

**CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
CAMPUS TIMÓTEO**

Lucas Gabriel Garcia Bourguignon

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA MODELAR A
FUNÇÃO DE DEGRADAÇÃO DO CONCRETO EXPOSTO À
SULFATO DE MAGNÉSIO**

Timóteo

2017

Lucas Gabriel Garcia Bourguignon

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA MODELAR A
FUNÇÃO DE DEGRADAÇÃO DO CONCRETO EXPOSTO À
SULFATO DE MAGNÉSIO**

Monografia apresentada à Coordenação de Engenharia de Computação do Campus Timóteo do Centro Federal de Educação Tecnológica de Minas Gerais para obtenção do grau de Bacharel em Engenharia de Computação.

Orientador: Prof. Me. Douglas Nunes de Oliveira

Coorientador: Prof. Dr. Evandro Tolentino

Timóteo

2017

Lucas Gabriel Garcia Bourguignon


Utilização de redes neurais artificiais para modelar a função de degradação do concreto exposto à sulfato de magnésio

Monografia apresentada à Coordenação de Engenharia de Computação do Campus Timóteo do Centro Federal de Educação Tecnológica de Minas Gerais para obtenção do grau de Bacharel em Engenharia de Computação.

Trabalho aprovado. Timóteo, 17 de maio de 2017:




Prof. Me. Douglas Nunes de Oliveira
Orientador



Prof. Dr. Evandro Tolentino
Coorientador



Prof. Me. Luciano Nascimento Moreira
Professor Convidado



Prof. Me. Allisson Pinto Chaves
Professor Convidado

Timóteo
2017

Dedico esse trabalho à minha família
por todo apoio e incentivo.

Agradecimentos

Agradeço primeiramente a minha família, aos meus pais Eliete e Ailson, ao meu irmão Juninho e sua esposa Maiza, que me conscientizaram sobre a importância dos estudos, me incentivaram e apoiaram durante toda minha vida, para conseguir chegar até aqui, eles são o que tenho de mais precioso na vida. Agradeço a Thamyris, por todos momentos de compreensão, apoio e companheirismo.

Agradeço a todos meus amigos, que participaram diretamente de todas as alegrias e dificuldades que passamos para concluir este curso.

Agradeço ao CEFET, todos os professores, toda equipe administrativa e aos demais funcionários por me proporcionar um ambiente agradável e propício para o meu crescimento pessoal e intelectual.

Agradeço em especial aos professores Douglas Nunes de Oliveira e Evandro Tolentino, que foram de extrema importância para o desenvolvimento deste trabalho, contribuindo não só com seus inestimáveis conhecimentos mas também com todo incentivo necessário para alcançar o objetivo final.

E por ultimo, mas não menos importante, agradeço a Deus que me guiou e colocou todas essas pessoas incríveis no meu caminho. Que ele continue me guiando por toda minha vida.

“Mais que de máquinas, precisamos de humanidade.”.
Charles Chaplin

Resumo

Um concreto durável é aquele que atinge o tempo de serviço para o qual foi projetado, no ambiente ao qual foi exposto. A durabilidade de um concreto pode ser limitada, como resultado do desempenho de seus materiais constituintes ao ataque químico. Dentre os produtos químicos que podem agredir um concreto estão os sulfatos, que podem estar presentes em solos e águas subterrâneas ou marítimas. Após a penetração dos íons sulfato no concreto, os cristais de monosulfoaluminato de cálcio da pasta de cimento endurecida podem se converter em gesso ou etringita, o que resulta numa expansão volumétrica que produz tensões internas, levando à destruição da pasta de cimento, causando o enfraquecimento do concreto. Este trabalho apresenta a construção, treinamento e aplicação de uma Rede Neural Artificial (RNA) para estimar a deterioração de concretos por ataque por sulfato, utilizando como base de dados os resultados obtidos por degradação de concretos de cimento Portland por exposição ao sulfato de magnésio. Como resultado a RNA apresentou um resultado próximo ao obtido pelos experimentos empíricos, mostrando que uma RNA pode ser usada como um aproximador universal de funções. Os resultados encontrados viabilizam um futuro aprimoramento da RNA para resolver problemas ainda não solucionados.

Palavras-chave: Redes neurais artificiais. Concreto. Ataque por sulfato.

Abstract

A concrete is durable if it has accomplished the desired service life in the environment in which it is exposed. The durability of concrete can be limited as a result of adverse performance of its constituents under chemical attack. Amongst other aggressive chemical exposures, the sulphate attack is an important concern. Water, soils and gases, which contain sulphate, represent a potential threat to the durability of concrete structures. Upon the penetration of sulphate ions into the concrete, the calcium monosulfoaluminate crystals in the paste may convert into gypsum or ettringite. It results in a change to a larger molar volume, and these volumetric changes cause expansion and internal stresses, which ultimately destroy the paste bonds, deteriorating the concrete. The present work presents the application of the neural networks for estimating deterioration of various concrete mixtures due to exposure to sulphate solutions. A neural networks model was constructed, trained and tested using the available database. The results showed artificial neural networks could be successfully used in function approximation problems in order to approach the data generation function. Once data generation function is known, artificial neural network structure is tested using data not presented to the network during training.

Keywords: artificial neural networks, concrete, sulphate attack.

Lista de ilustrações

Figura 1 – Modelo Neuronal	15
Figura 2 – Gráfico da função sigmoïdal	16
Figura 3 – Diferença entre funções linearmente (A) e não linearmente separáveis (B) .	18
Figura 4 – Representação de um perceptron de múltiplas camadas	19
Figura 5 – Estrutura da RNA desenvolvida	29
Figura 6 – Resultados para UPV em 10% das épocas de treino	31
Figura 7 – Resultados para UPV em 40% das épocas de treino	32
Figura 8 – Resultados para UPV em 100% das épocas de treino	33
Figura 9 – Resultados para Resistência a compressão em 10% das épocas de treino .	34
Figura 10 – Resultados para Resistência a compressão em 40% das épocas de treino .	35
Figura 11 – Resultados para Resistência a compressão em 100% das épocas de treino .	36
Figura 12 – Resultados para Porosimetria de Mercúrio em 10% das épocas de treino . .	37
Figura 13 – Resultados para Porosimetria de Mercúrio em 40% das épocas de treino . .	38
Figura 14 – Resultados para Porosimetria de Mercúrio em 100% das épocas de treino .	39
Figura 15 – Relação entre a quantidade de erro pelas épocas de treino	40
Figura 16 – Relação entre a quantidade de erro pelas épocas de treino	41
Figura 17 – Relação entre a quantidade de erro pelas épocas de treino	41
Figura 18 – Época 3691: Melhor generalização	42
Figura 19 – Generalização no final das épocas	43
Figura 20 – Época 5979: Melhor generalização	44
Figura 21 – Generalização no final das épocas	45
Figura 22 – Época 6469: Melhor generalização	46
Figura 23 – Generalização no final das épocas	47

Lista de tabelas

Tabela 1 – Exemplo de normalização de dados	17
Tabela 2 – Compilado dos dados do trabalho de Costa (2004)	25
Tabela 3 – Estratificação dos agregados	26
Tabela 4 – Nova base com informações detalhadas	27
Tabela 5 – Base totalmente normalizada	27
Tabela 6 – Resultados para UPV em 10% das épocas de treino	30
Tabela 7 – Resultados para UPV em 40% das épocas de treino	31
Tabela 8 – Resultados para UPV em 100% das épocas de treino	32
Tabela 9 – Resultados para Resistência a compressão em 10% das épocas de treino	33
Tabela 10 – Resultados para Resistência a compressão em 40% das épocas de treino	34
Tabela 11 – Resultados para Resistência a compressão em 100% das épocas de treino	35
Tabela 12 – Resultados para Porosimetria de Mercúrio em 10% das épocas de treino	36
Tabela 13 – Resultados para Porosimetria de Mercúrio em 40% das épocas de treino	37
Tabela 14 – Resultados para Porosimetria de Mercúrio em 100% das épocas de treino	38
Tabela 15 – Época 3691: Melhor generalização	42
Tabela 16 – Generalização no final das épocas	43
Tabela 17 – Época 5979: Melhor generalização	44
Tabela 18 – Generalização no final das épocas	45
Tabela 19 – Época 6469: Melhor generalização	46
Tabela 20 – Generalização no final das épocas	47
Tabela 21 – Base de Dados iniciais	51
Tabela 22 – Base de Dados Detalhada	54
Tabela 23 – Base de Dados Normalizada	57
Tabela 24 – Relação entre valores reais e encontrados para <i>Ultrasonic Pulse Test</i>	60
Tabela 25 – Relação entre valores reais e encontrados para Resistência a compressão	62
Tabela 26 – Relação entre valores reais e encontrados para Porosimetria de Mercúrio	63

Sumário

1	INTRODUÇÃO	12
1.1	Justificativa	13
1.2	Objetivos	13
1.3	Estrutura do Texto	13
2	FUNDAMENTAÇÃO TEÓRICA	15
2.1	Neurônios Artificiais	15
2.1.1	Pesos sinápticos e somador	15
2.1.2	Somador	16
2.1.3	Função de ativação	16
2.1.4	Bias	17
2.2	Normalização	17
2.3	Redes Neurais artificiais	17
2.3.1	Perceptrons	18
2.3.2	Perceptrons de multicamadas	18
2.4	Aprendizagem de estruturas de redes neurais	19
2.4.1	Algoritmo de retropropagação	19
2.4.2	Avaliação do desempenho pela generalização	20
2.4.3	A estrutura da rede	21
2.5	O concreto	21
2.5.1	Definição de concreto	21
2.5.2	Materiais constituintes	21
2.5.2.1	Agregado	21
2.5.2.2	Cimento Portland	22
2.5.3	Caracterização do concreto	22
2.5.3.1	Ultrasonografia (<i>Ultrasonic Pulse Test</i> UPV)	22
2.5.3.2	Resistência a compressão	22
2.5.3.3	Porosimetria de mercúrio	23
2.5.3.4	Fluorescência de raios X	23
3	MÉTODO	24
4	MODELAGEM	25
4.1	Levantamento de dados	25
4.2	Modelagem dos dados	26
4.3	Modelagem da Rede Neural Artificial	28
4.3.1	A estrutura da Rede	28
5	RESULTADOS	30

5.1	Capacidade de especialização da RNA	30
5.1.1	<i>Ultrasonic Pulse Test</i>	30
5.1.2	Resistência a compressão	33
5.1.3	Porosimetria de Mercúrio	36
5.2	Capacidade de generalização da RNA	40
5.2.1	<i>Ultrasonic Pulse Test</i>	40
5.2.2	Resistência a compressão	41
5.2.3	Porosimetria de Mercúrio	41
5.3	Melhor generalização da RNA	42
5.3.1	<i>Ultrasonic Pulse Test</i>	42
5.3.2	Resistência a compressão	44
5.3.3	Porosimetria de Mercúrio	46
6	CONCLUSÃO	48
6.1	Trabalhos futuros	48
	REFERÊNCIAS	49
	ANEXO A – BASE DE DADOS INICIAL	51
	ANEXO B – BASE DE DADOS DETALHADA	54
	ANEXO C – BASE DE DADOS NORMALIZADA	57
	ANEXO D – RELAÇÃO ENTRE OS VALORES REAIS E OS VALORES EN- CONTRADOS POR QUANTIDADE DE ÉPOCAS DE TREINO	60
D.1	<i>Ultrasonic Pulse Test</i>	60
D.2	Resistência a compressão	62
D.3	Porosimetria de Mercúrio	63

1 Introdução

Um neurônio biológico tem a capacidade de coletar, processar e disseminar sinais elétricos. A distribuição desses neurônios em uma rede interligada gera a capacidade de processamento informações e consequentemente de aprendizagem.

