



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL
CURSO DE ENGENHARIA CIVIL

BERGSON GONÇALVES LOPES VASCONCELOS

**PREDIÇÃO DE RESISTÊNCIA DE CONCRETO DE ALTO DESEMPENHO
ATRAVÉS DE REDES NEURAIS ARTIFICIAIS.**

JOÃO PESSOA

2021

BERGSON GONÇALVES LOPES VASCONCELOS

**PREDIÇÃO DE RESISTÊNCIA DE CONCRETO DE ALTO DESEMPENHO
ATRAVÉS DE REDES NEURAIS ARTIFICIAIS.**

Trabalho de Conclusão de Curso submetido à
Coordenação do Curso de Engenharia Civil da
Universidade Federal da Paraíba, como um
dos requisitos obrigatórios para obtenção do
título de Bacharel em Engenharia Civil.

Orientador: Prof. Dr. Francisco Jácome
Sarmiento.

JOÃO PESSOA

2021

Catálogo na publicação
Seção de Catalogação e Classificação

V331p Vasconcelos, Bergson Goncalves Lopes.
Predição de resistência de concreto de alto
desempenho
através de redes neurais artificiais / Bergson
Goncalves Lopes Vasconcelos. - João Pessoa, 2021.
35 f. : il.

Orientação: Francisco Jácome Sarmento.
Monografia (Graduação) - UFPB/CT.

1. Concreto de Alto Desempenho. 2. Resistência à
Compressão. 3. Redes Neurais Artificiais. 4. Traços de
Concreto. 5. Dosagem de Concreto. I. Sarmento,
Francisco Jácome. II. Título.

UFPB/BSCT

CDU 624 (043.2)

FOLHA DE APROVAÇÃO

BERGSON GONÇALVES LOPES VASCONCELOS

**PREDIÇÃO DE RESISTÊNCIA DE CONCRETO DE ALTO DESEMPENHO
ATRAVÉS DE REDES NEURAIIS ARTIFICIAIS.**

Trabalho de Conclusão de Curso em 06/12/2021 perante a seguinte Comissão Julgadora:



Francisco Jácome Sarmento

Departamento de Engenharia Civil e Ambiental do CT/UFPB


APROVADO



Adriano Rolim da Paz

Universidade Federal da Paraíba – UFPB


Aprovado



Enildo Tales Ferreira

Universidade Federal da Paraíba - UFPB

APROVADO



Profª. Andrea Brasiliano Silva

Matrícula Siape: 1549557

Coordenadora do Curso de Graduação em Engenharia Civil

“O homem não teria alcançado o possível se, repetidas vezes, não tivesse tentado o impossível.”

-Max Weber

AGRADECIMENTOS

Aos meus pais, Joselinda e Marcos, por todo o amor, apoio e motivação, além de serem os melhores exemplos que eu poderia ter.

À minha irmã, Gabriela, por todo o carinho, auxílio e incentivo, sem nunca medir esforços para me ajudar.

A Francisco Sarmiento, professor e orientador, por toda ajuda, compreensão, confiança, paciência e dedicação.

Aos professores Adriano Rolim da Paz e Enildo Tales Ferreira, pela gentileza em aceitar o convite para participar da banca examinadora.

Aos colegas de curso, que se tornaram grandes amigos, por todo companheirismo, amparo e estímulo, em especial, George, Lucas, Felipe, Diego, Abimael, João Félix, Gabriel, Josielly, Paula, Késsia, Nathália e Cecília.

A todos os amigos e familiares que contribuíram de alguma maneira ao longo desses cinco anos de graduação.

RESUMO

Embora seja talvez o insumo mais popular da construção civil, o concreto requer bastante atenção em sua dosagem (principalmente o concreto de alto desempenho), e muitas vezes necessita de inúmeros ajustes empíricos para se garantir uma resistência à compressão compatível com a de projeto. Considerando ainda que os métodos mais consolidados para dosagem do traço de concreto fazem uso de ábacos e tabelas empíricas, faz-se notar, nessa ausência de método matemático direto, uma promissora possibilidade de aplicação de Redes Neurais Artificiais para se ter um método mais simples e confiável para dosagem do traço e determinação da resistência à compressão do concreto de alto desempenho a partir da proporção dos materiais que o compõem, visto que elas são modelos computacionais bastante eficazes na resolução de problemas complexos. Este trabalho tem como objetivo desenvolver um modelo de predição da resistência à compressão de concretos de alto desempenho através da utilização de Redes Neurais Artificiais com base nas proporções dos materiais que constituem o concreto, tendo obtido resultados consideravelmente satisfatórios.

Palavras Chave: Concreto de Alto Desempenho; Resistência à Compressão; Redes Neurais Artificiais; Traços de Concreto; Dosagem de Concreto.

ABSTRACT

Although it is perhaps the most popular material in civil construction, concrete requires a lot of attention in its dosage (especially high-performance concrete), and often requires numerous empirical adjustments to ensure compressive strength compatible with the designed. Considering that most of the consolidated methods for concrete dosage uses abacuses and empirical tables, it is noted, in this absence of a direct mathematical method, a promising possibility of applying Artificial Neural Networks to have a simpler and reliable method for concrete dosage and determination of high-performance concrete compressive strength based on the proportion of the materials that compose it, since they are computational models very effective in solving complex problems. This work aims to develop a model to predict the compressive strength of high-performance concretes through the use of Artificial Neural Networks based on the proportions of the materials that constitute the concrete, obtaining remarkably satisfactory results.

Keywords: High Performance Concrete; Compressive Strength; Artificial Neural Network; Concrete Trace; Concrete Dosage.

