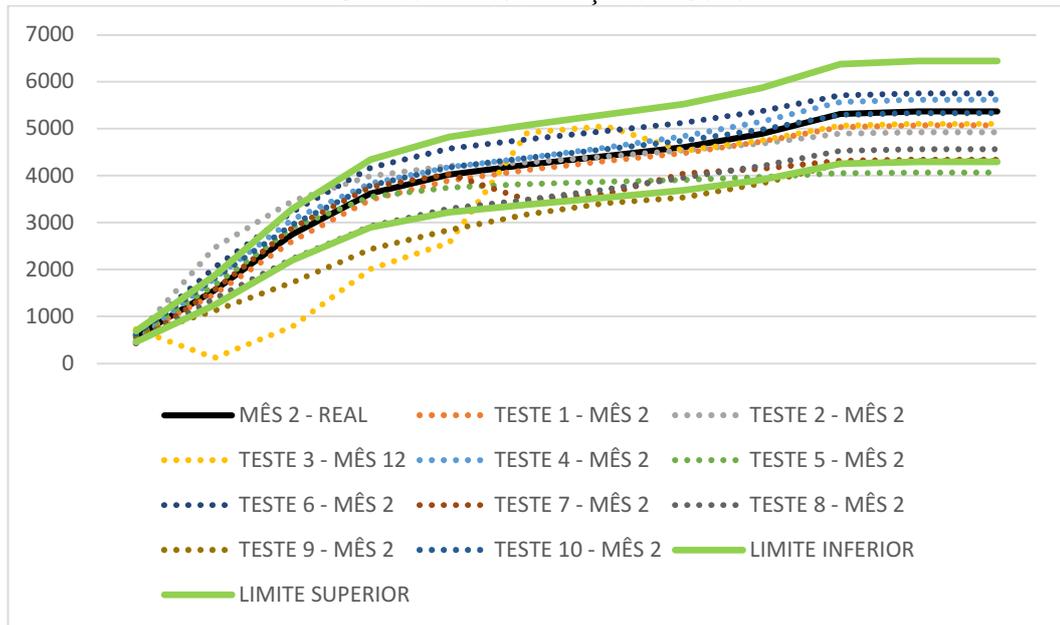
Fonte: Elaborado pelo autor (2021).

Gráfico 3: Mês 1 - Rua 07 – Corte



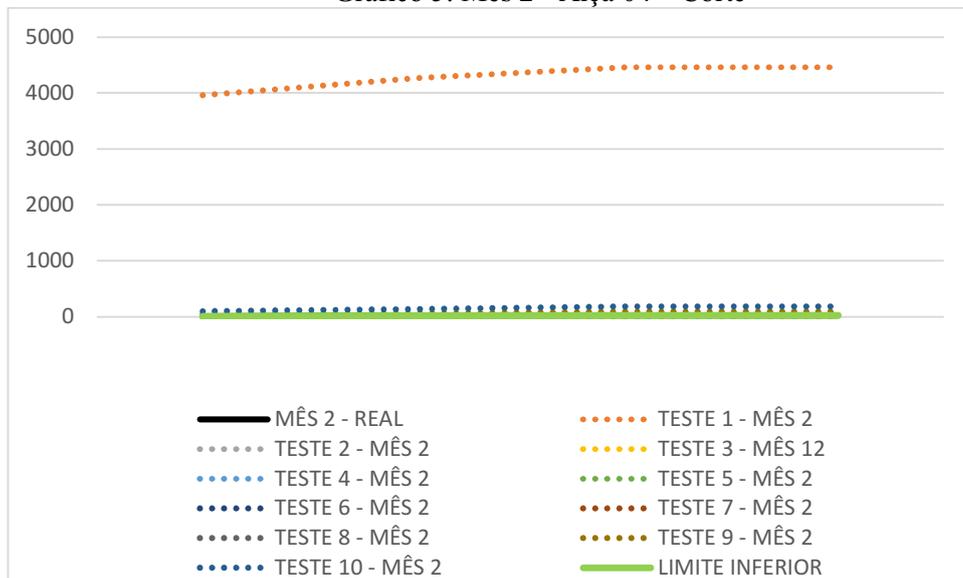
Fonte: Elaborado pelo autor (2021).