O processo de aprendizagem dos neurônios biológicos se dá através de tentativa e erro, ou seja, através do treino. Uma ação executada várias vezes, tende a ser mais eficiente com o passar do tempo. Desde que se conheça o resultado esperado de uma ação, é possível comparar com o resultado obtido em uma tentativa, e a partir desse momento encontrar formas para se aproximar do resultado esperado. Uma rede neural artificial tem como objetivo simular essa característica biológica humana.

Redes neurais artificiais (RNA) são utilizadas como forma de simular comportamentos ou como aproximadores universais de funções em diversas áreas. Diversos trabalhos científicos fazem uso de RNA para solucionar problemas, tais como: Soares et al. (2014), faz uso de RNA para encontrar a estimativa de retenção de água do solo. O uso deste recurso como um aproximador universal de funções torna possível encontrar funções de pedotransferência (FTP), as quais descrevem equações que expressam dependências da retenção da água com elementos básicos disponíveis em levantamentos de solos. Os resultados encontrados foram classificados como “ótimos”; Morett et al. (2016), usam a capacidade de uma RNA em aprender com experiências passadas, para prever o módulo da elasticidade e a resistência a compressão de corpos-de-prova de concreto; Silva et al. (2009), usam RNA para estimar o volume de madeira de eucalipto em função do diâmetro a 1,30 m do solo (DAP), da altura total (Ht) e do clone. Concluíram que RNA apresentam boa adequação ao problema, sendo elas altamente recomendadas para realizar prognose da produção de florestas plantadas.

O conceito de Rede Neural Artificial (RNA) foi concebido em 1943 com o trabalho pioneiro de McCulloch e Pitts (1943), onde descrevem um cálculo lógico que unificava os estudos de neurofisiologia e da lógica matemática. Ainda em seu artigo, McCulloch e Pitts (1943) afirmam que uma Rede Neural Artificial realizaria, a princípio, a computação de qualquer função computável, desde que opere de forma síncrona e que suas conexões sinápticas sejam ajustadas de maneira correta. Sendo assim, qualquer tarefa, pode ser interpretada por uma RNA, desde que se conheça os dados de entrada, variantes que influenciam na execução da tarefa, e o resultado obtidos.

Existe a necessidade de estabelecer uma função que relaciona a composição de um concreto com sua degradação. Para que a aproximação de uma função, que liga o domínio (composição do concreto) e contradomínio (seu comportamento mecânico), é necessário utilizar uma base de dados. Este trabalho tem como ponto de partida o trabalho desenvolvido pelo Engenheiro Civil Rodrigo Moyses Costa, em defesa de sua tese apresentada ao Programa de Pós-Graduação em Engenharia de Estruturas da Escola de Engenharia da Universidade Federal de Minas Gerais, em 2004. No estudo em questão Rodrigo Moyses desenvolveu uma série

de ensaios, buscando analisar as propriedades mecânicas do concreto deteriorado pela ação de sulfato. Como um dos resultados, ele produziu uma base de dados onde está documentada essa relação. Em posse dos dados compilados deste trabalho, é possível utilizar RNA para modelar a função que relaciona a composição do concreto com as características mecânicas atribuídas a ele após a degradação.

1.1 Justificativa

O concreto é um dos materiais mais utilizados na era moderna em nosso país. Com o propósito de oferecer eficiência, economia, durabilidade e facilidade na execução de projetos, esse compósito é usado em diversos setores da construção civil, gerando uma relevante contribuição ao PIB brasileiro.

A importância econômica desse recurso motiva diversos estudos relacionados, direta e indiretamente, ao tema. Efetuar um estudo detalhado do processo de produção e aplicação do concreto facilitará a análise da viabilidade de um projeto de engenharia.

A maneira prática de efetuar a análise do comportamento de um concreto, aplicado em um ambiente específico, consome muitos recursos, como: o tempo necessário para fabricação, acompanhamento e medição dos resultados de corpos-de-provas submetidos a condições específicas. O uso de recursos computacionais possibilita uma maior variedade de simulações em menor tempo, tornando os estudos mais ágeis e mais controlados, contornando barreiras, imprevistos e falhas que possivelmente podem ocorrer nos testes práticos.

É nesse contexto que se enquadra esse trabalho. Fundamenta-se na necessidade de tornar as análises e os estudos mais ágeis através do uso de recursos computacionais. Dessa forma será possível fazer uma análise prévia da aplicação de um projeto de engenharia, considerando a viabilidade econômica e estrutural da aplicação do concreto nesse projeto.

1.2 Objetivos

Partindo dos princípios apresentados, é possível afirmar que uma rede neural deve ser capaz de aproximar de qualquer função computável. Este trabalho tem como objetivo treinar uma rede de neurônios artificiais através dos dados obtidos por Costa (2004). Os treinos devem torná-la capaz de modelar a função de degradação do concreto. O resultado deve ser um programa capaz de prever as características mecânicas de um corpo-de-prova de concreto degradado por sulfatos.

1.3 Estrutura do Texto

Este trabalho tem como objetivo encontrar a função que representa a degradação do concreto em relação ao tempo. O mesmo está estruturado em seis capítulos, que buscam organizar as informações relevantes ao estudo. O primeiro capítulo trata da apresentação do problema, motivação, relevância e objetivo. No segundo capítulo é apresentada toda bibliografia que fundamentam os assuntos relevantes para a compreensão desse trabalho. Nele são


apresentados conceitos sobre Redes Neurais Artificiais, uma noção básica sobre concreto e sobre os testes que geraram os dados usados como base neste estudo. No terceiro capítulo são apresentadas as etapas do procedimento usado para o desenvolvimento do trabalho. No capítulo 4 é apresentado toda modelagem envolvida neste trabalho. Nele está presente as técnicas usadas para aperfeiçoamento dos dados e modelagem da Rede Neural Artificial. O capítulo 5 é onde são apresentados os resultados encontrados. Para demonstrar a eficiência do uso de RNA para solução do problema, estes resultados são apresentados em forma de gráficos. No sexto capítulo, que finaliza este trabalho, está presente a conclusão da proposta e algumas ideias de projetos futuros a serem desenvolvidos a partir deste. Todos os dados amostrais, que geram os gráficos apresentados nos resultados, estão presentes na seção de apêndices.

2 Fundamentação Teórica

Nesta sessão serão abordados os conceitos fundamentais para a compreensão do método utilizado neste trabalho, onde serão apresentados aspectos gerais sobre: neurônios artificiais, rede de neurônios artificiais e a capacidade de aprendizagem dessas estruturas; os conceitos, composições e testes para medir a qualidade de um concreto.

2.1 Neurônios Artificiais

Em seu livro, Haykin (2001) define o modelo de neurônios como uma unidade de processamento de informação que é fundamental para a operação de rede neural. Através do diagrama em blocos da Figura 1 é possível identificar os elementos básicos do modelo neuronal:



Fonte: Adaptado de Haykin (2001)

2.1.1 Pesos sinápticos e somador

Um conjunto de sinapses ou elos de conexão são pesos associados a cada uma das partes de um estímulo. Um estímulo é uma amostra encontrada no domínio da função. Dado $\bar{x}$ como uma amostra, x_i como um de seus valores e m o número de valores ou componentes desta amostra, temos: $i = 1, 2, \dots, m$. Um peso sináptico que liga uma entrada x_i a um neurônio k é representado por w_{ki} . Em outras palavras, dada uma massa de entrada, cada x_i de uma amostra tem um peso sináptico relacionado, esses pesos vão ser posteriormente ajustados, visando encontrar o peso ideal para chegar ao resultado esperado.

2.1.2 Somador

Realiza o somatório de cada um dos sinais de entrada, x_i , ponderados pelos seus respectivos pesos sinápticos do neurônio. Essa operação constitui um combinador linear.


2.1.3 Função de ativação

Uma função de ativação, ou função restritiva, é usada para restringir a amplitude de saída de um neurônio. A função de ativação é projetada para atender a duas aspirações: Primeiramente a unidade deve ser “Ativa” (próxima de +1) quando as entradas “corretas” forem recebidas e “inativa” (próxima a 0) quando as entradas “erradas” forem recebidas; em segundo lugar a função de ativação precisa ser não-linear. Um exemplo de função de ativação é a função sigmoidal, representada pela Equação 2.1:

$$f(u) = \frac{1}{1 + e^{Bu}} \quad (2.1)$$

Ela produz resultados que estão compreendidos dentro do intervalo fechado $[0,1]$, como pode ser visto no gráfico a baixo:

Figura 2 – Gráfico da função sigmoidal



Fonte: Autor.

2.1.4 Bias

O bias é usado para controlar a entrada líquida da função de ativação. O bias b_k , tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente (HAYKIN, 2001).

Caso uma RNA seja utilizada para aproximar de uma reta dada pela Equação 2.2.

$$f(x) = ax + b \quad (2.2)$$

O termo b serve para dar liberdade à reta de se deslocar pelo eixo x para a direita e esquerda, saindo da origem. Este mesmo efeito deve ser modelado em uma RNA. O termo a é modelado pelos pesos sinápticos, x pelas entradas x_i e o termo b pelo bias.

2.2 Normalização

A normalização de dados é uma técnica utilizada no pré-processamento que tem por objetivo reorganizar os dados em uma faixa de valores adequada para a modelagem do problema. A técnica escolhida foi utilizar o princípio dos segmentos proporcionais (SILVA; FLAUZINO; SPATTI, 2010), onde o valor de cada variável (x) foi convertido em um valor na escala entre 0 e 1 (z). O cálculo é realizado de acordo com a Equação 2.3, onde, x_i^{min} representa o menor valor do conjunto i e x_i^{max} o maior valor desse mesmo conjunto i de informações.

$$N(x_{ki}) = \frac{x_{ki} - x_i^{min}}{x_i^{max} - x_i^{min}} \quad (2.3)$$

Como no exemplo abaixo, a base de dados na tabela 1 possui uma alta recomendação de normalização, pois deixará as colunas i com a mesma ordem de grandeza.

Tabela 1 – Exemplo de normalização de dados

Dados Originais			Dados Normalizados		
Indivíduo	Peso	Altura	Indivíduo	Peso	Altura
A	79	1,9	A	0,618181818	1
B	45	1,6	B	0	0
C	80	1,75	C	0,636363636	0,5
D	100	1,8	D	1	0,666666667

Fonte: Autor.

2.3 Redes Neurais artificiais


As redes neurais são formadas por camadas de Neurônios Artificiais interligados, com o objetivo de aumentar a capacidade de processamento e dessa forma resolver problemas mais complexos. “As redes neurais são compostas de nós ou unidades conectadas por vínculos orientados. Um vínculo de unidade j para a unidade i serve para propagar a ativação a desde j até i ” (RUSSELL; NORVIG, 2004).