LISTA DE FIGURAS

Figura 1 – Modelo não linear do neurônio artificial	19
Figura 2 – Exemplo de Rede Alimentadas Diretamente com Múltiplas Camadas	20
Figura 3 – Tela de Inicialização do MATLAB R2021b	21
Figura 4 – Exemplo de aplicação do MATLAB	22
Figura 5 – Tela Inicial do MATLAB.	23
Figura 6 – Janela de Gerenciamento de Complementos do MATLAB.....	24
Figura 7 – Primeiras 20 linhas do banco de dados utilizado	25
Figura 8 – Código utilizado no MATLAB.	26
Figura 9 – Caixa de diálogo inicial do comando “nnstart”	27
Figura 10 – Esquema da Arquitetura da Rede Neural Artificial	28
Figura 11 – Resultados do treinamento da Rede Neural Artificial	30
Figura 12 – Gráfico de performance da Rede Neural Artificial	31
Figura 13 – Histograma de erros da Rede Neural	32
Figura 14 – Gráficos de correlação da Rede Neural Artificial	33

LISTA DE TABELAS

Tabela 1 – Divisão dos dados entre as etapas de processamento da Rede Neural	28
Tabela 2 – Critérios de Parada para o Treinamento da Rede Neural.....	29
Tabela 3 – Erro quadrático médio nas etapas de processamento da Rede Neural.....	31
Tabela 4 – Coeficientes de correlação das etapas de processamento da Rede Neural	32

LISTA DE ABREVIATURAS E SIGLAS

ABCP – Associação Brasileira de Cimento Portland

ACI - American Concrete Institute

CAD – Concreto de Alto Desempenho

CC – Concreto Convencional

EQM – Erro Quadrático Médio

MATLAB - MATrix LABoratory

RNA – Rede Neural Artificial

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	CONTEXTUALIZAÇÃO	13
1.2	OBJETIVOS E JUSTIFICATIVAS	14
1.2.1	Objetivo Geral.....	14
1.2.2	Objetivo Específico	14
1.2.3	Justificativa.....	14
2	REFERENCIAL TEÓRICO	15
2.1	CONCRETO DE ALTO DESEMPENHO	15
2.1.1	Definições e Componentes.....	15
2.1.2	Resistência à Compressão	16
2.2	REDES NEURAIS ARTIFICIAIS	17
2.2.1	Conceitos e Definições	17
2.2.2	Funcionamento da Rede Neural Artificial	18
2.2.3	Software Utilizado para Modelagem da Rede Neural.....	21
3	MATERIAIS E MÉTODOS	24
3.1	BANCO DE DADOS	24
3.2	MODELAGEM E PARÂMETROS ADOTADOS NO TREINAMENTO DA REDE.....	27
4	RESULTADOS E DISCUSSÕES.....	30
4.1	RESULTADOS DO TREINAMENTO DA REDE.....	30
4.2	CORRELAÇÕES OBTIDAS	32
4.3	RESULTADOS DE PREDIÇÃO DE RESISTÊNCIA À COMPRESSÃO.....	33
5	CONSIDERAÇÕES FINAIS	34
6	REFERÊNCIAS BIBLIOGRÁFICAS.....	35

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

A descoberta da relação água-cimento (a/c) de Abrams em 1918 foi descrita como o avanço mais útil e significativo na história da tecnologia do concreto. A formulação mais importante dele foi a proporcionalidade inversa entre a relação a/c e a resistência à compressão do concreto. Assim, a Lei de Abrams geralmente aceita é uma formulação da observação de que o aumento da proporção a/c diminui a resistência do concreto, enquanto a diminuição da relação a/c aumenta sua resistência. A implicação, portanto, é que as resistências de vários concretos comparáveis são idênticas, desde que suas relações a/c permaneçam as mesmas, independentemente das proporções dos demais materiais que o compõem (Oluokun 1994). A regra de Abrams implica que apenas a qualidade da pasta de cimento controla a resistência do concreto. Entretanto, segundo Yeh (1998), “A análise de uma variedade de dados experimentais mostra que isso não é totalmente verdade”.

Nesse contexto, vários estudos independentes mostraram que o desenvolvimento da resistência do concreto é determinado não apenas pela relação a/c, mas também é influenciado pelo conteúdo dos outros componentes (Oluokun 1994). Portanto, embora os dados experimentais tenham mostrado a aceitabilidade prática desta regra dentro de limites amplos, alguns desvios foram relatados. As atuais equações empíricas apresentadas nos códigos e padrões para estimar a resistência à compressão são baseadas em ensaios de concreto sem materiais cimentícios complementares, o que nos permite observar mais algumas variantes complexas a serem determinadas na solução do problema da dosagem do concreto.

Na busca por saídas para este problema, têm-se como promissora solução a utilização de Redes Neurais Artificiais, que são uma família de arquiteturas paralelas que resolvem problemas difíceis por meio da cooperação de elementos de computação altamente interconectados, mas simples (ou neurônios artificiais). Basicamente, os elementos de processamento de uma rede neural são semelhantes aos neurônios do cérebro, que consistem em muitos elementos computacionais simples dispostos em camadas. O interesse em redes neurais se expandiu bastante nas últimas décadas. Muito do sucesso das redes neurais é devido a características como processamento não linear, processamento paralelo, etc. Dessa maneira, busca-se analisar a aplicabilidade das Redes Neurais Artificiais na determinação da

resistência à compressão de concretos de alto desempenho a partir dos traços utilizados para dosá-los.

1.2 OBJETIVOS E JUSTIFICATIVAS

1.2.1 Objetivo Geral

Desenvolvimento de um modelo de predição de resistência à compressão de concretos de alto desempenho através de uma Rede Neural Artificial.

1.2.2 Objetivo Específico

Este trabalho tem como objetivo específico: calcular e apresentar as correlações obtidas entre as resistências calculadas para os concretos de alto desempenho através da Rede Neural Artificial e seus respectivos valores de resistência à compressão medidos em laboratório.

1.2.3 Justificativa

A proposição do tema pode ser vista como uma maneira de sugerir alternativas para as estimativas empíricas e não tão precisas para dosagem de concretos de alto desempenho, buscando agilizar esse processo e reduzir a quantidade de ajustes experimentais necessários após a dosagem do traço inicial.

2 REFERENCIAL TEÓRICO

2.1 CONCRETO DE ALTO DESEMPENHO

2.1.1 Definições e Componentes

O concreto simples, ou concreto convencional (CC) é formado basicamente por uma mistura de aglomerante (cimento Portland, em geral), agregado miúdo (usualmente areia), agregado graúdo (geralmente brita) e água. Podem ser empregados outros componentes como aditivos e adições minerais, com o intuito de se melhorar algumas propriedades do concreto, tanto no estado fresco como no estado endurecido (FILHO e LINS, 2003).