Gráfico 4: Mês 2 - Alça 03 – Corte



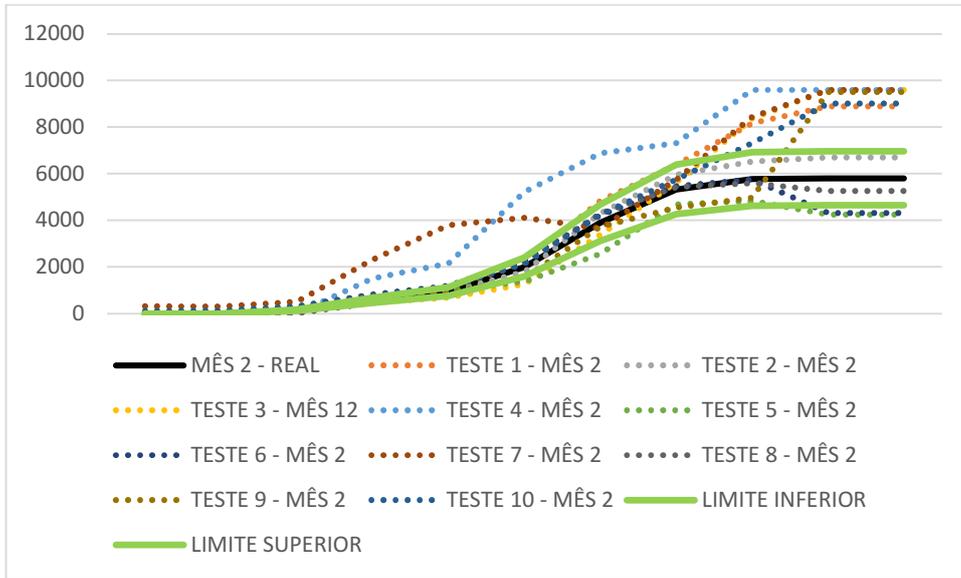
Fonte: Elaborado pelo autor (2021).

Gráfico 5: Mês 2 - Alça 04 – Corte



Fonte: Elaborado pelo autor (2021).

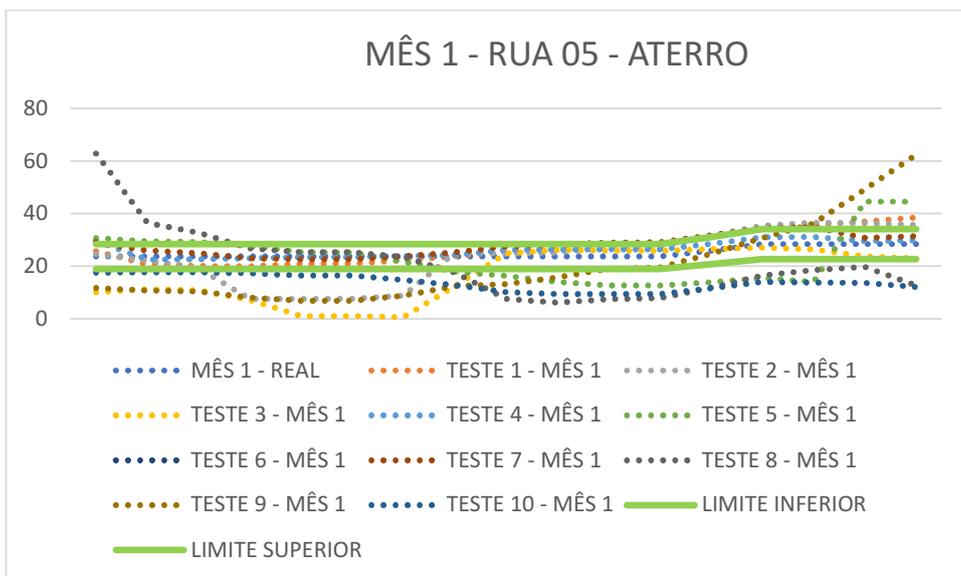
Gráfico 6: Mês 2 - Rua 15 – Corte



Fonte: Elaborado pelo autor (2021).

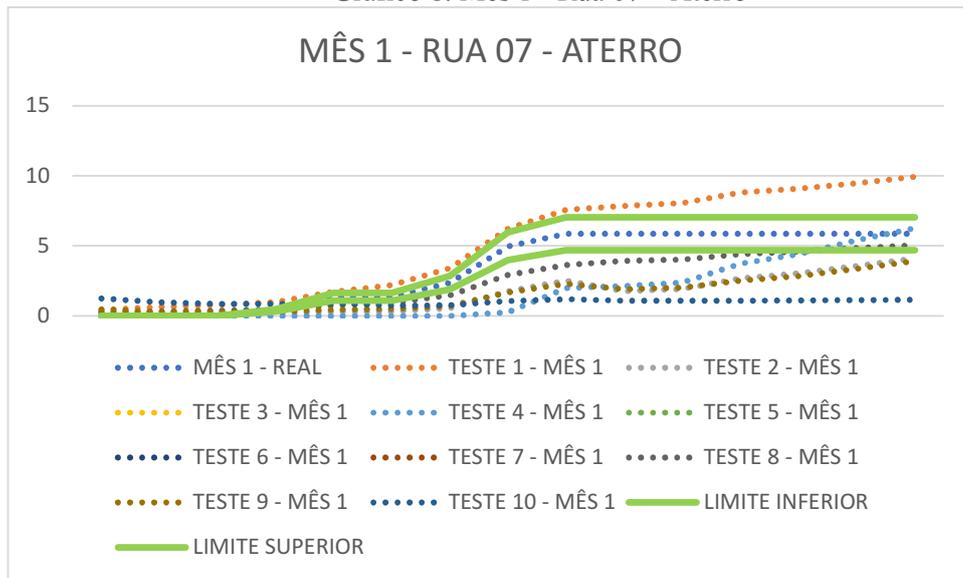
No entanto, para os métodos de análise por estacas e por trecho, não foi possível obter um erro aceitável para a previsão do volume executado de aterro, com resultados de erro médio maiores que 20%, conforme já indicado nas Tabelas 1 e 2. Os gráficos 7 ao 9, apresentados abaixo, exemplificam o erro encontrado.