2.3.1 Perceptrons

O perceptron, proposto por Rosenblatt (1958), é uma rede onde todas as entradas estão conectadas diretamente às saídas, também conhecido como uma rede neural de uma única camada. Trata-se de um simples neurônio usado para classificar suas entradas em uma de duas categorias, 0 ou 1, tomadas geralmente por convenção como falso e verdadeiro respectivamente.

Perceptrons são capazes de modelar apenas funções que sejam linearmente separáveis, figura 3. Segundo Coppin (2010), uma função linearmente separável é aquela que pode ser desenhada em um gráfico bidimensional e que os valores distintos, isto é, de categorias diferentes, podem ser separados por apenas uma reta.

Figura 3 – Diferença entre funções linearmente (A) e não linearmente separáveis (B)



Fonte: Adaptado de Coppin (2010)

2.3.2 Perceptrons de multicamadas


A maioria dos problemas do mundo real não é linearmente separável, então é preciso de algo com mais capacidade de processamento. Coppin (2010) afirma que Perceptrons multicamadas são capazes de modelar funções mais complexas, incluindo aquelas que não são linearmente separáveis.

A rede consiste de um conjunto de neurônios artificiais como os da Figura 1, unidades sensoriais, organizados em camadas de forma que essas camadas sejam interligadas, havendo comunicação entre elas. O sinal de entrada se propaga através da rede, camada por camada.

Redes neurais artificiais aprendem de forma semelhante aos perceptrons simples, porém o fato de haver várias camadas ocultas, ou seja, camadas que não estão diretamente ligadas à camada de saída, gera a necessidade de atualizar muito mais pesos quando um erro é cometido para um fragmento de dados de treinamento. Para lidar com isso, faz-se uso da técnica de retropropagação, ou seja, o erro encontrado na camada de saída é propagado

de forma calculada para as camadas ocultas que o antecedem. Após esse momento, com os pesos ajustados, inicia-se o próximo treino.

Figura 4 – Representação de um perceptron de múltiplas camadas



Fonte: Adaptada de Haykin (2001).

2.4 Aprendizagem de estruturas de redes neurais

A aprendizagem de uma RNA se dá através de treinos seguidos de reajustes nos pesos de cada camada, através da retropropagação, e do recomeço do ciclo.

2.4.1 Algoritmo de retropropagação

O processo de propagação de retorno do erro da camada de saída para as camadas ocultas emerge diretamente de uma derivação do gradiente de erro global. Cada iteração do algoritmo é finalizada pela alimentação de erros no sentido das saídas às entradas. Este processo é descrito abaixo em uma representação do algoritmo:

1. Inicialize W_i (pesos) com valores pequenos e randômicos.
2. Para cada par $[X, Y]$ (amostras da massa de treinamento) faça:
 - Execute o vetor X na RNA e encontre a saída $\underline{O}$.
 - Para cada neurônio da camada de saída calcule $\Delta w'_i$.

$$\Delta w'_i = O_i * (1 - O_i) * (y_i - O_i)$$

- Para cada neurônio da camada intermediária calcule Δw_i

$$\Delta W_h = H_h * (1 - H_h) * \sum \Delta W'_i * W'_{ih}$$

- Para cada w_i da camada intermediária recalcule.

$$W_{ih} = W_{ih} + \eta \Delta W_h * x_i$$

- Para cada w'_i da camada de saída recalcule.

$$W'_{ho} = W'_{hp} \eta \Delta W'_o * H_h$$

3. Até encontrar a condição de parada verdadeira.

2.4.2 Avaliação do desempenho pela generalização

Russell e Norvig (2004) consideram um algoritmo de aprendizagem bom quando ele produz hipóteses que fazem um bom trabalho ao prever as classificações de exemplos não treinados (generalização). Uma previsão é considerada boa se resulta verdadeira e assim torna-se possível qualificar a hipótese comparando suas previsões com a classificação correta, depois de conhecê-la. Ainda segundo Russell e Norvig (2004), com frequência é mais conveniente adotar a seguinte metodologia, para conseguir avaliar o desempenho do algoritmo:

1. Coletar um grande conjunto de exemplos.
2. Dividi-lo em dois conjuntos: o conjunto de treinamento e o conjunto de teste
3. Aplicar o algoritmo de aprendizagem ao conjunto de treinamento, gerando uma hipótese h .
4. Medir a porcentagem de exemplos no conjunto de teste que são corretamente classificados por h .
5. Repetir as etapas 1 e 4 para diferentes tamanhos de conjuntos de teste e diferentes conjuntos de treinamento de cada tamanho selecionado aleatoriamente.

O resultado desse procedimento é um conjunto de dados que pode ser processado e usado para medir a qualidade da previsão. Essa função pode ser representada em um gráfico, fornecendo a curva de aprendizagem do algoritmo.

Uma rede generaliza bem quando o resultado computado pela rede for correto, para dados de testes que não foram utilizados no treinamento da rede (HAYKIN, 2001), assumindo que os dados de teste sejam retirados de uma mesma população usada para gerar os dados de treinamento. Uma rede neural produzirá um mapeamento de entrada-saída correto, mesmo havendo diferenças entre as entradas usada para teste e as entradas usadas para treino. Entretanto quando uma rede neural aprende um número excessivo de exemplos, pode ocorrer a memorização dos dados de treinamento isso pode levar a RNA a perder a capacidade de generalização. A “memorização” é essencialmente uma “tabela de consulta”, o que implica que o mapeamento de entrada-saída computada pela rede neural não está preciso.

2.4.3 A estrutura da rede

Redes multicamadas completamente conectadas, ou seja, onde todos os nós de duas camadas se comunicam entre si, dão a liberdade de escolher o número de camadas ocultas e seus tamanhos. Com as variações possíveis de uma mesma rede, variações geradas pela liberdade de lidar com as camadas ocultas, é preciso entender como encontrar a melhor estrutura para determinado problema. Os autores Russell e Norvig (2004), alertam para o risco de uma rede muito grande se tornar capaz de memorizar todos os exemplos, se transformando em uma tabela de busca, que não irá necessariamente realizar boas generalizações para entradas que não foram vistas antes. A abordagem habitual é tentar várias combinações entre camadas e seus tamanhos e escolher a que trouxer melhor resultado.

2.5 O concreto

Este trabalho vai usar um recurso computacional para simular testes realizados de forma prática em corpos-de-provas de concreto. O concreto normalmente é feito com a mistura de cimento Portland, areia, brita e água. Para o uso de uma RNA é preciso ter uma massa de dados que vai servir como base da aprendizagem dos neurônios. Essa base é formada, em parte, pelos elementos que compoem um concreto, atuando como as entradas para a RNA. As informações usadas para alimentar a Rede referente ao concreto estão descritas a seguir:

2.5.1 Definição de concreto

Segundo Tolentino (2017), a definição de concreto é: um produto monolítico resultante da mistura de agregado graúdo, agregado miúdo e aglomerante. **Mono** (do grego “monos”) é um designativo de unidade; **lito** (do grego “lithos”) significa pedra. O termo monólito significa pedra única, ou que consta de uma única pedra. Já o termo monolítico significa relativo a monólito; semelhante a um monólito; que se comporta como um conjunto rígido, indivisível.

2.5.2 Materiais constituintes

2.5.2.1 Agregado

Os agregados podem ser definidos como materiais granulosos e inertes (que não sofrem transformação química), com dimensões e propriedades variáveis, que podem ser selecionados adequadamente à obra de engenharia que se pretende executar. Os agregados em geral devem ser formados por partículas duras e resistentes, isentas de produtos nocivos, tais como sais, matéria orgânica, material pulverulento, etc. (TOLENTINO, 2017).

A norma NBR 7211 da Associação Brasileira de Normas Técnicas (2005) define:

- Agregado Miúdos: Agregados cujos grãos passam na peneira com abertura de malha de 4,75 mm e ficam retidos na peneira com abertura de malha de 0,15 mm (150 μm). Ex.: areia natural, areia artificial, etc.

- Agregados Graúdos: Agregados cujos grãos passam na peneira com abertura de malha de 75 mm e ficam retidos na peneira com abertura de malha de 4,75 mm. Ex.: brita, seixo rolado, etc.

Segundo Bauer (1994), os agregados constituem cerca de 70% da composição de um concreto e pode ser definidos como materiais granulosos e inertes, ou seja, que não reagem com outro material usado na composição do concreto.

2.5.2.2 Cimento Portland

O cimento Portland é um pó na tonalidade cinza, composto de partículas angulares de tamanho entre 1-50 μm e que é constituído essencialmente de silicatos hidráulicos de cálcio (provenientes da moagem do clínquer), com certa proporção de sulfato de cálcio natural (adicionado ao clínquer moído), podendo conter, eventualmente, adições de outros materiais que modificam suas propriedades ou facilitam seu emprego (tais como escória de alto-forno, materiais pozzolânicos, etc.). Por sua vez o clínquer é um produto de natureza granulosa, composto por nódulos de 5-25 mm de diâmetro, e que é resultante da calcinação de uma mistura de matéria-prima adequada, conduzida até a temperatura de sinterização (TOLENTINO, 2017).

2.5.3 Caracterização do concreto

Atuando como as saídas esperadas estão os resultados dos testes realizados para medir a qualidade mecânica deste concreto, descritos a seguir:

2.5.3.1 Ultrasonografia (*Ultrasonic Pulse Test* UPV)

O ensaio não destrutivo de UPV tem como objetivo monitorar e diagnosticar as condições físicas estruturais, almejando conservar o estado de vida útil das estruturas (COSTA, 2004). O teste encontra a velocidade de propagação de uma onda ultrasonica através do corpo-de-prova, de forma a indicar a sanidade do mesmo.

Segundo Bauer (1982), por se tratar de testes não destrutivos, apresentam largas possibilidades de aplicação no estudo da patologia do concreto e no controle corrente de sua qualidade. Bauer (1982) afirma ainda que essa técnica pode ser útil na verificação de falhas de concretagem, de trincas ou fissuras e da resistência de concreto, como uma verificação adicional de controle de estruturas já prontas.

2.5.3.2 Resistência a compressão

Mehta e Monteiro (1994) afirmam que a resistência de um material é definida como a capacidade de este resistir à tensão sem ruptura. O teste de resistência a compressão é um teste destrutível, que busca encontrar o valor máximo que um corpo-de-prova resiste antes da ruptura.

Geralmente, a resistência à compressão simples é medida em corpos-de-prova cilíndricos padronizados, de 15 cm de diâmetro por 30 cm de altura ou de 10 cm de diâmetro por 20 cm de altura, curados em câmara úmida e ensaiados na idade de 28 dias. O carregamento de

ensaio deve ser aplicado continuamente e sem choques, com a velocidade de carregamento de $(0,45 \pm 0,15)$ MPa/s. A velocidade de carregamento deve se mantida constante durante todo o ensaio (TOLENTINO, 2017).

2.5.3.3 Porosimetria de mercúrio

O procedimento de ensaio consiste em colocar a amostra seca em estufa num recipiente chamado de penetrômetro, sendo ambos preenchidos com mercúrio. Ao se aumentar a pressão sobre o líquido, seu nível é reduzido à medida que este penetra nos poros da amostra. Com os valores do volume de poros penetrado pelo mercúrio e com a respectiva pressão aplicada, uma curva porosimétrica é obtida (MASCARENHA et al., 2008).