Enquanto o concreto de alto desempenho (CAD) pode ser definido como uma evolução do CC, possuindo superiores parâmetros de resistência, trabalhabilidade e durabilidade, conforme Tutikian, Isaia e Helene (2011). O CAD é indicado para situações e/ou peças estruturais específicas, quando se necessita de um concreto com características especiais, como por exemplo, para uma viga extremamente densa em armadura, a qual poderia apresentar falhas de concretagem devido a segregação ou exsudação no concreto caso se utilizasse um concreto convencional. Ele também pode ser definido como sendo “um concreto que atenda uma combinação especial entre desempenho e requisitos de uniformidade que não pode ser atingida rotineiramente com o uso de componentes convencionais e práticas normais de mistura, lançamento e cura.” (ACI, 1998).

Nesse cenário, ao se fazer um projeto estrutural, é considerado um determinado valor para a resistência do concreto (f_{ck}), assim, ao executar o projeto, deve-se garantir um concreto com mínima resistência equivalente àquela de projeto. Dessa forma, para conseguir alcançar então o f_{ck} de projeto, é necessário misturar os componentes do concreto na proporção correta, isto é, realizar a devida dosagem do traço do concreto.

Já o traço de um concreto, trata-se da proporção com que cada um destes entra na mistura, tendo a quantidade de cimento como a unidade de referência. Dessa maneira, ele é apresentado como uma sequência de números que indicam estas proporções (ex.: 1:3:5:0,5; o que representa um traço em que se tem, para cada parte de cimento, três partes de agregado miúdo, cinco partes de agregado graúdo e meia parte de água).

Embora não se disponha de equações e métodos matemáticos para dosagem do concreto e para determinação de sua resistência à compressão em função dos materiais constituintes, existem diversos métodos empíricos para tal, entre os quais se destacam o proposto pelo American Concrete Institute (ACI) e o da Associação Brasileira de Cimento Portland (ABCP).

Apesar de existirem inúmeros métodos para a dosagem do concreto, nenhum possibilita a obtenção de um traço (proporção dos materiais) final diretamente, isto é, sem a necessidade de ajustes experimentais. Assim sendo, é necessário preparar um corpo de prova experimental e realizar o ensaio de compressão para verificar se as propriedades desejadas foram atingidas após a determinação do traço do concreto, sendo comumente ainda necessárias correções no traço após o ensaio (OLIVEIRA et al., 2007).

Embora complexo e muitas vezes bastante empírico e repetitivo, o processo de dosagem do traço do concreto é fundamental para um bom desempenho da estrutura, visto que inúmeras patologias podem ocorrer devido à falta de resistência desejada. Segundo NEVILLE e BROOKS (2010), um concreto mal dosado pode gerar problemas de erosão, aberturas de fissuras, descoloração, lixiviação e durabilidade. Sabendo-se então da importância de garantir uma resistência adequada do concreto, é importante definir o que é esta característica e como ela pode ser obtida.

2.1.2 Resistência à Compressão

Quando se trata de um concreto no estado endurecido, a resistência à compressão do concreto é sua principal propriedade e é a que normalmente é utilizada para se caracterizar o concreto. Desta forma, na engenharia estrutural, geralmente um concreto é especificado em termos de sua resistência característica à compressão aos 28 dias (f_{ck}). Essa resistência corresponde a uma probabilidade de 95% de ser alcançada no sentido favorável quando se ensaiam um determinado número de corpos de prova, definido pela NBR 6118/2014 (ABNT 2014), em laboratório, 28 dias após a preparo dos corpos de prova.

Logo, ao serem confeccionados vários corpos de prova utilizando um mesmo traço, ou seja, de um mesmo concreto, têm-se que suas resistências à compressão apresentam uma distribuição de frequências próxima da normal (TAVARES, 2002), e a partir das resistências atingidas dos corpos de provas, pode-se calcular a resistência característica à compressão

(fck) do concreto, que é obtida através do ensaio de resistência à compressão, normatizado pela NBR 5739/94 (ABNT 1994).

Dessa maneira, todos os cálculos e projetos das estruturas de concreto armado e protendido são realizados levando em conta o valor da resistência característica à compressão aos 28 dias do concreto, logo é imprescindível a garantia de conformidade desta propriedade, havendo o risco de a estrutura ser comprometida devido à baixa capacidade de suporte causada por uma baixa resistência à compressão do concreto que a compõe.

2.2 REDES NEURAIIS ARTIFICIAIS

2.2.1 Conceitos e Definições

Redes Neurais Artificiais (RNA's) são programas computacionais criados para aprender algo e foram inspirados na estrutura do cérebro humano, de maneira que fossem capazes de apresentar características humanas necessárias ao tratamento de problemas para os quais não existem equações desenvolvidas ou são de difícil modelagem por meio das técnicas computacionais tradicionais (Haykin, 2001).

Nesse contexto, as Redes Neurais Artificiais possuem algumas propriedades que as tornam bastante promissoras na resolução de problemas, e dentre estas propriedades, destacam-se: aprendizado por experiência (“Fitting”); generalização de novos exemplos a partir dos já apresentados; obtenção ou extração de características essenciais de dados ruidosos; classificação e padronização de conjunto de dados (“Pattern Recognition”); associação entre padrões diferentes (“Clustering”).

O modo de funcionamento das Redes Neurais também diverge dos demais programas tradicionais, que possuem execução direta, pois elas são executadas em duas fases distintas de processamento, em que a primeira busca treinar a rede de acordo com os dados disponíveis e na segunda é feita sua validação (podendo haver uma terceira para teste da rede).

Dessa forma, em sua primeira fase de processamento, a etapa de treinamento, são apresentados os padrões de dados que devem ser mapeados e aprendidos pela rede, e a cada iteração realizada pela Rede Neural Artificial, é medido o erro, calculado entre a saída obtida


pelo processo iterativo do treinamento e o valor conhecido que se deseja atingir, o “target” (alvo).