Gráfico 7: Mês 1 - Rua 05 – Aterro



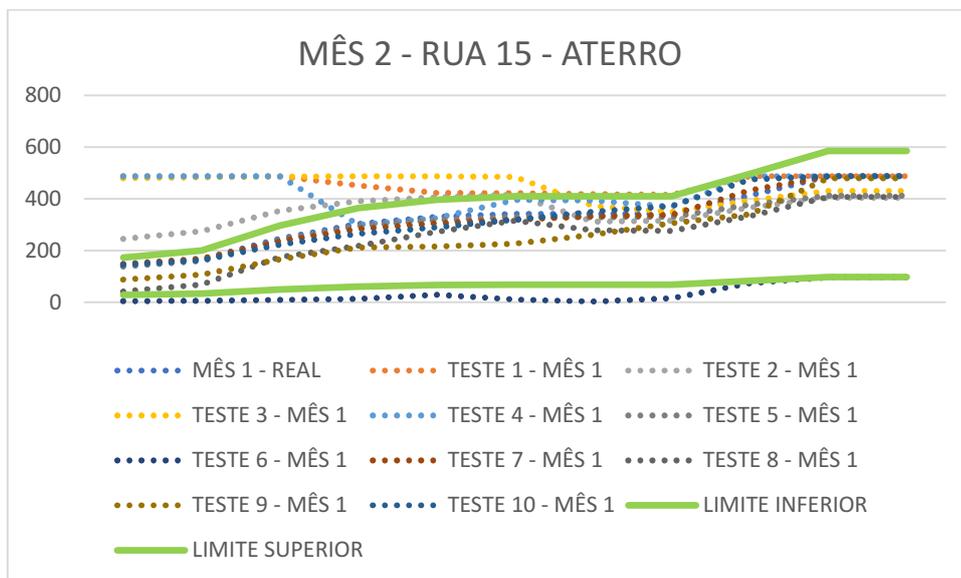
Fonte: Elaborado pelo autor (2021).

Gráfico 8: Mês 1 - Rua 07 – Aterro



Fonte: Elaborado pelo autor (2021).

Gráfico 9: Mês 2 - Rua 15 – Aterro



Fonte: Elaborado pelo autor (2021).

As diferenças nas porcentagens de erro médio nos resultados de volume de corte e aterro podem ser explicadas, especialmente, por dois motivos: Insuficiência de parâmetros de entrada e pouca quantidade de dados disponíveis. A falta de dados como índice pluviométrico no local da obra, quantidade e tipos de máquinas trabalhando, produção em m³/hora de cada máquina, distância média de bota fora ou empréstimo, entre outros, podem ter influenciado de forma negativa os resultados das previsões, principalmente para o volume de aterro.

5.2. PREVISÃO DE DESEMBOLSO

Considerando que o valor do metro cúbico escavado é pago em porcentagens fixas de material de primeira, segunda e terceira, o valor de desembolso é facilmente calculado e está apresentado na Tabela 3 para os meses 1 e 2. O erro médio nos valores de desembolso são os mesmos apresentados para os meses 1 e 2 na previsão do volume escavado e aterrado na Tabela 2 para a RNA1.

Tabela 3: Previsão de desembolso

MÊS 1				MÊS 2			
CORTE		ATERRO		CORTE		ATERRO	
Volume (m ³)	Custo (R\$)						
23970,43	258.868,55	37,32	321,70	11203,54	120.992,60	418,13	3604,28

Fonte: Elaborado pelo autor (2021).

A partir dos resultados apresentados na Tabela 3, pode-se ter uma melhor percepção das diferenças de valores em metro cúbico de corte e aterro executados por mês e como eles podem ter sido essenciais no desempenho das redes desenvolvidas, de modo que os volumes de aterro apresentados nos meses 1 e 2, mesmo que somados, não chegam a 1% do valor total de aterro da obra analisada, o que pode explicar os erros obtidos nas previsões para este tipo de serviço.

No entanto, como já observado antes, a previsão de desembolso para o serviço de corte se mostrou bem consistente e confiável, quando comparada aos resultados reais, o que pode indicar claramente a eficiência do uso de RNA's em previsões de desembolso em serviços de terraplenagem.

6. CONCLUSÕES

Apesar de necessitar de algumas melhorias e aperfeiçoamentos, a rede neural proposta cumpriu com os objetivos estipulados a ela. Através da rede elaborada foi possível, a partir da seleção prévia de um orçamento de obra, elaborar sete arquiteturas diferentes a fim de encontrar a que apresente a melhor taxa de acerto, variando o número de camadas, neurônios e função de ativação. Com isso, para cada rede neural, foram realizados dez testes e aplicada a média em todos eles para chegar à porcentagem de erro de cada RNA. Assim, usando dados e valores estabelecidos em contrato, foi possível prever o resultado de desembolso para os serviços de corte e aterro.