O teste consiste em submeter pequenas amostras do corpo-de-prova imersas em mercúrio, a alta pressão. Dessa forma será possível encontrar um valor absoluto que vai referenciar o grau de porosidade do material.

2.5.3.4 Fluorescência de raios X

A espectrometria de fluorescência de raios X é uma técnica não destrutiva que permite identificar os elementos presentes em uma amostra. Este procedimento consiste em uma fonte de radiação que provoca a excitação dos átomos da substância que pretende analisar. Na natureza tudo tende a buscar o estado de estabilidade, dessa forma o átomo excitado tende a retornar ao seu estado fundamental, o que resulta em uma emissão de energia. Esta energia é específica de cada elemento químico, o que permite sua identificação (BECKHOFF et al., 2006).

3 Método

Para organizar o desenvolvimento deste trabalho, foi usado um método no qual foi estabelecido uma sequência de etapas. As etapas englobaram desde a análise do problema e levantamento bibliográfico, até a análise dos resultados. Os principais passos usados como base para este trabalho estão descritos a seguir:

1. O levantamento bibliográfico partiu do estudo realizado por Costa (2004), em defesa de sua tese apresentada ao Programa de Pós-Graduação em Engenharia de Estruturas da Escola de Engenharia da Universidade Federal de Minas Gerais, em 2004. O problema consiste em avaliar a qualidade de diferentes composições de concreto por meio de Redes Neurais Artificiais (RNA). Em seguida verificou-se na literatura a viabilidade do uso de RNA para resolver problemas não lineares.
2. Considerou-se os compostos químicos comuns de cada agregado. Esses dados são provenientes de um ensaio chamado fluorescência de raio x. Dessa forma foi possível aprofundar os estudos da relação entre os agregados e a resistência do concreto. Foi gerada uma nova base mais detalhada, refinando a qualidade dos dados.
3. Foram compilados os dados presentes no trabalho de Costa (2004). Essa massa de dados foi organizada para formar uma base, que tornasse possível a leitura e interpretação pela RNA.
4. Uniu-se os dados presentes no trabalho de Costa (2004) com os dados estratificados dos agregados.
5. Para se adequar a algumas características específicas do algoritmo de RNA, foi necessário fazer adaptações nos dados. A base foi totalmente normalizada, através da Equação ??, com intuito de otimizar a resposta da RNA.
6. Com a base formada foi possível desenvolver uma RNA completamente conectada. Para encontrar a melhor estrutura da rede possível, foi usada a abordagem habitual para esse tipo, que é tentar várias estruturas e ficar com a que gerar melhores resultados (RUSSELL; NORVIG, 2004).
7. Para confirmar a eficiência do uso de RNA para a solução do problema, os resultados colhidos foram tabelados e apresentados em forma de gráficos. A princípio verificou-se a capacidade de encontrar resultados próximos aos reais e previamente conhecidos. Na sequência a rede foi usada para classificar a base de teste e verificar sua generalização.

4 Modelagem

Neste capítulo serão apresentados os procedimentos realizados para modelagem dos dados e da Rede Neural Artificial.

4.1 Levantamento de dados

Fez-se um compilado das informações apresentadas no trabalho de Costa (2004) que gerou uma base que correlaciona todas as informações de composição e resultados dos testes. O resultado desse levantamento gerou uma tabela com 54 amostras, cada uma delas é caracterizada por 9 dados distintos de entrada (domínio) e ainda por 3 informações de saída (contradomínio). Essas informações são apresentadas na Tabela 2, :

Tabela 2 – Compilado dos dados do trabalho de Costa (2004)

Resist. Ideal	Agregado			Cimento			Sol.	Dias	Saídas		
	CC	CD	GN	CPII	CPIII	PCIV			UPV (μs)	RC (MPa)	PM (nm)
20	1	0	0	1	0	0	0	90	19,81	27,25	18,4
20	1	0	0	1	0	0	10	28	20,39	23,5	28,1
20	1	0	0	1	0	0	50	180	22,29	20	37
...	...	...	...	...	...	...	...	...	...	...	...
50	0	0	1	0	0	1	0	90	19,33	51,75	24,3
50	0	0	1	0	0	1	10	28	22,41	52,75	24,1
50	0	0	1	0	0	1	50	180	20,24	62,5	28,3

Fonte: Costa (2004), tabela completa presente no Anexo A

Onde:

- C.C.: Agregado de Calcário Calcítico
- C.D.: Agregado de Calcário Dolomítico
- G.N.: Agregado de Gnaísse
- CPII: Cimento Portland CPII
- CPIII: Cimento Portland CPIII
- PCIV: Cimento Portland PCIV
- Sol: O estudo de Costa (2004), visou mensurar e analisar a degradação causada no concreto pela exposição ao sulfato de magnésio por longos períodos. Devido a indisponibilidade de tempo, para simular o passar dos anos, a forma usada foi submeter os

corpos-de-prova à uma solução concentrada desse composto. A representação numérica dessa concentração foi previamente estabelecida e controlada para não alterar os resultados.

- UPV: *Ultrasonic Pulse Test* para medição da porosidade interna
- RC: Resistência a compressão
- PM: Porosimetria de Mercúrio para medição da porosidade conectada com o exterior)

Nota-se que a ausência e a presença de determinados compostos obedecem uma distribuição binária, onde o número um (1) indica que a formação apresenta esse composto e o número zero (0) indica o contrário

4.2 Modelagem dos dados

Para aprofundar o estudo da relação entre os agregados e a resistência à degradação, optou-se por considerar a estratificação de cada agregado em seus compostos comuns. Esses valores foram encontrados pelos trabalhos: Souza e Bragança (2013), Silva e Silva (2010) e Vieira, Monteiro e Peiter (2008). Os autores utilizaram a técnica de Fluorescência de raios X. Essa estratificação gerou os seguintes resultados apresentados na Tabela 3:

Tabela 3 – Estratificação dos agregados

Tipo de Agregado	Al₂O₃	CaO	Fe₂O₃	K₂O	MgO	P₂O₅	SiO₂	TiO₂
Calcário Dolomítico	1,3%	33,72%	0,59%	0,32%	9,5%	0,02%	11,17%	0,04%
Calcário Calcítico	1,24%	50,18%	0,51%	0,33%	0,72%	0,03%	3,80%	0,05%
Gnaisse	14,76%	2,08%	4,18%	5,47%	0,73%	0,30%	67,83%	0,71%

Fonte: Compilado de Souza e Bragança (2013), Silva e Silva (2010) e Vieira, Monteiro e Peiter (2008)

Ao inserir as informações estratificadas da Tabela 3 na Tabela 2 foi construída uma nova base. Nesse momento é possível identificar a presença de determinado agregado através de sua composição, como pode ser visto na Tabela 4:

Tabela 4 – Nova base com informações detalhadas

		Amostras				
Resistencia ideal	20 ou 50	20	20	20	...	50
Agregado	Al ₂ O ₃	1,24	1,24	1,24	...	14,76
	CaO	50,18	50,18	50,18	...	2,08
	Fe ₂ O ₃	0,51	0,51	0,51	...	4,18
	K ₂ O	0,33	0,33	0,33	...	5,47
	MgO	0,72	0,72	0,72	...	0,73
	P ₂ O ₅	0,03	0,03	0,03	...	0,30
	SiO ₂	3,80	3,80	3,80	...	67,83
	TiO ₂	0,05	0,05	0,05	...	0,71
Cimento	CPII	1	1	1	...	0
	CPIII	0	0	0	...	0
	PCIV	0	0	0	...	1
Solução	0, 10 ou 50	0	10	50	...	50
Qtd Dias	28, 90 ou 180	90	28	180	...	180
Saidas	UPV	19,81	20,39	22,29	...	20,24
	RC	27,25	23,5	20	...	62,5
	PM	18,4	28,1	37	...	28,3

Fonte: Autor, tabela completa presente no Anexo B

Para se ajustar à função de ativação, mostrou-se interessante normalizar a base de dados, para que todos os valores que influenciam nos resultados estejam dentro do mesmo intervalo. Para essa transformação foi aplicada a Equação 2.3 , gerando dessa maneira a Tabela 5:

Tabela 5 – Base totalmente normalizada

		Amostras				
Resistencia ideal	20 ou 50	0	0	0	...	1
Agregado	Al ₂ O ₃	0	0	0	...	1
	CaO	1	1	1	...	0
	Fe ₂ O ₃	0	0	0	...	1
	K ₂ O	0,002	0,002	0,002	...	1
	MgO	0	0	0	...	0,001
	P ₂ O ₅	0,036	0,036	0,036	...	1
	SiO ₂	0	0	0	...	1
	TiO ₂	0,015	0,015	0,015	...	1
Cimento	CPII	1	1	1	...	0
	CPIII	0	0	0	...	0
	PCIV	0	0	0	...	1
Solução	0, 10 ou 50	0	0,2	1	...	1
Qtd Dias	28, 90 ou 180	0,408	0	1	...	1
Saidas	UPV	0,470	0,573	0,910	...	0,546
	RC	0,161	0,078	0	...	0,944
	PM	0,082	0,287	0,475	...	0,291

Fonte: Autor, tabela completa presente no Anexo C

Ao fim da modelagem a base resultante foi formada por 54 amostras onde cada uma delas possui informações referentes a sua formação, 14 dados distintos, e aos 3 testes realizados. Por se tratar de tabelas com muitas informações, estas não puderam ser apresentadas por completo neste momento. As tabelas completas estão presentes nos Anexos.


4.3 Modelagem da Rede Neural Artificial

Definida a base, a RNA pôde ser construída. Optou-se por um Perceptron de múltiplas camadas por este tratar tanto problemas linearmente separáveis como não linearmente separáveis. Cada camada pode criar combinações de retas de maneira que crie uma região convexa. Uma camada cria uma região convexa dentro de outra região, também convexa, criada pela camada anterior (BRAGA; CARVALHO; LUDERMIR, 2007).

4.3.1 A estrutura da Rede

A RNA foi desenvolvida de forma completamente conectada, ou seja, todos os neurônios de uma camada se comunicam com todos da camada seguinte. Redes completamente conectadas limitam as configurações de suas estruturas a variações relacionadas ao número de camadas ocultas e seus tamanhos. A abordagem habitual é tentar várias configurações e escolher aquela que traz melhor resultado (RUSSELL; NORVIG, 2004). Baseado nisso a estrutura escolhida segue a seguinte distribuição: uma camada de entrada com 14 neurônios, que é o número de informações que caracterizam uma amostra; uma camada intermediária (oculta) que possui 8 neurônios. A escolha dessa quantidade de neurônios se deu através de uma convenção que sugere o uso do valor proveniente do resultado da soma dos neurônios da camada de entrada (14) com os da camada de saída (1), dividido por 2, encontrando o valor aproximado de 8; seguido por uma camada de saída, com apenas um neurônio. Esta estrutura está representada na Figura 5.

Figura 5 – Estrutura da RNA desenvolvida



Fonte: Adaptada de Haykin (2001).

Para tratar o problema em questão, optou-se por considerar as saídas individualmente. Foram criadas três RNA's diferentes, cada uma consideraria um tipo de saída: UPV, Resistência a compressão e Porosimetria de mercúrio. Dessa forma os ajustes e erros de uma saída não vão interferir em outra.