Assim, a rede passa por esse processo iterativo de treinamento até que o erro atinja um valor considerado satisfatório para a aplicação investigada, e então são salvos todos os parâmetros e configurações da Rede Neural criada. Após essa primeira fase, e já com esse aprendizado adquirido e armazenado, é iniciada a segunda fase de processamento da Rede Neural, que é a fase de execução, em que ela será testada (calculando o erro da mesma maneira da fase de treinamento). Nesta etapa serão apresentados à Rede Neural Artificial padrões de testes, também sob forma numérica, dos dados aos quais se deseja fazer o diagnóstico e que, normalmente, não fizeram parte do treinamento. Ou seja, dos dados iniciais utilizados para criar a Rede Neural, uma porção é utilizada para a fase de treinamento e outra para a fase de validação. Após concluídas as duas fases com um valor considerado razoável para o erro, pode-se validar a Rede Neural Artificial testando-a com novos dados.

Existem inúmeras aplicações das Redes Neurais na engenharia civil, como por exemplo, para solução de sistema de inequações lineares, para determinação de custos imobiliários, para criação de modelos de chuva-vazão, etc.

2.2.2 Funcionamento da Rede Neural Artificial

Buscando se assemelhar às estruturas biológicas nas quais se inspiram, as RNAs possuem neurônios (artificiais), que se tratam de conjuntos de unidades de processamento. Estes neurônios artificiais atuam paralelamente uns aos outros e armazenam o conhecimento adquirido pela rede (FARIAS, 2006).

Figura 1 – Modelo não linear do neurônio artificial

Fonte: Adaptado de Haykin (2001)

Esta unidade básica de processamento da Rede Neural (neurônio artificial) possui alguns componentes básicos, como pode ser visto na figura 1. Os sinais de entrada (x_n) são responsáveis pela ativação da RNA e correspondem aos dados iniciais fornecidos à rede (“inputs”). Já os pesos (w_{in}) referem-se aos valores numéricos das conexões ou sinapses, multiplicando os sinais de entrada, que são ajustáveis e modificam a RNA durante seu treinamento. O componente bias (b_i), de maneira semelhante aos pesos, é um valor numérico ajustável que varia ao longo do treinamento da RNA buscando ajustá-la para se ter uma melhor performance. Já a junção aditiva (também conhecida como campo local induzido) é o componente do neurônio artificial em que é realizado o somatório das operações realizadas pelos componentes descritos anteriormente (sinais de entrada, pesos e bias). Composta então a junção aditiva (m), ela é submetida a uma função de ativação ($f(m)$), que tem como objetivo restringir a saída, limitando a amplitude do neurônio a um valor finito, sendo geralmente duas possibilidades de saída do neurônio artificial (y): $[0,1]$ ou $[-1,1]$. Este processo pode ser representado pelas equações (1) e (2).

$$m = \sum_{n=1}^N w_{in} * x_n + b_i \quad \text{Eq. (1)}$$

$$y = f(m) \quad \text{Eq. (2)}$$

A partir destes componentes básicos da arquitetura das Redes Neurais Artificiais, elas podem ser estruturadas de diversas formas. Geralmente são modeladas camadas compostas por 1 ou mais neurônios, podendo haver apenas uma camada com o(s) neurônio(s) de entrada e uma com o(s) de saída, bem como a RNA pode possuir 1 ou mais camadas ocultas com

inúmeros neurônios. Dentre essas possibilidades para a arquitetura da RNA, conforme explica Haykin (2001), destacam-se 3 principais:


- Redes Alimentadas Adiante com Camada Única

Caracterizam-se por possuir, além da camada de entrada de neurônios, apenas uma camada de nós computacionais (neurônios), a de saída.

- Redes Alimentadas Diretamente com Múltiplas Camadas

Essa classe de Redes Neurais se particulariza por possuir uma ou mais camadas ocultas de nós computacionais (neurônios ocultos), nas quais se busca intervir entre as camadas de entrada e de saída de maneira a otimizar a performance da RNA.

Figura 2 – Exemplo de Rede Alimentadas Diretamente com Múltiplas Camadas



Fonte: FLECK et al., UFTPR (2016)

- Redes Recorrentes

Estas se diferenciam das duas primeiras não pela composição de suas camadas, mas pela forma como se dão suas sinapses. Diferentemente das anteriores, em que as sinapses alimentavam sempre os neurônios posteriores, as redes recorrentes se caracterizam por possuírem pelo menos um laço de realimentação, em que a saída de um neurônio de uma camada posterior serve como sinal de entrada para um neurônio de uma camada anterior.

Já no que concerne ao processo de aprendizagem da RNA, Haykin (2001) o resume como a sequência de três eventos: “A rede neural é estimulada por um ambiente. A rede neural sofre modificações nos seus parâmetros livres como resultado desta estimulação. A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na

sua estrutura interna.” Esses eventos sucintamente descrevem o que acontece com a RNA durante seu processo de aprendizagem, entretanto, a maneira com que ocorrem as modificações em seus parâmetros é o aspecto mais relevante deste processo.


Existem várias regras de aprendizagem de Redes Neurais, sendo a principal delas a de aprendizagem por correção de erro, em que se é comparada a saída do neurônio com a resposta desejada ou alvo (“target”) e calculado o erro. A partir deste erro calculado para cada neurônio, seus pesos e bias são reajustados, obtêm-se uma nova saída da rede e o processo é repetido até que se tenha um resultado satisfatório (ou se atinja algum critério de parada do treinamento da rede).

Utilizando da regra de aprendizagem por correção de erro, foram desenvolvidos inúmeros algoritmos com esta finalidade, inclusive alguns considerados de “alto desempenho” (FIORIN, 2011), como o de Levenberg-Marquardt, considerado um dos mais rápidos e eficientes no treinamento de Redes Neurais Artificiais.

2.2.3 Software Utilizado para Modelagem da Rede Neural

Atualmente existem diversos softwares disponíveis para criação de Redes Neurais Artificiais, dentre eles, o escolhido para utilização neste trabalho foi o “MATrix LABoratory” MATLAB, do qual foi recentemente disponibilizada a licença estudantil pela Universidade Federal da Paraíba.