A RNA1 mostrou-se eficaz para previsão de desembolso em serviços de cortes, dentro das obras de terraplenagem, chegando a apresentar um erro médio de 7% no desembolso mensal real, bem abaixo do limite de 20% estabelecido.

Para o serviço de aterro a mesma rede não se mostrou tão eficaz, apresentando o menor erro mensal médio de 26% e chegando até a 32%, o que pode ser explicado pela pouquíssima quantidade de dados para análise, a pequena quantidade de parâmetros de entrada disponíveis para utilização, além do baixo volume de aterro executado nos meses usados para teste.

Portanto, entende-se que, apesar das melhorias que ainda podem e devem ser implantadas, o estudo apresentado contribui para o avanço nas pesquisas a respeito das redes neurais, principalmente na sua aplicação em obras de terraplenagem.

REFERÊNCIAS

- BARRETO, Jorge M. **Introdução às Redes Neurais Artificiais**. Florianópolis: Ufsc, 2002;
- BIONDI NETO, Luiz *et al.* **REDES NEURAS ARTIFICIAIS PARA ESTIMATIVA DE CUSTOS DE CONSTRUÇÃO CIVIL**. Rio de Janeiro: VII Simpósio de Pesquisa Operacional e Logística da Marinha, 2004. 9 f;
- BRITO, Isis Raquel Tacla; BIANCHI, Flavia Regina; CASTRO, Veronica Amanda Brombley Castro. Veronica Amanda Brombley. **Estudo Comparativo Entre Pavimento Rígido e Flexível**. Espírito Santo: Ucl, 2008. Color;
- DACOREGIO, Frederico Amorim. **Estimativa preliminar de custos de obras utilizando redes neurais artificiais**. Frederico Amorim Dacoregio; orientadora, Fernanda Fernandes Marchiori, 2017. 276 p;
- DIANA CAR-PUSIC, SILVANA PETRUSEVA, VALENTINA ZILESKA PANCOVSKA, ZLATKO ZAFIROVSKI, **NEURAL NETWORK-BASED MODEL FOR PREDICTING PRELIMINARY CONSTRUCTION COST AS PART OF COST PREDICTING SYSTEM**, ADVANCES IN CIVIL ENGINEERING , VOL. 2020 , ARTIGO ID 8886170 , 13 PÁGINAS , 2020 . <https://doi.org/10.1155/2020/8886170>;
- FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. L. F. de. **Inteligência artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, 2011
- FALCÃO, Viviane Adriano. **MODELO DE ROTEIRIZAÇÃO PARA A TERRAPLENAGEM EM OBRAS RODOVIÁRIAS APLICANDO PROGRAMAÇÃO LINEAR INTEIRA**. 2016. 104 f. Monografia (Especialização) - Curso de Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, 2016;
- FINOCCHIO, Marco Antonio Ferreira. **NOÇÕES DE REDES NEURAS ARTIFICIAIS**. Paraná: Utfpr, 2014;
- FURTADO, Maria Inês Vasconcellos. F992r Redes neurais artificiais [recurso eletrônico]: uma abordagem para sala de aula / Maria Inês Vasconcellos Furtado. – Ponta Grossa (PR): Atena Editora, 2019;
- GONÇALVES AR. Redes Bayesianas. Andreic [at] dca.fee.unicamp.br;
- GUNAYDIN H. M.; DOGAN S. Z. A neural network approach for early cost estimation of structural systems of buildings. International Journal of Project Management. Turquia, 2004; 22(7):595-602;
- JUSZCZYK, Michał; LEŚNIAK, Agnieszka; ZIMA, Krzysztof. **ANN Based Approach for Estimation of Construction Costs of Sports Fields**. 2018. Disponível em:

<https://www.hindawi.com/journals/complexity/2018/7952434/#summary-and-conclusion>. Acesso em: 08 out. 2021.

Manual de pavimentação. 3.ed. – Rio de Janeiro, 2006. 274p. (IPR. Publ., 719);

MICALI, J. F. M. Um modelo para integração da indústria da construção civil. São Paulo, 2000. 151 f. Tese (doutorado em engenharia civil) - Escola Politécnica, Universidade de São Paulo.;

PASTANA, Carlos Eduardo Troccoli. **Pavimentações de Estradas**. Marília: Unimar, 2006. 88 p;

PEŠKO, Igor *et al.* "Estimation of Costs and Durations of Construction of Urban Roads Using ANN and SVM", Complexity, vol. 2017, Article ID 2450370, 13 pages, 2017. <https://doi.org/10.1155/2017/2450370>;

RICARDO, Hélio de Souza; CATALANI, Guilherme. **Manual prático de Escavação: terraplanagem e escavação de rocha**. 3. ed. São Paulo: Pini, 2000. 393 p;

Russell, S. & Norvig, P. **Artificial Intelligence - A Modern Approach**, PrenticeHall, 1995;

SOUSA, Luiz Manoel; FALCÃO, Viviane Adriano. PLANEJAMENTO DE OBRAS DE TERRAPLENAGEM E PAVIMENTAÇÃO: UM MANUAL DE REFERÊNCIA, 2014.