A função de ativação usada é uma função sigmoideal, Equação 2.1, que comprime os resultados de um treino entre zero e um. O resultado de cada treino é comparado com o resultado esperado e baseado na possível diferença entre esses valores, em seguida é aplicado o algoritmo de retropropagação, ajustando os valores dos pesos sinápticos.

Após seguidos treinos, é possível avaliar o poder de generalização da RNA. Uma rede treinada e com bom grau de generalização é capaz simular os testes para valores ainda não usados nos treinos e prever seu comportamento.

5 Resultados

Após a devida estruturação do algoritmo da RNA, passou-se para a validação experimental. Para isso verificou-se após os treinos a capacidade de generalização do algoritmo. A forma usada para visualizar essa característica foi gerar gráficos onde é possível identificar a aprendizagem com o passar das épocas de treino. Para testar a qualidade do concreto, foram colhidos resultados de três testes distintos, *Ultrasonic Pulse Test*, Resistência a Compressão e Porosimetria de Mercúrio, dessa forma, foram planejadas três RNA's, para cada um destas saídas da base de dados.

Existem valores reais de saídas e valores obtidos pela rede depois de ter sido treinada. O objetivo nas próximas três sub-sessões é mostrar a diferença entre estes dois valores e com isso demonstrar o quanto a RNA projetada está aproximando da função geradora dos dados.

Os gráficos a seguir foram gerados ao fim de cento e cinquenta mil épocas de treinos, considerando toda a massa de dados, de forma ordenada, simultaneamente para treino e para teste. A relação entre os valores reais e os valores encontrados é representada nas tabelas que antecedem os gráficos, porém as tabelas completas podem ser encontradas nos anexos deste trabalho.

5.1 Capacidade de especialização da RNA


5.1.1 *Ultrasonic Pulse Test*

Tabela 6 – Resultados para UPV em 10% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,062069948
2	0,028368794	2	0,071409116
3	0,093971631	3	0,078158603
4	0,120567376	4	0,078641463
5	0,138297872	5	0,171853407
6	0,161347518	6	0,150975828
7	0,184397163	7	0,155027261
8	0,184397163	8	0,202045002
9	0,19858156	9	0,176169835
10	0,207446809	10	0,231965257
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 6 – Resultados para UPV em 10% das épocas de treino




Fonte: Autor.

Tabela 7 – Resultados para UPV em 40% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,033874895
2	0,028368794	2	0,048895523
3	0,093971631	3	0,049291251
4	0,120567376	4	0,109945975
5	0,138297872	5	0,143571146
6	0,161347518	6	0,16329417
7	0,184397163	7	0,192230274
8	0,184397163	8	0,181457021
9	0,19858156	9	0,170146343
10	0,207446809	10	0,206437103
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 7 – Resultados para UPV em 40% das épocas de treino




Fonte: Autor.

Tabela 8 – Resultados para UPV em 100% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,026632982
2	0,028368794	2	0,040928003
3	0,093971631	3	0,057084337
4	0,120567376	4	0,111011975
5	0,138297872	5	0,139853947
6	0,161347518	6	0,164499332
7	0,184397163	7	0,185248118
8	0,184397163	8	0,18320111
9	0,19858156	9	0,192719283
10	0,207446809	10	0,210899829
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 8 – Resultados para UPV em 100% das épocas de treino



Fonte: Autor.


5.1.2 Resistência a compressão

Tabela 9 – Resultados para Resistência a compressão em 10% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,066653388
2	0,005555556	2	0,066151843
3	0,022222222	3	0,15311718
4	0,033333333	4	0,094022448
5	0,038888889	5	0,049374048
6	0,044444444	6	0,040889678
7	0,061111111	7	0,057152417
8	0,077777778	8	0,101495924
9	0,077777778	9	0,091284885
10	0,077777778	10	0,138492491
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 9 – Resultados para Resistência a compressão em 10% das épocas de treino




Fonte: Autor.

Tabela 10 – Resultados para Resistência a compressão em 40% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,015486171
2	0,005555556	2	0,061904878
3	0,022222222	3	0,10091945
4	0,033333333	4	0,068920307
5	0,038888889	5	0,053445887
6	0,044444444	6	0,022117851
7	0,061111111	7	0,07926997
8	0,077777778	8	0,087016
9	0,077777778	9	0,086319248
10	0,077777778	10	0,06199274
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 10 – Resultados para Resistência a compressão em 40% das épocas de treino




Fonte: Autor.

Tabela 11 – Resultados para Resistência a compressão em 100% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,007303936
2	0,005555556	2	0,033385729
3	0,022222222	3	0,044859297
4	0,033333333	4	0,058613773
5	0,038888889	5	0,040000221
6	0,044444444	6	0,001164626
7	0,061111111	7	0,055520015
8	0,077777778	8	0,094654237
9	0,077777778	9	0,061047056
10	0,077777778	10	0,083967638
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 11 – Resultados para Resistência a compressão em 100% das épocas de treino



Fonte: Autor.


5.1.3 Porosimetria de Mercúrio

Tabela 12 – Resultados para Porosimetria de Mercúrio em 10% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,053458086
2	0,025316456	2	0,072225981
3	0,033755274	3	0,044998551
4	0,056962025	4	0,04691959
5	0,075949367	5	0,016744063
6	0,082278481	6	0,112298448
7	0,08649789	7	0,016089528
8	0,088607595	8	0,146691831
9	0,116033755	9	0,129364294
10	0,116033755	10	0,09850308
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 12 – Resultados para Porosimetria de Mercúrio em 10% das épocas de treino




Fonte: Autor.

Tabela 13 – Resultados para Porosimetria de Mercúrio em 40% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,029172368
2	0,025316456	2	0,037021633
3	0,033755274	3	0,034856196
4	0,056962025	4	0,075225321
5	0,075949367	5	0,05875212
6	0,082278481	6	0,113951361
7	0,08649789	7	0,084816487
8	0,088607595	8	0,122085026
9	0,116033755	9	0,131023933
10	0,116033755	10	0,149623512
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 13 – Resultados para Porosimetria de Mercúrio em 40% das épocas de treino




Fonte: Autor.

Tabela 14 – Resultados para Porosimetria de Mercúrio em 100% das épocas de treino

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0	1	0,019761478
2	0,025316456	2	0,022151014
3	0,033755274	3	0,027412272
4	0,056962025	4	0,057003035
5	0,075949367	5	0,079936591
6	0,082278481	6	0,085490054
7	0,08649789	7	0,084890833
8	0,088607595	8	0,100087633
9	0,116033755	9	0,121727209
10	0,116033755	10	0,13807696
...	...	...	...

Fonte: Autor, tabelas completas presente no Anexo D.

Figura 14 – Resultados para Porosimetria de Mercúrio em 100% das épocas de treino



Fonte: Autor.

Comprovada a tendência de aproximação da RNA, pôde-se notar uma tendência de que a rede está se tornando especialista, ou seja, se tornando capaz de encontrar os resultados esperados.


Os gráficos a seguir foram gerados após retirar oito amostras aleatoriamente da base de treino e usá-las para os testes. Neles são apresentadas a relação entre a quantidade de épocas e a quantidade de erro encontradas nas fazes de treinos e testes. A quantidade de erro é a soma das diferenças entre o valor real e o valor encontrado para cada uma das amostras. Observa-se que com o passar das épocas de treino a tendência é estabilizar a aprendizagem, passando por um momento onde a generalização é considerada a melhor possível, isto é, onde a quantidade de erro é menor.

A dimensão das tabelas inviabiliza a sua apresentação, pois estaríamos apresentando uma tabela de cento e cinquenta mil linhas.

5.2 Capacidade de generalização da RNA

5.2.1 Ultrasonic Pulse Test


Figura 15 – Relação entre a quantidade de erro pelas épocas de treino



Fonte: Autor.

5.2.2 Resistência a compressão


Figura 16 – Relação entre a quantidade de erro pelas épocas de treino



Fonte: Autor.

5.2.3 Porosimetria de Mercúrio

Figura 17 – Relação entre a quantidade de erro pelas épocas de treino



Fonte: Autor.

Os gráficos seguintes apresentam em qual época de treino ocorre a melhor generalização, seguido por um gráfico onde é possível observar a generalização ao fim das épocas de treino. A relação entre a amostra e os valores é representada nas tabelas que antecedem os gráficos.

5.3 Melhor generalização da RNA


5.3.1 Ultrasonic Pulse Test

Tabela 15 – Época 3691: Melhor generalização

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0,666666667	1	0,666719113
2	0,432624113	2	0,515444793
3	0,895390071	3	0,870428874
4	0,184397163	4	0,276106547
5	0,276595745	5	0,383033374
6	0,413120567	6	0,281045006
7	0,930851064	7	0,552255388
8	0,934397163	8	0,584752314

Fonte: Autor.

Figura 18 – Época 3691: Melhor generalização




Fonte: Autor.

Tabela 16 – Generalização no final das épocas

Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor
1	0,666667	1	0,766578537
2	0,432624	2	0,94875394
3	0,89539	3	0,985130163
4	0,184397	4	0,192466658
5	0,276596	5	0,754167936
6	0,413121	6	0,867538401
7	0,930851	7	0,934135672
8	0,934397	8	0,85281996

Fonte: Autor.

Figura 19 – Generalização no final das épocas



Fonte: Autor.


5.3.2 Resistência a compressão

Tabela 17 – Época 5979: Melhor generalização

Valor Real		Valor Real	
Amostra	Valor	Amostra	Valor
1	0,666666667	1	0,719230462
2	0,432624113	2	0,511071204
3	0,895390071	3	0,936327601
4	0,184397163	4	0,228607598
5	0,276595745	5	0,275733122
6	0,413120567	6	0,218374604
7	0,930851064	7	0,518536611
8	0,934397163	8	0,69156006

Fonte: Autor.

Figura 20 – Época 5979: Melhor generalização




Fonte: Autor.

Tabela 18 – Generalização no final das épocas

Valor Real		Valor Real	
Amostra	Valor	Amostra	Valor
1	0,666667	1	0,933074184
2	0,432624	2	0,932936955
3	0,89539	3	0,991643351
4	0,184397	4	0,204395895
5	0,276596	5	0,209106425
6	0,413121	6	0,534450588
7	0,930851	7	0,364020969
8	0,934397	8	0,920674756

Fonte: Autor.

Figura 21 – Generalização no final das épocas



Fonte: Autor.


5.3.3 Porosimetria de Mercúrio

Tabela 19 – Época 6469: Melhor generalização

Valor Real		Valor Real	
Amostra	Valor	Amostra	Valor
1	0,666666667	1	0,712627047
2	0,432624113	2	0,490938997
3	0,895390071	3	0,911855668
4	0,184397163	4	0,201816939
5	0,276595745	5	0,252778105
6	0,413120567	6	0,155314984
7	0,930851064	7	0,448046916
8	0,934397163	8	0,64921212

Fonte: Autor.

Figura 22 – Época 6469: Melhor generalização




Fonte: Autor.

Tabela 20 – Generalização no final das épocas

Valor Real		Valor Real	
Amostra	Valor	Amostra	Valor
1	0,666667	1	0,576083082
2	0,432624	2	0,746761477
3	0,89539	3	0,985390255
4	0,184397	4	0,040029647
5	0,276596	5	0,146170985
6	0,413121	6	0,088919932
7	0,930851	7	0,204538677
8	0,934397	8	0,728328016

Fonte: Autor.