Figura 3 - Tela de Inicialização do MATLAB R2021b



Fonte: MathWorks (2021)


O MATLAB é um software desenvolvido pela MathWorks voltado para programação e cálculo numérico, com o objetivo de analisar dados, desenvolver algoritmos e criar modelos computacionais. Ele surgiu inicialmente apenas para resolução de problemas matriciais, mas logo se expandiu pela comunidade acadêmica, principalmente na área da matemática aplicada, e foi se tornando eficaz em inúmeras áreas do conhecimento e aplicações, como engenharia, robótica, sistemas de controle, processamento de sinais e de imagens, “Deep Learning”, “Machine Learning”, análise de dados e sistemas de condução autônomos. A figura 4 ilustra umas das aplicações do MATLAB, em que podem ser observados dois gráficos tridimensionais gerados pelo software.

Figura 4 – Exemplo de aplicação do MATLAB



Fonte: MathWorks (2021)

Sua escolha para utilização neste trabalho deve-se à praticidade de utilização e primazia na elaboração de Redes Neurais Artificiais e modelos computacionais, além de ser reconhecido internacionalmente como um dos melhores softwares para os fins almejados neste trabalho e para programação em geral.

Figura 5 - Tela Inicial do MATLAB

Fonte: Autor (2021)

A figura 5 traz a tela inicial do software e, em destaque, a janela de comando (“Comand Window”) onde podem ser executados códigos instantâneos simples (um por vez). Já na janela vizinha (“Workspace”, espaço de trabalho em inglês) ficam armazenadas todas as variáveis utilizadas durante a execução do software. E através da utilização de “Scripts” ou “Live Scripts” podem ser escritos arquivos com várias linhas de códigos para os mais variados fins.


Além das inúmeras funcionalidades deste software, como a criação de rotinas de cálculos complexos e a elaboração de programas executáveis, ele também permite a instalação de complementos para resolução de problemas específicos.

3 MATERIAIS E MÉTODOS

Para a elaboração deste trabalho, isto é, para a modelagem da Rede Neural capaz de realizar a predição da resistência do concreto de alto desempenho foi necessário utilizar um banco de dados considerável para treinar a rede e também configurar a rede de maneira que ela se ajustasse o melhor possível aos dados.

Já quanto ao MATLAB, foram instalados dois complementos no software, as caixas de ferramentas (ou “ToolBox’s”) de “Deep Learning” e “Neural Network”, conforme mostra a Figura 6.

Figura 6 – Janela de Gerenciamento de Complementos do MATLAB



Fonte: Autor (2021)

Assim, após a instalação dos complementos ao MATLAB, foi criado um “Live Script” (documento para desenvolvimento de códigos no software) e então iniciou-se a elaboração do trabalho. Vale ressaltar que o MATLAB possui linguagem de programação própria, do tipo interpretada e simples de ser utilizada.

3.1 BANCO DE DADOS

O banco de dados utilizado foi obtido do trabalho “Modeling of Strength of High-Performance Concrete Using Artificial Neural Networks” do pesquisador I-Cheng Yeh, do Departamento de Engenharia Civil da Universidade de Chung-Hua, Taiwan. O banco de

dados possui as características de 1030 corpos de prova rompidos de concretos de alto desempenho. A figura 7 apresenta uma amostra desse banco de dados com os títulos de cada coluna.

Figura 7 - Primeiras 20 linhas do banco de dados utilizado

Cement (component 1)(kg in a m ³ mixture)	Blast Furnace Slag (component 2)(kg in a m ³ mixture)	Fly Ash (component 3)(kg in a m ³ mixture)	Water (component 4)(kg in a m ³ mixture)	Superplasticizer (component 5)(kg in a m ³ mixture)	Coarse Aggregate (component 6)(kg in a m ³ mixture)	Fine Aggregate (component 7)(kg in a m ³ mixture)	Age (day)	Concrete compressive strength(MPa, megapascals)
540,0	0,0	0,0	162,0	2,5	1040,0	676,0	28	79,99
540,0	0,0	0,0	162,0	2,5	1055,0	676,0	28	61,89
332,5	142,5	0,0	228,0	0,0	932,0	594,0	270	40,27
332,5	142,5	0,0	228,0	0,0	932,0	594,0	365	41,05
198,6	132,4	0,0	192,0	0,0	978,4	825,5	360	44,30
266,0	114,0	0,0	228,0	0,0	932,0	670,0	90	47,03
380,0	95,0	0,0	228,0	0,0	932,0	594,0	365	43,70
380,0	95,0	0,0	228,0	0,0	932,0	594,0	28	36,45
266,0	114,0	0,0	228,0	0,0	932,0	670,0	28	45,85
475,0	0,0	0,0	228,0	0,0	932,0	594,0	28	39,29
198,6	132,4	0,0	192,0	0,0	978,4	825,5	90	38,07
198,6	132,4	0,0	192,0	0,0	978,4	825,5	28	28,02
427,5	47,5	0,0	228,0	0,0	932,0	594,0	270	43,01
190,0	190,0	0,0	228,0	0,0	932,0	670,0	90	42,33
304,0	76,0	0,0	228,0	0,0	932,0	670,0	28	47,81
380,0	0,0	0,0	228,0	0,0	932,0	670,0	90	52,91
139,6	209,4	0,0	192,0	0,0	1047,0	806,9	90	39,36
342,0	38,0	0,0	228,0	0,0	932,0	670,0	365	56,14
380,0	95,0	0,0	228,0	0,0	932,0	594,0	90	40,56
475,0	0,0	0,0	228,0	0,0	932,0	594,0	180	42,62

Fonte: I-Cheng Yeh, Universidade de Chung-Hua, Taiwan (1998)

As primeiras 7 colunas trazem a quantidade de cada componente do traço do concreto utilizado para moldar o corpo de prova:

- 1ª: Cimento, em quilogramas por m³ de concreto (kg/m³);
- 2ª: Escória de Alto Forno, em quilogramas por m³ de concreto (kg/m³);
- 3ª: Cinzas Volantes, em quilogramas por m³ de concreto (kg/m³);
- 4ª: Água, em quilogramas por m³ de concreto (kg/m³);
- 5ª: Aditivo Superplastificante, em quilogramas por m³ de concreto (kg/m³);
- 6ª: Agregado Graúdo, em quilogramas por m³ de concreto (kg/m³);
- 7ª: Agregado Miúdo, em quilogramas por m³ de concreto (kg/m³).