VIEIRA, Marcello da Costa. **Planejamento Logístico Integrado Aplicado à Programação de obras de infraestrutura de transportes**. 2019. 181 f. Tese (Doutorado) - Curso de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 2019.

ANEXO I

Gráfico de Regressão – RNA1 – TESTE 1

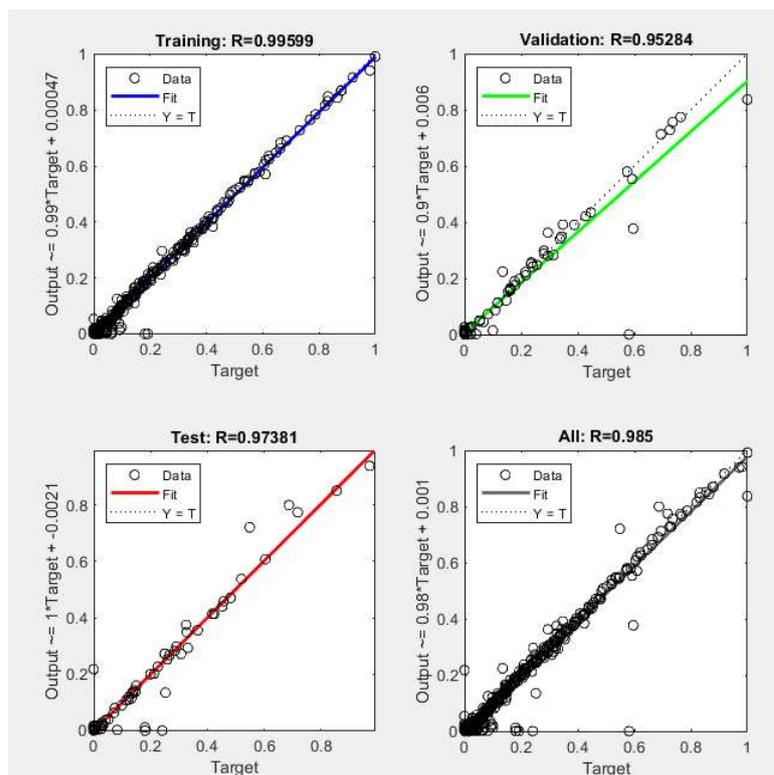


Gráfico de Regressão – RNA1 – TESTE 2

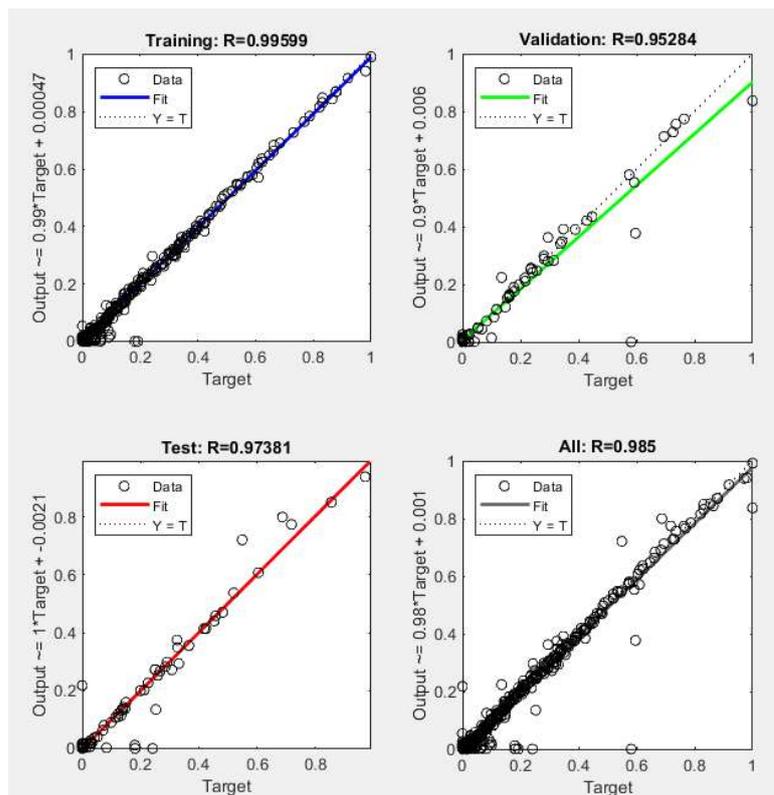


Gráfico de Regressão – RNA1 – TESTE 3

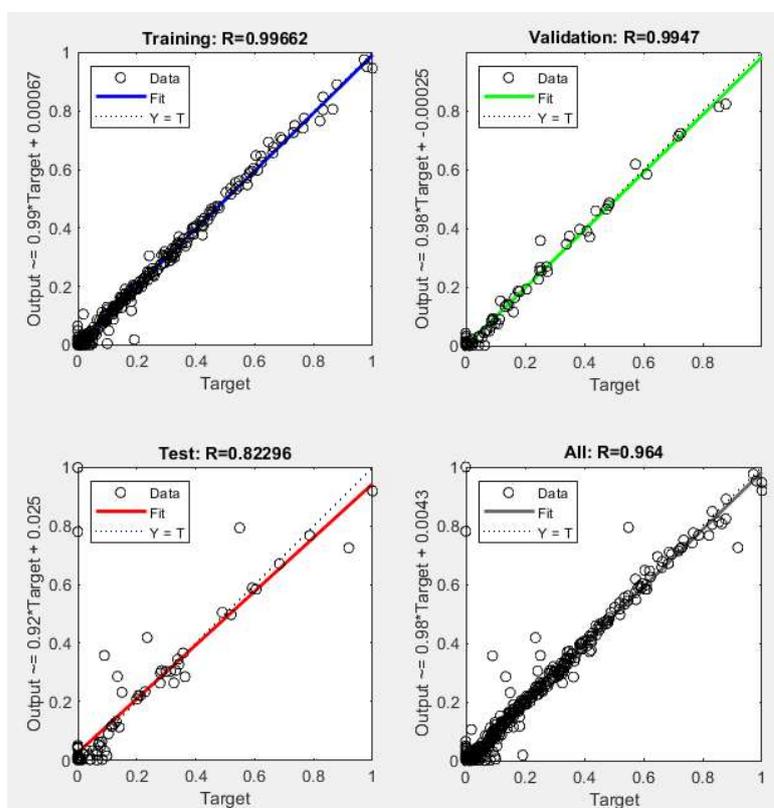


Gráfico de Regressão – RNA1 – TESTE 4