Figura 23 – Generalização no final das épocas



Fonte: Autor.

Nota-se que não necessariamente a melhor generalização ocorre ao fim das épocas.

6 Conclusão

A modelagem da função de degradação do concreto, feita neste trabalho, utilizou Redes Neurais Artificiais (RNA). Como não há na literatura, pelo menos do conhecimento dos envolvidos neste trabalho, um estudo que utiliza Redes Neurais Artificiais para simular e gerar resultados aproximados dos testes práticos da degradação do concreto, não cabe aqui uma comparação com trabalhos anteriores. Se comparado com o método habitual, que envolve todo processo de produção, teste e análise, o algoritmo apresentou resultados extremamente satisfatórios em relação ao tempo de execução e à proximidade entre os valores encontrados e os esperados. O uso de ferramentas computacionais fornece uma maneira de criar simulações rápidas e eficientes. Ao fim do processo de aprendizagem, a RNA pôde ser usada como uma função que gera resultados similares aos encontrados de maneira prática. Apesar dos nossos estudos terem utilizado uma base de dados com poucas amostras, porém proveniente de uma experimento real, a maneira como o algoritmo modela a função de degradação do concreto, abre precedentes que justificam o uso do mesmo em trabalhos futuros. Pode-se concluir que o algoritmo implementado é capaz de simular computacionalmente os testes realizados no trabalho de Costa (2004). Conhecendo as composições usadas na fabricação do concreto, a RNA é capaz de retornar os resultados referentes aos testes de UPV, de Resistência a Compressão e Porosimetria de Mercúrio suficientemente próximos dos reais.

6.1 Trabalhos futuros

Algumas indicações de continuidade ou implementação não abordadas neste trabalho são apresentadas a seguir:

- Criar uma interface com o usuário, para tornar o uso prático da ferramenta mais intuitivo.
- Variar o número de camadas ocultas, monitorando uma possível melhora na convergência da RNA.
- Ampliar o intervalo de normalização da base de dados.
- Trabalhar com os coeficientes de aprendizado dinâmicos, coeficientes distintos por neurônio.
- Treinar mais as amostras que apresentam maiores erros.
- Acrescentar os óxidos não comuns aos agregados, ampliando dessa maneira a base de informações usadas nos treinos.
- Dada a modelagem da degradação do concreto, feita pela RNA, verificar a viabilidade do uso de Algoritmos Genéticos para otimizar o concreto para uma saída desejada.

Referências

- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *Agregados para concreto: NBR 7211, Rio de Janeiro*. [S.l.], 2005. Citado na página 21.
- BAUER, L. A. F. *Materiais de construção*. 1. ed. Rio de Janeiro: LTC, 1982. Citado na página 22.
- BAUER, L. A. F. *Materiais de construção*. 5. ed. Rio de Janeiro: LTC, 1994. Citado na página 22.
- BECKHOFF, B. et al. *Handbook of Practical X-Ray Fluorescence Analysis*. 1. ed. Berlin-London: Springer, 2006. Citado na página 23.
- BRAGA, A. de P.; CARVALHO, A. C. P. de Leon Ferreira de; LUDERMIR, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*. 2. ed. Rio de Janeiro: LTC, 2007. Citado na página 28.
- COPPIN, B. *Inteligência Artificial*. 1. ed. Rio de Janeiro: LTC, 2010. Citado na página 18.
- COSTA, R. M. Análise de propriedades mecânicas do concreto deteriorado pela ação de sulfato mediante utilização do upv. 2004. Disponível em: <<http://www.bibliotecadigital.ufmg.br/dspace/handle/1843/PASA-89RGTR>>. Citado nas páginas 9, 13, 22, 24 e 25.
- HAYKIN, S. S. *Redes Neurais: Principio e Prática*. 2. ed. Porto Alegre: Bookman, 2001. Citado nas páginas 15, 17, 19, 20 e 29.
- MASCARENHA, M. M. dos A. et al. Conference report, *Utilização da Porosimetria por Injeção de Mercúrio (MIP) na determinação de curvas características em solos deformáveis*. 2008. Disponível em: <<http://hdl.handle.net/2117/9939>>. Citado na página 23.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943. Citado na página 12.
- MEHTA, P. K.; MONTEIRO, P. J. M. *Concreto: Estrutura, propriedades e materiais*. 1. ed. São Paulo: Pini, 1994. Citado na página 22.
- MORETT, J. F. et al. Prediction of modulus of elasticity and compressive strength of concrete specimens by means of artificial neural networks. In: *Acta Scientiarum. Technology, January-March 2016, Vol.38, pp.65-70*. [S.l.: s.n.], 2016. p. 65–70. Citado na página 12.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, p. 386–408, 1958. Citado na página 18.
- RUSSELL, S.; NORVIG, P. *Inteligência Artificial*. 2. ed. Rio de Janeiro: Elsevier, 2004. Citado nas páginas 17, 20, 21, 24 e 28.
- SILVA, I. N. da; FLAUZINO, R. A.; SPATTI, D. H. *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas*. 1. ed. São Paulo: Artliber, 2010. Citado na página 17.
- SILVA, M. L. M. da et al. Ajuste do modelo de schumacher e hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. In: *Rev. Árvore vol.33 no.6 Viçosa Nov./Dec. 2009*. [S.l.: s.n.], 2009. Citado na página 12.

SILVA, N. S. da; SILVA, M. L. da. Prospecção e análise técnica da jazida de calcário renaux com o objetivo de desenvolver calcita 200 para aplicação em massas de monoporosa. *Cerâmica Industrial*, v. 15, p. 39–42, 2010. Citado na página 26.

SOARES, F. C. et al. Redes neurais artificiais na estimativa da retenção de água do solo. In: *Ciência Rural*, February 2014, Vol.44(2), pp.293-300. [S.l.: s.n.], 2014. p. 293–300. Citado na página 12.

SOUZA, F. de; BRAGANÇA, S. R. Caracterização tecnológica de um calcário dolomítico in natura, calcinado e sulfatado como meio dessulfurante. *Cerâmica*, v. 59, n. 350, p. 331–337, 2013. Citado na página 26.

TOLENTINO, E. Materiais de Construção, *Notas de aula*. 2017. Citado nas páginas 21, 22 e 23.

VIEIRA, C. M. F.; MONTEIRO, S. N.; PEITER, C. C. Substituição de areia de quartzo por finos de gnaiss em massa cerâmica para telhas: teste industrial. *Cerâmica*, v. 54, n. 332, p. 480–486, 2008. Citado na página 26.

ANEXO A – BASE DE DADOS INICIAL

Tabela 21 – Base de Dados iniciais

Resist. Ideal	Agregado				Cimento			Solução	Qtd Dias	Saídas		
	CC	CD	GN	CPII	CPIII	PCIV	0 , 10 ou 50			28, 90 ou 180	UPV	RC
20 ou 50	1	0	0	1	0	0	0	0	90	19,81	27,25	18,4
20	1	0	0	1	0	0	0	10	28	20,39	23,5	28,1
20	1	0	0	1	0	0	0	50	180	22,29	20	37
20	1	0	0	0	1	0	0	0	180	18,91	29,5	18,6
20	1	0	0	0	1	0	0	10	90	19,68	35,75	20
20	1	0	0	0	1	0	0	50	28	19,57	32,25	24,9
20	1	0	0	0	0	1	0	0	28	18,2	23,75	36,5
20	1	0	0	0	0	1	0	10	180	20,53	23,5	20,6
20	1	0	0	0	0	1	0	50	90	20,92	25,5	22,2
20	0	1	0	1	0	0	0	0	28	19,17	22,75	29,4
20	0	1	0	1	0	0	0	10	180	19,29	22	31,1
20	0	1	0	1	0	0	0	50	90	20,03	23,75	49,3
20	0	1	0	0	1	0	0	0	90	18,2	32,75	16,1
20	0	1	0	0	1	0	0	10	28	18,81	21	23,6
20	0	1	0	0	1	0	0	50	180	19,51	21,5	35,8
20	0	1	0	0	0	1	0	0	180	19,03	20,25	48,8
20	0	1	0	0	0	1	0	10	90	19,89	26,75	21,4
20	0	1	0	0	0	1	0	50	28	19,6	21,75	27,6

20	0	0	0	1	1	0	0	0	0	180	20,84	26	28
20	0	0	0	1	1	0	0	0	10	90	21,43	33,25	30,9
20	0	0	0	1	1	0	0	0	50	28	22,8	24,5	35,5
20	0	0	0	1	0	1	0	0	0	28	20,3	33,25	22,8
20	0	0	0	1	0	1	0	0	10	180	20,86	34,25	24,8
20	0	0	0	1	0	1	0	0	50	90	21,6	41,75	25,6
20	0	0	0	1	0	0	0	1	0	90	20,96	26,25	61,9
20	0	0	0	1	0	0	0	1	10	28	20,68	26	28,5
20	0	0	0	1	0	0	0	1	50	180	22,21	23,5	25,3
50	1	0	0	0	1	0	0	0	0	90	18,28	45,75	23,4
50	1	0	0	0	1	0	0	0	10	28	21,23	43,75	26,4
50	1	0	0	0	1	0	0	0	50	180	18,33	51,5	31,4
50	1	0	0	0	0	1	0	0	0	180	18,71	55,75	18,1
50	1	0	0	0	0	1	0	0	10	90	18,07	48,25	23,9
50	1	0	0	0	0	1	0	0	50	28	19,83	44,25	27,1
50	1	0	0	0	0	0	0	1	0	28	19,48	47	23,8
50	1	0	0	0	0	0	0	1	10	180	18,85	60,25	17,2
50	1	0	0	0	0	0	0	1	50	90	18,72	50,75	18,7
50	0	1	0	0	1	0	0	0	0	28	18,84	46,5	33
50	0	1	0	0	1	0	0	0	10	180	17,69	46,25	23,6
50	0	1	0	0	1	0	0	0	50	90	17,32	38	42,4
50	0	1	0	0	0	1	0	0	0	90	17,16	53	14,5
50	0	1	0	0	0	1	0	0	10	28	19,49	42	28,9
50	0	1	0	0	0	1	0	0	50	180	18,56	50	48,3
50	0	1	0	0	0	0	0	1	0	180	17,94	53,75	23,7
50	0	1	0	0	0	0	0	1	10	90	17,84	43,75	20

50		0	1	0	0	0	0	1	50	28	19,49	41	32,4
50		0	0	1	1	0	0	0	0	180	19,36	65	15,7
50		0	0	1	1	0	0	0	10	90	19,44	48,25	27,7
50		0	0	1	1	0	0	0	50	28	22,43	56	33,5
50		0	0	1	0	1	0	0	0	28	21,91	57,25	21,9
50		0	0	1	0	1	0	0	10	180	19,86	59,5	20,8
50		0	0	1	0	1	0	0	50	90	19,74	51,75	24,3
50		0	0	1	0	0	0	1	0	90	19,33	51,75	24,3
50		0	0	1	0	0	0	1	10	28	22,41	52,75	24,1
50		0	0	1	0	0	0	1	50	180	20,24	62,5	28,3

Fonte: Autor.