Já as duas últimas colunas referem-se ao ensaio de resistência à compressão realizado, sendo a 8ª coluna a idade (em dias) do concreto em que foi rompido e a 9ª a resistência à compressão do concreto em megapascals (MPa).

Para a modelagem da Rede Neural, os dados das 8 primeiras colunas foram considerados como as informações de entrada para obtenção da resistência à compressão do concreto de alto desempenho (dado de saída da rede). Enquanto a resistência à compressão obtida em laboratório (9ª coluna do banco de dados) foi utilizada para avaliar a precisão da Rede Neural, sendo confrontada com a resistência calculada pela Rede. Essa escolha se deveu à busca por extrair o máximo de informações do banco de dados, almejando treinar uma RNA mais completa e com menos restrições.

Inicialmente os dados foram obtidos em tabela no Excel (Figura 7), necessitando serem importados para o MATLAB, o que foi realizado através das seguintes linhas de códigos.

Figura 8 - Código utilizado no MATLAB

```

1 ConcreteData = readmatrix("Concrete_Data.xls");
2 ResistenciasEnsaaiadas = ConcreteData(:,9);
3 ResistenciasEnsaaiadas = ResistenciasEnsaaiadas';
4 Dados_Concretos_TracoUnitario= NaN(1030,8);
5 for i=1:7
6     for j=1:1030
7         Dados_Concretos_TracoUnitario(j,i)=ConcreteData(j,i)/ConcreteData(j,1);
8         Dados_Concretos_TracoUnitario(j,8)=ConcreteData(j,8);
9     end
10 end
11 Dados_Concretos_TracoUnitario = Dados_Concretos_TracoUnitario';

```

Fonte: Autor (2021)


Sendo o arquivo original do banco de dados o “Concrete_Data.xls”, a linha 1 do código lê o arquivo em Excel e o transforma em uma matriz de 1030 linhas e 9 colunas. Já as linhas 2 e 3 do código criam uma variável em forma de vetor (“ResistenciasEnsaaiadas”) com as resistências à compressão de cada traço do banco de dados e transformam o vetor coluna em um vetor linha (conversão necessária para inserção dos dados na criação da RNA).

Em seguida foi necessário fazer um tratamento dos dados para se ter um melhor desempenho da rede, transformando os valores absolutos de massa de cada componente do traço utilizado para cada concreto em traços unitários, isto é, dividindo cada um dos valores pela massa de cimento do traço. A necessidade desse ajuste foi observada através de diversos testes realizados utilizando os dados originais e os dados convertidos (traços unitários). Dessa forma, as linhas 4 a 11 do código criam uma nova matriz com os traços convertidos para forma unitária e a invertem para ser utilizada na RNA.

3.2 MODELAGEM E PARÂMETROS ADOTADOS NO TREINAMENTO DA REDE

Após a importação do banco de dados e os ajustes necessários apresentados no item 3.1, parte-se para a modelagem da Rede Neural e a definição de seus parâmetros. Dentro do software MATLAB, esta configuração é feita através do comando “nnstart”, o qual inicializa a caixa de ferramentas para criação de RNA’s.

Figura 9 - Caixa de diálogo inicial do comando “nnstart”



Fonte: Autor (2021)


Nesta janela inicial é definido o tipo de Rede Neural a ser modelada que, como explicado anteriormente, foi do tipo “Fitting”. Em seguida serão estabelecidos os parâmetros da rede para que ela possa ser treinada. Os primeiros parâmetros adotados foram referentes a divisão dos dados entre as etapas de treinamento, validação e teste da rede, para as quais foram definidos os percentuais de 85%, 10% e 5%, respectivamente. Assim, tivemos 875 dados para a fase de treinamento da rede, 103 para a de validação e 52 para a de teste, como ilustra a tabela 1.

Tabela 1 – Divisão dos dados entre as etapas de processamento da Rede Neural

Etapa de Processamento	Quantidade de Conjunto de Dados
Treinamento	875
Validação	103
Teste	52

Fonte: Autor (2021)

Posteriormente, foi preciso definir o tamanho da camada oculta de neurônios da rede. Este processo foi realizado através de inúmeros testes, em que se obteve os melhores resultados de ajuste da rede com uma camada oculta contendo 16 neurônios. A figura 10 ilustra a arquitetura final da Rede Neural construída, compreendendo os 8 neurônios de entradas iniciais correspondentes aos “inputs”, os 16 neurônios da camada oculta e o neurônio de saída com a resistência esperada do concreto de alto desempenho (“output”).

Figura 10 – Esquema da Arquitetura da Rede Neural Artificial

Fonte: Autor (2021)

Já em relação ao algoritmo utilizado, foi escolhido o modelo de Levenberg-Marquardt como algoritmo de treinamento da Rede Neural. A divisão dos dados entre as etapas de treinamento, validação e teste foi feita de maneira aleatória ou randômica e a performance da rede foi avaliada através do método do erro quadrático médio. Foram definidos também os critérios de parada para o treinamento da rede, assim, ao atingir o valor máximo para um desses parâmetros, encerra-se o processo de treinamento da rede. Cada um desses parâmetros e seus respectivos valores limites estão expostos na tabela 2.

Tabela 2 – Critérios de Parada para o Treinamento da Rede Neural

Critério de Parada	Valor Máximo
Gerações (“Epochs”)	1000
Performance (EQM)	0
Gradiente	10^{-7}
Mu	10^{10}
Checagens de Validação	6

Fonte: Autor (2021)


Esses critérios utilizados no algoritmo de Levenberg-Marquardt buscam avaliar a performance da rede, almejando alcançar os menores valores de erros possíveis. Assim, o critério de número de gerações limita a “quantidade máxima de tentativas” para o treinamento da rede, já o da performance busca alcançar um grau de convergência da rede em que o erro seja igual a 0. Já os últimos três critérios, assim como o das gerações, interrompem o treinamento da rede para evitar que ela fique em execução indeterminadamente sem que haja melhoras em sua performance entre uma geração e outra. O do gradiente avalia a melhora na performance da rede e a interrompe quando o desempenho da rede é muito semelhante geração a geração. O critério de aprendizado Mu limita o valor máximo de aprendizado que a rede pode alcançar durante seu processamento, e, por fim, o critério das checagens de validação limita por quantas gerações seguidas é aceitável um aumento contínuo no valor do erro. Após concluída a modelagem da Rede Neural e definidos todos os seus parâmetros de treinamento, ela então é executada, como exposto no tópico a seguir.