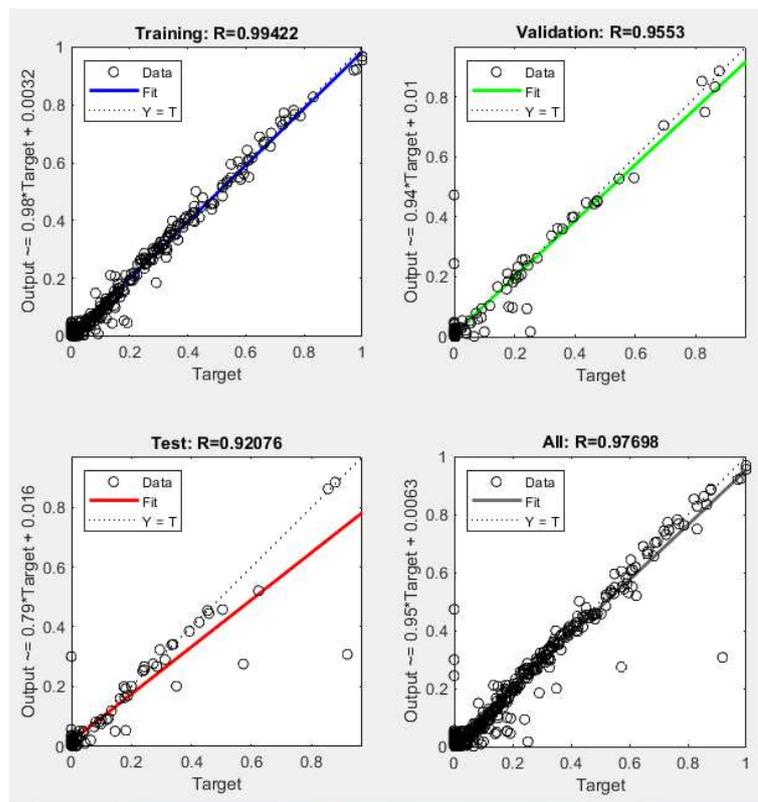


Gráfico de Regressão – RNA1 – TESTE 5

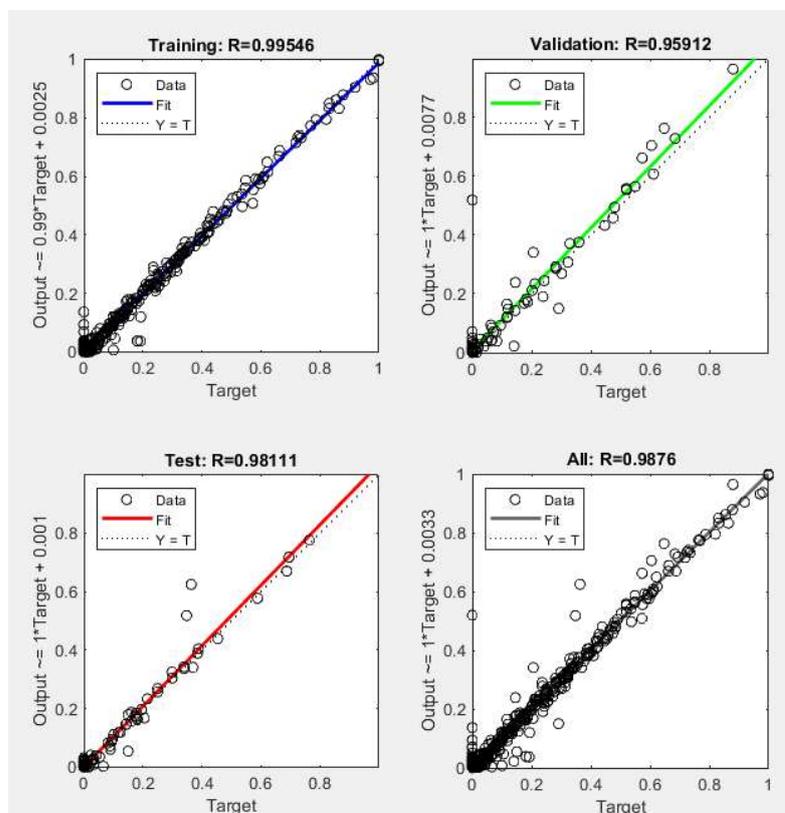


Gráfico de Regressão – RNA1 – TESTE 6

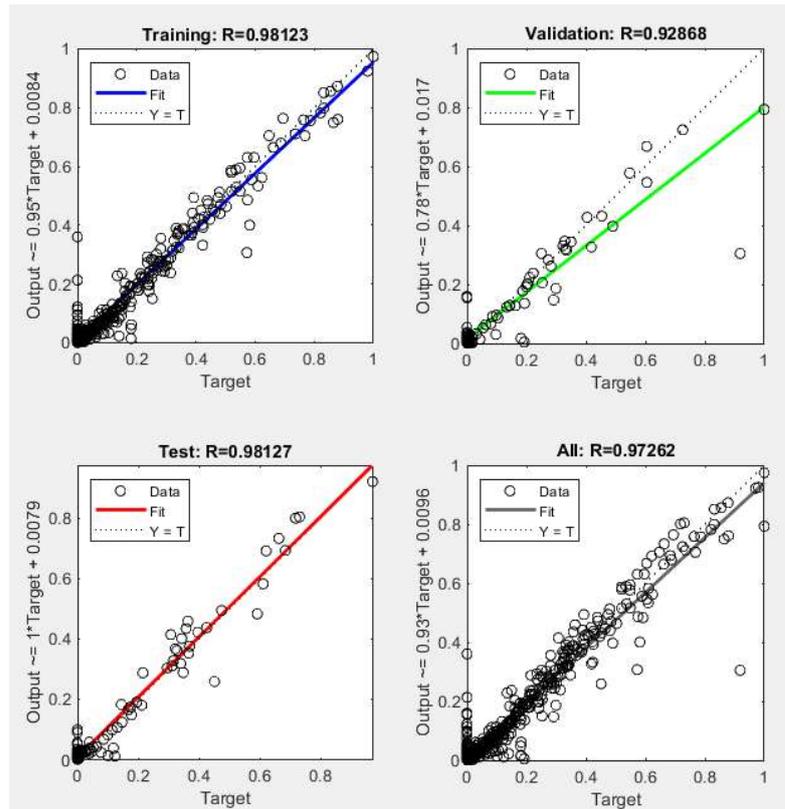


Gráfico de Regressão – RNA1 – TESTE 7