ANEXO B – BASE DE DADOS DETALHADA

Tabela 22 – Base de Dados Detalhada

Resist. Ideal	Agregado								Cimento				Solução	Qtd Dias	Saídas		
20/50	Al2O3	CaO	Fe2O3	K2O	MgO	P2O5	SiO2	TiO2	CPII	CPIII	PCIV	0/10/50	28/90/180	UPV	FC	PM	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	1	0	0	0	90	19,81	27,25	18,4	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	1	0	0	10	28	20,39	23,5	28,1	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	1	0	0	50	180	22,29	20	37	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	1	0	0	180	18,91	29,5	18,6	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	1	0	10	90	19,68	35,75	20	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	1	0	50	28	19,57	32,25	24,9	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	0	1	0	28	18,2	23,75	36,5	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	0	1	10	180	20,53	23,5	20,6	
20	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	0	1	50	90	20,92	25,5	22,2	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	1	0	0	0	28	19,17	22,75	29,4	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	1	0	0	10	180	19,29	22	31,1	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	1	0	0	50	90	20,03	23,75	49,3	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	1	0	0	90	18,2	32,75	16,1	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	1	0	10	28	18,81	21	23,6	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	1	0	50	180	19,51	21,5	35,8	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	0	1	0	180	19,03	20,25	48,8	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	0	1	10	90	19,89	26,75	21,4	
20	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	0	1	50	28	19,6	21,75	27,6	

20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	1	0	0	0	0	180	20,84	26	28
20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	1	0	0	0	10	90	21,43	33,25	30,9
20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	1	0	0	0	50	28	22,8	24,5	35,5
20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	1	0	0	0	28	20,3	33,25	22,8
20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	1	0	0	10	180	20,86	34,25	24,8
20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	1	0	0	50	90	21,6	41,75	25,6
20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	0	1	0	0	90	20,96	26,25	61,9
20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	0	1	0	10	28	20,68	26	28,5
20	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	0	1	0	50	180	22,21	23,5	25,3
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	1	0	0	0	0	90	18,28	45,75	23,4
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	1	0	0	0	10	28	21,23	43,75	26,4
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	1	0	0	0	50	180	18,33	51,5	31,4
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	1	0	0	0	180	18,71	55,75	18,1
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	1	0	0	10	90	18,07	48,25	23,9
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	1	0	0	50	28	19,83	44,25	27,1
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	0	1	0	0	28	19,48	47	23,8
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	0	1	0	10	180	18,85	60,25	17,2
50	1.24	50.18	0.51	0.33	0.72	0.03	3.80	0.05	0	0	1	0	50	90	18,72	50,75	18,7
50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	1	0	0	0	0	28	18,84	46,5	33
50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	1	0	0	0	10	180	17,69	46,25	23,6
50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	1	0	0	0	50	90	17,32	38	42,4
50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	1	0	0	0	90	17,16	53	14,5
50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	1	0	0	10	28	19,49	42	28,9
50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	1	0	0	50	180	18,56	50	48,3
50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	0	1	0	0	180	17,94	53,75	23,7
50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	0	1	0	10	90	17,84	43,75	20

50	1.3	33.72	0.59	0.32	9.5	0.02	11.17	0.04	0	0	1	50	28	19,49	41	32,4
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	1	0	0	0	180	19,36	65	15,7
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	1	0	0	10	90	19,44	48,25	27,7
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	1	0	0	50	28	22,43	56	33,5
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	1	0	0	28	21,91	57,25	21,9
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	1	0	10	180	19,86	59,5	20,8
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	1	0	50	90	19,74	51,75	24,3
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	0	1	0	90	19,33	51,75	24,3
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	0	1	10	28	22,41	52,75	24,1
50	14.76	2.08	4.18	5.47	0.73	0.30	67.83	0.71	0	0	1	50	180	20,24	62,5	28,3

Fonte: Autor.

ANEXO C – BASE DE DADOS NORMALIZADA

Tabela 23 – Base de Dados Normalizada

Resist. Ideal	Agregado								Cimento				Sol.	Qtd Dias	Saídas		
	Al2O3	CaO	Fe2O3	K2O	MgO	P2O5	SiO2	TiO2	CPII	CPIII	PCIV	UPV			FC	PM	
0	0	1	0	0,00	0	0,04	0	0,01	1	0	0		0,41	0,47	0,16	0,08	
0	0	1	0	0,00	0	0,04	0	0,01	1	0	0		0,2	0,57	0,08	0,29	
0	0	1	0	0,00	0	0,04	0	0,01	1	0	0		1	0,91	0	0,47	
0	0	1	0	0,00	0	0,04	0	0,01	0	1	0		0	0,31	0,21	0,09	
0	0	1	0	0,00	0	0,04	0	0,01	0	1	0		0,2	0,45	0,35	0,12	
0	0	1	0	0,00	0	0,04	0	0,01	0	1	0		1	0,43	0,27	0,22	
0	0	1	0	0,00	0	0,04	0	0,01	0	0	1		0	0,18	0,08	0,46	
0	0	1	0	0,00	0	0,04	0	0,01	0	0	1		0,2	0,60	0,08	0,13	
0	0	1	0	0,00	0	0,04	0	0,01	0	0	1		1	0,67	0,12	0,16	
0	0,00	0,66	0,02	0	1	0	0,12	0	1	0	0		0	0,36	0,06	0,31	
0	0,00	0,66	0,02	0	1	0	0,12	0	1	0	0		0,2	0,38	0,04	0,35	
0	0,00	0,66	0,02	0	1	0	0,12	0	1	0	0		1	0,51	0,08	0,73	
0	0,00	0,66	0,02	0	1	0	0,12	0	0	1	0		0	0,18	0,28	0,03	
0	0,00	0,66	0,02	0	1	0	0,12	0	0	1	0		0,2	0,29	0,02	0,19	
0	0,00	0,66	0,02	0	1	0	0,12	0	0	1	0		1	0,42	0,03	0,45	
0	0,00	0,66	0,02	0	1	0	0,12	0	0	0	1		0	0,33	0,01	0,72	
0	0,00	0,66	0,02	0	1	0	0,12	0	0	0	1		0,2	0,48	0,15	0,15	
0	0,00	0,66	0,02	0	1	0	0,12	0	0	0	1		1	0,43	0,04	0,28	

0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	1	0,65	0,13	0,28
0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	0,41	0,76	0,29	0,35
0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	0	1	0,1	0,44
0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	0	0,56	0,29	0,18
0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	0,2	0,66	0,32	0,22
0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	0,41	0,79	0,48	0,23
0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	0,41	0,67	0,14	1
0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	0,2	0,62	0,13	0,30
0	1	0	1	1	0,00	1	1	1	1	0	0	0	0	1	0,90	0,08	0,23
1	0	1	0	0,00	0	0,04	0	0,01	1	0	0	0	0	0,41	0,20	0,57	0,19
1	0	1	0	0,00	0	0,04	0	0,01	1	0	0	0	0	0,2	0,72	0,53	0,25
1	0	1	0	0,00	0	0,04	0	0,01	1	0	0	0	0	1	0,21	0,7	0,36
1	0	1	0	0,00	0	0,04	0	0,01	0	0	0	0	0	1	0,27	0,79	0,08
1	0	1	0	0,00	0	0,04	0	0,01	0	0	0	0	0	0,41	0,16	0,63	0,20
1	0	1	0	0,00	0	0,04	0	0,01	0	0	0	0	0	0	0,47	0,54	0,27
1	0	1	0	0,00	0	0,04	0	0,01	0	0	0	0	0	0	0,41	0,6	0,20
1	0	1	0	0,00	0	0,04	0	0,01	0	0	0	0	0	0,2	0,30	0,89	0,06
1	0	1	0	0,00	0	0,04	0	0,01	0	0	0	0	0	0,41	0,28	0,68	0,09
1	0,00	0,66	0,02	0	1	0	0,12	0	1	0	0	0	0	0	0,30	0,59	0,39
1	0,00	0,66	0,02	0	1	0	0,12	0	1	0	0	0	0	0,2	0,09	0,58	0,19
1	0,00	0,66	0,02	0	1	0	0,12	0	1	0	0	0	0	1	0,03	0,4	0,59
1	0,00	0,66	0,02	0	1	0	0,12	0	0	0	0	0	0	0,41	0	0,73	0
1	0,00	0,66	0,02	0	1	0	0,12	0	0	0	0	0	0	0,2	0,41	0,49	0,30
1	0,00	0,66	0,02	0	1	0	0,12	0	0	0	0	0	0	1	0,25	0,67	0,71
1	0,00	0,66	0,02	0	1	0	0,12	0	0	0	0	0	0	0	0,14	0,75	0,19
1	0,00	0,66	0,02	0	1	0	0,12	0	0	0	0	0	0	0,2	0,12	0,53	0,12

1	0,00	0,66	0,02	0	1	0	0,12	0	0	0	1	1	0	0,41	0,47	0,38
1	1	0	1	1	0,00	1	1	1	0	0	0	0	1	0,39	1	0,03
1	1	0	1	1	0,00	1	1	1	0	0	0	0,2	0,41	0,40	0,63	0,28
1	1	0	1	1	0,00	1	1	1	0	0	0	1	0	0,93	0,8	0,40
1	1	0	1	1	0,00	1	1	1	0	1	0	0	0	0,84	0,83	0,16
1	1	0	1	1	0,00	1	1	1	0	1	0	0,2	1	0,48	0,88	0,13
1	1	0	1	1	0,00	1	1	1	0	1	0	1	0,41	0,46	0,71	0,21
1	1	0	1	1	0,00	1	1	1	0	0	1	0	0,41	0,38	0,71	0,21
1	1	0	1	1	0,00	1	1	1	0	0	1	0,2	0	0,93	0,73	0,20
1	1	0	1	1	0,00	1	1	1	0	0	1	1	1	0,55	0,94	0,29

Fonte: Autor.