4 RESULTADOS E DISCUSSÕES

4.1 RESULTADOS DO TREINAMENTO DA REDE


Utilizando o algoritmo de treinamento de Levenberg-Marquardt, foi obtido o melhor desempenho para o treinamento da rede após apenas 4 segundos (evidenciando a capacidade de processamento do software MATLAB e o potencial do algoritmo utilizado), como ilustra a figura 11.

Figura 11 – Resultados do treinamento da Rede Neural Artificial



Fonte: Autor (2021)

Como pode ser visto na figura 11, na 34ª geração da rede se atingiu o limite máximo de 6 checagens de validação, isto é, por 6 gerações seguidas da rede o erro quadrático médio continuou aumentando, sendo, portanto, a 28ª geração da Rede Neural a de melhor desempenho na etapa de validação. A figura 12 traz a evolução da performance da rede em cada etapa ao longo das gerações.

Figura 12 – Gráfico de performance da Rede Neural Artificial

Fonte: Autor (2021)


Como pode ser observado na figura 12, o erro quadrático médio decresceu significativamente nas primeiras gerações até se tornar aproximadamente constante a cada nova “epoch” (embora tenha continuado a diminuir na etapa de treinamento, o mesmo não foi observado nas outras etapas).

Tabela 3 – Erro quadrático médio nas etapas de processamento da Rede Neural

Etapas de Processamento	Erro Quadrático Médio (MPa²)
Treinamento	19.9851
Validação	34.1941
Teste	23.1568

Fonte: Autor (2021)

Dessa maneira, segundo a tabela 3, teve-se que o erro quadrático médio para as etapas de treinamento, validação e teste foi 19.9851 MPa², 34.1941 MPa² e 23.1568 MPa², respectivamente. Já na figura 13, pode ser observado o histograma de erro da rede treinada com todos os 1030 conjuntos de dados utilizados.

Figura 13 – Histograma de erros da Rede Neural

Fonte: Autor (2021)

4.2 CORRELAÇÕES OBTIDAS

Outra métrica a destacar é a correlação entre os resultados obtidos pela rede e as resistências esperadas, o que permite avaliar o grau de precisão das predições das resistências à compressão para concretos de alto desempenho geradas através da Rede Neural Artificial.


Tabela 4 – Coeficientes de correlação das etapas de processamento da Rede Neural

Etapas de Processamento	Coefficiente R^2
Treinamento	0.96333
Validação	0.94751
Teste	0.95361
Todas	0.96097

Fonte: Autor (2021)

Para cada uma das etapas de execução da rede foi gerado um gráfico de correlação entre as resistências calculadas (eixo Y) e as esperadas (eixo X). Conforme a tabela 4, pode-se observar que os coeficientes R^2 de correlação se aproximaram bastante de 1 em todas as etapas, alcançando 0.96333 na etapa de treinamento, 0.94751 na de validação e 0.95361 na de teste. Já considerando todos os dados de todas as etapas, obteve-se o coeficiente de correlação R^2 igual a 0.96097, ou seja, um resultado bastante satisfatório. Já a figura 14 traz os gráficos de correlação dos dados para cada uma das etapas de processamento (e também o gráfico com todos os dados reunidos) com as curvas de ajuste.

Figura 14 – Gráficos de correlação da Rede Neural Artificial



Fonte: Autor (2021)

4.3 RESULTADOS DE PREDIÇÃO DE RESISTÊNCIA À COMPRESSÃO

Como introduzido nas seções anteriores, a RNA modelada obteve excelentes resultados de predição da resistência à compressão dos concretos de alto desempenho ensaiados, apresentando notável convergência entre as resistências resultantes da rede e as esperadas. A correlação obtida para todos os dados de resistência à compressão de 96,097% revela a ótima precisão alcançada pela rede. A grande maioria dos dados se aproximou bastante da curva $Y=T$, sendo Y as respostas de saída da rede e T (ou “target”, alvo em inglês) as resistências à compressão esperadas, como pode ser observado na figura 14.

Embora os resultados tenham sido consideravelmente satisfatórios, utilizando como variáveis para predição da resistência à compressão do concreto apenas os teores em massa de seus componentes, poder-se-ia ter um modelo bem mais genérico e eficiente caso se dispusesse de mais informações a respeito do concreto moldado, como por exemplo: as características granulométricas dos agregados, o tipo de aglomerante utilizado, as condições climáticas do local em que o concreto foi dosado, dentre outras.

5 CONSIDERAÇÕES FINAIS

Inicialmente, apenas analisando a problemática explanada e considerando a inexistência de um método exato para a solução do problema, já se podia esperar resultados promissores com a utilização da tecnologia das Redes Neurais Artificiais, capazes de simplificar problemas bastante difíceis.

Assim, embora seja bastante complexa a determinação do traço de um concreto de alto desempenho, o trabalho demonstrou ser possível prever a resistência à compressão do concreto a partir do seu traço, treinando-se a RNA com a dosagem e a resistência real resultante dessa dosagem. Dessa maneira, pode-se evitar reajustes experimentais desnecessários na dosagem do concreto, sendo possível que esses ajustes sejam feitos utilizando a própria RNA associada a um banco de dados, sem a necessidade de desperdiçar materiais e energia em ensaios feitos em laboratório.