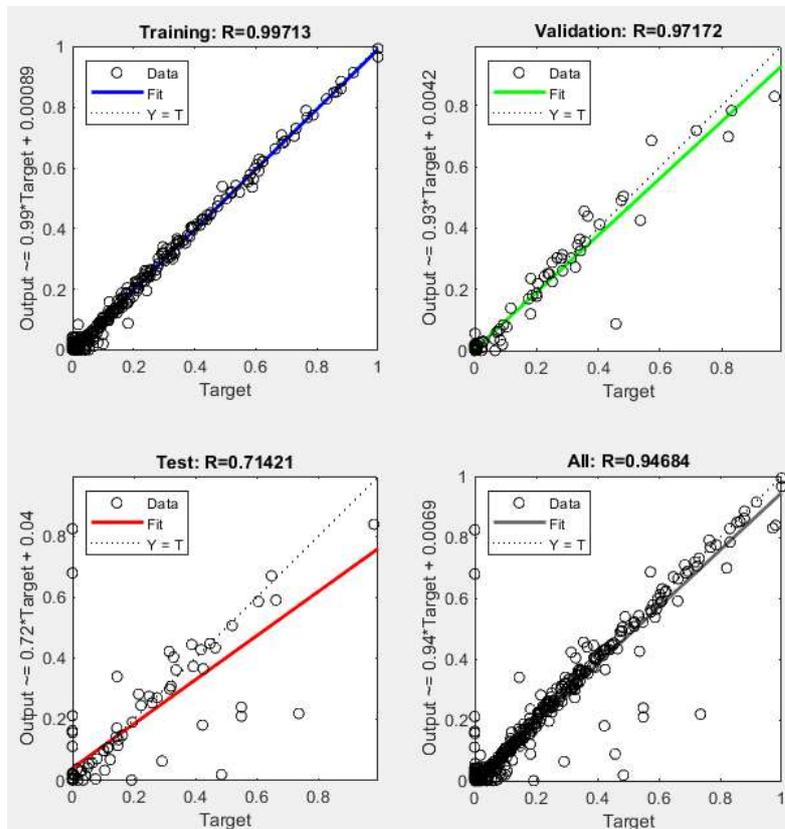


Gráfico de Regressão – RNA1 – TESTE 8

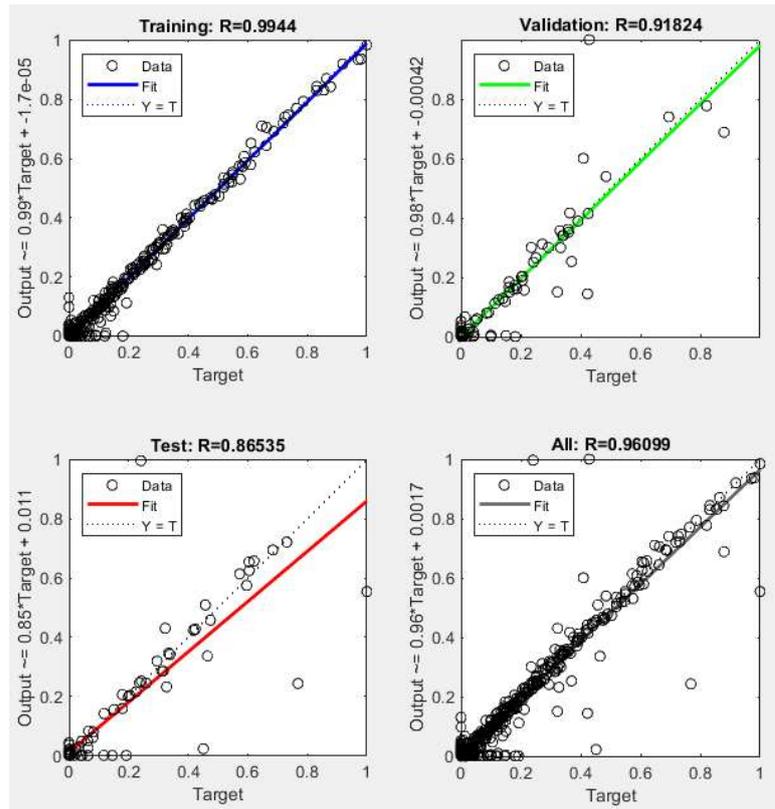


Gráfico de Regressão – RNA1 – TESTE 9

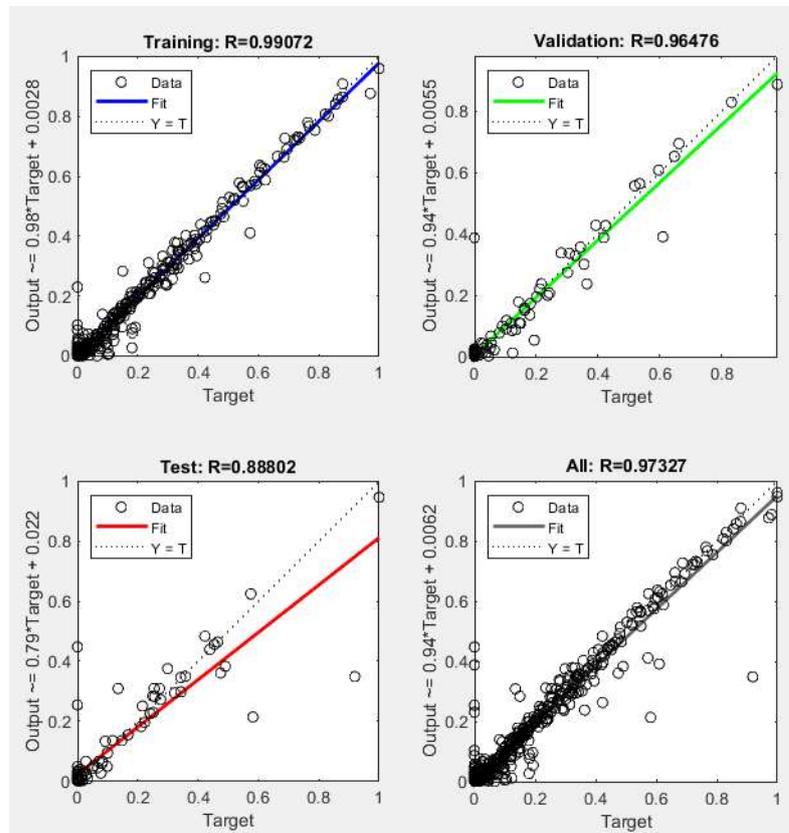


Gráfico de Regressão – RNA1 – TESTE 10