ANEXO D – RELAÇÃO ENTRE OS VALORES REAIS E OS VALORES ENCONTRADOS POR QUANTIDADE DE ÉPOCAS DE TREINO

D.1 Ultrasonic Pulse Test

Tabela 24 – Relação entre valores reais e encontrados para *Ultrasonic Pulse Test*

20% dos Treinos				40% dos Treinos				100% dos Treinos			
Valor Real		Valor Encontrado		Valor Real		Valor Encontrado		Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor
1	0	1	0,06	1	0	1	0,03	1	0	1	0,03
2	0,03	2	0,07	2	0,03	2	0,05	2	0,03	2	0,04
3	0,09	3	0,08	3	0,09	3	0,05	3	0,09	3	0,06
4	0,12	4	0,08	4	0,12	4	0,11	4	0,12	4	0,11
5	0,14	5	0,17	5	0,14	5	0,14	5	0,14	5	0,14
6	0,16	6	0,15	6	0,16	6	0,16	6	0,16	6	0,16
7	0,18	7	0,16	7	0,18	7	0,19	7	0,18	7	0,19
8	0,18	8	0,20	8	0,18	8	0,18	8	0,18	8	0,18
9	0,20	9	0,18	9	0,20	9	0,17	9	0,20	9	0,19
10	0,21	10	0,23	10	0,21	10	0,21	10	0,21	10	0,21
11	0,25	11	0,22	11	0,25	11	0,26	11	0,25	11	0,25
12	0,27	12	0,27	12	0,27	12	0,27	12	0,27	12	0,27
13	0,28	13	0,29	13	0,28	13	0,28	13	0,28	13	0,28
14	0,29	14	0,30	14	0,29	14	0,29	14	0,29	14	0,29
15	0,30	15	0,30	15	0,30	15	0,29	15	0,30	15	0,30
16	0,30	16	0,28	16	0,30	16	0,30	16	0,30	16	0,30
17	0,31	17	0,32	17	0,31	17	0,32	17	0,31	17	0,31
18	0,33	18	0,32	18	0,33	18	0,33	18	0,33	18	0,33
19	0,36	19	0,35	19	0,36	19	0,36	19	0,36	19	0,35

20	0,38	20	0,37	20	0,38	20	0,38	20	0,38	20	0,38	20	0,38
21	0,38	21	0,42	21	0,38	21	0,38	21	0,38	21	0,38	21	0,39
22	0,39	22	0,36	22	0,39	22	0,39	22	0,39	22	0,39	22	0,39
23	0,40	23	0,45	23	0,40	23	0,40	23	0,40	23	0,40	23	0,40
24	0,41	24	0,42	24	0,41	24	0,41	24	0,41	24	0,41	24	0,41
25	0,41	25	0,39	25	0,41	25	0,41	25	0,41	25	0,41	25	0,41
26	0,41	26	0,42	26	0,41	26	0,41	26	0,41	26	0,41	26	0,42
27	0,42	27	0,43	27	0,42	27	0,42	27	0,42	27	0,42	27	0,42
28	0,43	28	0,40	28	0,43	28	0,43	28	0,43	28	0,43	28	0,43
29	0,43	29	0,42	29	0,43	29	0,43	29	0,43	29	0,43	29	0,43
30	0,45	30	0,43	30	0,45	30	0,45	30	0,45	30	0,45	30	0,45
31	0,46	31	0,44	31	0,46	31	0,46	31	0,46	31	0,46	31	0,46
32	0,47	32	0,51	32	0,47	32	0,47	32	0,47	32	0,47	32	0,47
33	0,47	33	0,49	33	0,47	33	0,47	33	0,47	33	0,47	33	0,47
34	0,48	34	0,50	34	0,48	34	0,48	34	0,48	34	0,48	34	0,48
35	0,48	35	0,49	35	0,48	35	0,48	35	0,48	35	0,48	35	0,48
36	0,51	36	0,51	36	0,51	36	0,51	36	0,51	36	0,51	36	0,51
37	0,55	37	0,54	37	0,55	37	0,55	37	0,55	37	0,55	37	0,54
38	0,56	38	0,56	38	0,56	38	0,56	38	0,56	38	0,56	38	0,56
39	0,57	39	0,58	39	0,57	39	0,57	39	0,57	39	0,57	39	0,57
40	0,60	40	0,60	40	0,60	40	0,60	40	0,60	40	0,60	40	0,60
41	0,62	41	0,65	41	0,62	41	0,62	41	0,62	41	0,62	41	0,63
42	0,65	42	0,66	42	0,65	42	0,65	42	0,65	42	0,65	42	0,65
43	0,66	43	0,64	43	0,66	43	0,65	43	0,66	43	0,66	43	0,66
44	0,67	44	0,69	44	0,67	44	0,67	44	0,67	44	0,67	44	0,67
45	0,67	45	0,66	45	0,67	45	0,67	45	0,67	45	0,67	45	0,67
46	0,72	46	0,71	46	0,72	46	0,74	46	0,72	46	0,73	46	0,73
47	0,76	47	0,73	47	0,76	47	0,75	47	0,76	47	0,76	47	0,76
48	0,79	48	0,83	48	0,79	48	0,80	48	0,79	48	0,79	48	0,79
49	0,84	49	0,85	49	0,84	49	0,84	49	0,84	49	0,84	49	0,84
50	0,90	50	0,92	50	0,90	50	0,90	50	0,90	50	0,90	50	0,89
51	0,91	51	0,87	51	0,91	51	0,91	51	0,91	51	0,91	51	0,90
52	0,93	52	0,87	52	0,93	52	0,90	52	0,93	52	0,93	52	0,92
53	0,93	53	0,94	53	0,93	53	0,93	53	0,93	53	0,93	53	0,94
54	1	54	0,94	54	1	54	0,97	54	1	54	1	54	0,98

Fonte: Autor.

D.2 Resistência a compressão

Tabela 25 – Relação entre valores reais e encontrados para Resistência a compressão

20% dos Treinos				40% dos Treinos				100% dos Treinos			
Valor Real		Valor Encontrado		Valor Real		Valor Encontrado		Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor
1	0	1	0,07	1	0	1	0,02	1	0	1	0,01
2	0,01	2	0,07	2	0,01	2	0,06	2	0,01	2	0,03
3	0,02	3	0,15	3	0,02	3	0,10	3	0,02	3	0,04
4	0,03	4	0,09	4	0,03	4	0,07	4	0,03	4	0,06
5	0,04	5	0,05	5	0,04	5	0,05	5	0,04	5	0,04
6	0,04	6	0,04	6	0,04	6	0,02	6	0,04	6	0,00
7	0,06	7	0,06	7	0,06	7	0,08	7	0,06	7	0,06
8	0,08	8	0,10	8	0,08	8	0,09	8	0,08	8	0,09
9	0,08	9	0,09	9	0,08	9	0,09	9	0,08	9	0,06
10	0,08	10	0,14	10	0,08	10	0,06	10	0,08	10	0,08
11	0,08	11	0,09	11	0,08	11	0,09	11	0,08	11	0,09
12	0,08	12	0,03	12	0,08	12	0,01	12	0,08	12	0,04
13	0,1	13	0,19	13	0,1	13	0,14	13	0,1	13	0,11
14	0,12	14	0,08	14	0,12	14	0,12	14	0,12	14	0,12
15	0,13	15	0,17	15	0,13	15	0,20	15	0,13	15	0,13
16	0,13	16	0,12	16	0,13	16	0,17	16	0,13	16	0,14
17	0,14	17	0,12	17	0,14	17	0,12	17	0,14	17	0,13
18	0,15	18	0,06	18	0,15	18	0,08	18	0,15	18	0,15
19	0,16	19	0,09	19	0,16	19	0,14	19	0,16	19	0,16
20	0,21	20	0,26	20	0,21	20	0,20	20	0,21	20	0,21
21	0,27	21	0,28	21	0,27	21	0,27	21	0,27	21	0,27
22	0,28	22	0,13	22	0,28	22	0,22	22	0,28	22	0,28
23	0,29	23	0,17	23	0,29	23	0,16	23	0,29	23	0,29
24	0,29	24	0,36	24	0,29	24	0,32	24	0,29	24	0,29
25	0,32	25	0,33	25	0,32	25	0,32	25	0,32	25	0,32
26	0,35	26	0,29	26	0,35	26	0,36	26	0,35	26	0,35
27	0,4	27	0,41	27	0,4	27	0,40	27	0,4	27	0,40
28	0,47	28	0,48	28	0,47	28	0,45	28	0,47	28	0,46
29	0,48	29	0,39	29	0,48	29	0,46	29	0,48	29	0,48
30	0,49	30	0,61	30	0,49	30	0,49	30	0,49	30	0,48
31	0,53	31	0,55	31	0,53	31	0,54	31	0,53	31	0,53

32	0,53	32	0,53	32	0,57	32	0,53	32	0,53	32	0,53
33	0,54	33	0,54	33	0,54	33	0,54	33	0,54	33	0,54
34	0,57	34	0,57	34	0,57	34	0,57	34	0,57	34	0,57
35	0,58	35	0,58	35	0,59	35	0,58	35	0,58	35	0,58
36	0,59	36	0,59	36	0,58	36	0,59	36	0,59	36	0,60
37	0,6	37	0,6	37	0,58	37	0,6	37	0,6	37	0,59
38	0,63	38	0,63	38	0,62	38	0,63	38	0,63	38	0,63
39	0,63	39	0,63	39	0,68	39	0,63	39	0,63	39	0,64
40	0,67	40	0,67	40	0,66	40	0,67	40	0,67	40	0,67
41	0,68	41	0,68	41	0,68	41	0,68	41	0,68	41	0,69
42	0,7	42	0,7	42	0,70	42	0,7	42	0,7	42	0,70
43	0,71	43	0,71	43	0,73	43	0,71	43	0,71	43	0,70
44	0,71	44	0,71	44	0,70	44	0,71	44	0,71	44	0,70
45	0,73	45	0,73	45	0,71	45	0,73	45	0,73	45	0,74
46	0,73	46	0,73	46	0,74	46	0,73	46	0,73	46	0,73
47	0,75	47	0,75	47	0,74	47	0,75	47	0,75	47	0,75
48	0,79	48	0,79	48	0,79	48	0,79	48	0,79	48	0,80
49	0,8	49	0,8	49	0,78	49	0,8	49	0,8	49	0,80
50	0,83	50	0,83	50	0,81	50	0,83	50	0,83	50	0,83
51	0,88	51	0,88	51	0,90	51	0,88	51	0,88	51	0,87
52	0,89	52	0,89	52	0,91	52	0,89	52	0,89	52	0,90
53	0,94	53	0,94	53	0,94	53	0,94	53	0,94	53	0,95
54	1	54	1	54	0,93	54	1	54	1	54	0,99

Fonte: Autor.

D.3 Porosimetria de Mercúrio

Tabela 26 – Relação entre valores reais e encontrados para Porosimetria de Mercúrio

20% dos Treinos				40% dos Treinos				100% dos Treinos			
Valor Real		Valor Encontrado		Valor Real		Valor Encontrado		Valor Real		Valor Encontrado	
Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor	Amostra	Valor
1	0	1	0,05	1	0	1	0,03	1	0	1	0,02
2	0,03	2	0,07	2	0,03	2	0,04	2	0,03	2	0,02
3	0,03	3	0,04	3	0,03	3	0,03	3	0,03	3	0,03
4	0,06	4	0,05	4	0,06	4	0,08	4	0,06	4	0,06

43	0,38	43	0,38	43	0,37
44	0,39	44	0,39	44	0,39
45	0,40	45	0,40	45	0,40
46	0,44	46	0,44	46	0,44
47	0,45	47	0,45	47	0,45
48	0,46	48	0,46	48	0,46
49	0,47	49	0,47	49	0,48
50	0,59	50	0,59	50	0,59
51	0,71	51	0,71	51	0,71
52	0,72	52	0,72	52	0,73
53	0,73	53	0,73	53	0,73
54	1	54	1	54	0,96

43	0,38	43	0,37
44	0,39	44	0,39
45	0,40	45	0,39
46	0,44	46	0,45
47	0,45	47	0,45
48	0,46	48	0,46
49	0,47	49	0,47
50	0,59	50	0,59
51	0,71	51	0,70
52	0,72	52	0,74
53	0,73	53	0,73
54	1	54	0,93

43	0,38	43	0,38
44	0,39	44	0,40
45	0,40	45	0,40
46	0,44	46	0,45
47	0,45	47	0,46
48	0,46	48	0,45
49	0,47	49	0,47
50	0,59	50	0,61
51	0,71	51	0,70
52	0,72	52	0,74
53	0,73	53	0,71
54	1	54	0,90

Fonte: Autor.