Pôde-se perceber que as RNA's podem ser bastante eficientes na resolução do problema exposto no trabalho, revelando consideráveis agilidade e confiabilidade dos resultados. Além disso, foi possível notar também a possibilidade de aplicação das Redes Neurais Artificiais utilizando diversos materiais (como variados aditivos para concreto) e de diferentes localidades, e, além disso, para determinação de outras características do concreto como consistência, resistência à abrasão, resistência à tração, tensão de aderência, módulo de elasticidade, coeficiente de Poisson e permeabilidade.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, R.S. de; NETO, L.B.; TAVARES, M.E.N.. **Emprego de Redes Neurais Artificiais na Definição do Traço e na Obtenção de Resistência e Consistência de Concretos Usuais**. In: I Congresso de Estatística e Investigação Operacional da Galiza e Norte de Portugal e VI Congresso Galego de Estatística e Investigación de operaciós. Guimarães. CEIO 2005. Azarém: Universidade do Minho, 2005.

AMERICAN CONCRETE INSTITUTE. Committee 363R-92 (Reapproved 1997). **State of the art reporte on high strength concrete. ACI Manual of Concrete Practice**, part 1. Farmington Hills: ACI, 1998.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5739 - Concreto – Ensaio de compressão de corpos-de-prova cilíndricos**, Rio de Janeiro, 1994.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6118: Projeto de estruturas de concreto - Procedimento**. Rio de Janeiro, 2014.

BRAGA, Antônio de Pádua; LUDERMIR, Teresa Bernarda; CARVALHO, André Carlos Ponce de Leon Ferreira. **Redes Neurais: Teoria e aplicações**. Rio de Janeiro: Ltc, 2000

DA SILVA, G. **Redes Neurais Artificiais Para A Identificação De Objetos Contidos Em Imagens**. 2015.Trabalho de Conclusão de Curso (Graduação em Ciência da Computação). Instituto Municipal de Ensino Superior de Assis, São Paulo, 2015

DE JESUS, S. **Dosagem De Concretos Convencionais Utilizando Computação Bioinspirada**. 2015. Dissertação (Mestrado em Engenharia Civil e Ambiental). Universidade Estadual De Feira De Santana, Feira de Santana, 2015.

FARIAS, C. **Uso De Redes Neurais Artificiais Na Determinação De Dosagens Para Produção De Blocos De Concreto Com Resíduos Da Construção Civil**. Dissertação (Mestrado em m Ciência e Engenharia de Materiais). Universidade Federal de Campina Grande, Campina Grande, 2006.

FILHO, M.C.; LINS, L.N.. **Apostila de Materiais de Construção Civil I**. Curso de materiais de construção I, UERJ, Rio de janeiro, 2003.

FILHO, R. **Otimização De Vigas De Concreto Armado Utilizando Algoritmos Genéticos E Redes Neurais Artificiais**. 2016.Trabalho de Conclusão de Curso (Graduação em Engenharia Civil). Universidade Católica de Brasília, Distrito Federal, 2016

FIORIN, Daniel V. et al. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. Revista Brasileira de Ensino de Física [online]. 2011, v. 33, n. 1 [Acessado 15 Novembro 2021], pp. 01-20.

FLECK, Leandro; TAVARES, Maria Hermínia Ferreira; EYNG, Eduardo; HELMANN, Andrieli Cristina; ANDRADE, Minéia Aparecida de Moares. **Redes Neurais Artificiais: Princípios Básicos**. Revista Eletrônica Científica Inovação e Tecnologia, 2016, Paraná, v. 1, n. 13, p. 47-57, jan./jun. 2016

GETAHUN, M. A.; SHITOTE, S. M.; ABIERO GARIY, Z. C. **Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes**. Construction and Building Materials, v. 190, p. 517–525, 2018. Disponível em: <<https://doi.org/10.1016/j.conbuildmat.2018.09.097>>.

HAYKIN, S. **Redes Neurais: Princípios e Prática**, 3ª Edição, São Paulo. Bookman. 2001.

I-CHENG YEH, “**Modelling of strength of high performance concrete using artificial neural networks**,” Cement and Concrete Research, Vol. 28, No. 12, pp. 1797-1808 (1998).

KOVÁCS, Zsolt L. **Redes Neurais Artificiais: Fundamentos e aplicações**. 3. ed. São Paulo: Livraria da Física, 1996

MATSUNAGA, V. **Curso de Redes Neurais utilizando o MATLAB**. Belém, 2012. Disponível em: <<https://www.muriloleal.com.br/visao/repositorio/centec/eai/ia/REDES%20NEURAS%20-%20APOSTILA.pdf>>.

NEVILLE, A. M.; BROOKS, J. J. **Tecnologia do concreto**. 2 ed. Porto Alegre: Bookman Editora LTDA, 2010.

OLIVEIRA, H. M. de; BIONDI NETO, L.; TAVARES, M. E. de N. **Redes Neurais Artificiais na Obtenção do Traço e na Definição da Resistência à Compressão de Concretos de Alta Resistência**. Simpósio de Pesquisa Operacional e Logística da Marinha, 2007.

OLUOKUN, F.A.; **Fly Ash Concrete Mix-Design And The Water-Cement Ratio Law** (1994)

ROCHA, Stéphanie *et al.* Utilização de redes neurais para estimativa da resistência à compressão do concreto simples. **Brazilian Journal of Development**, [s. l.], v. 6, ed. 10, p. 79910-79922, oct 2020.

RODRIGUES, P. P. F.. **Parâmetros de dosagem do concreto**. Associação Brasileira de Cimento Portland, 3.ed. São Paulo, 1998.

TAVARES, M.E.N.. **Apostila de concreto armado**. Curso de concreto armado, UERJ, Rio de Janeiro, 2002.

TAVARES, M.E.N.; OLIVEIRA, H. M.; ALMEIDA, R.S. de; NETO, L.B.. **Validação Experimental de Traços de Concreto obtidos por Redes Neurais Artificiais**. In: VI Simpósio EPUSP Estruturas de Concreto. São Paulo, 2006

TUTIKIAN, B.; HELENE, P.; ISAIA, G. Concreto: Ciência e Tecnologia. **Concreto de Alto e Ultra-Alto Desempenho**. 2011. cap.36.

YEH, I.-C. Modeling Of Strength Of High-Performance Concrete Using Artificial Neural Networks. In: **Cement and Concrete Research**. USA: Elsevier Science Ltd, 1998. v. 28, p. 1797–1808.