



DENNIS SANTOS TAVARES

**APLICAÇÃO DE MODELOS MATEMÁTICOS DE
INTELIGÊNCIA COMPUTACIONAL NA PREDIÇÃO DA
RESISTÊNCIA À COMPRESSÃO AXIAL DE CONCRETO
DE CIMENTO PORTLAND**

LAVRAS – MG

2021

DENNIS SANTOS TAVARES

**APLICAÇÃO DE MODELOS MATEMÁTICOS DE INTELIGÊNCIA
COMPUTACIONAL NA PREDIÇÃO DA RESISTÊNCIA À COMPRESSÃO
AXIAL DE CONCRETO DE CIMENTO PORTLAND**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

Prof. *DSc.* Tadayuki Yanagi Junior

Orientador

Prof. *DSc.* Francisco Carlos Gomes

Prof. *DSc.* Wilian Soares Lacerda

Prof. *DSc.* Ednilton Tavares de Andrade

Co-orientadores

LAVRAS – MG

2021

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Tavares, Dennis Santos.

Aplicação de Modelos Matemáticos de Inteligência
Computacional na Predição da Resistência à Compressão Axial de
Concreto de Cimento Portland / Dennis Santos Tavares. - 2021.
84 p. : il.

Orientador(a): Tadayuki Yanagi Junior.

Coorientador(a): Francisco Carlos Gomes, Wilian Soares
Lacerda, Ednilton Tavares de Andrade.

Dissertação (mestrado acadêmico) - Universidade Federal de
Lavras, 2021.

Bibliografia.

1. Concreto de cimento Portland. 2. Redes Neurais Artificiais.
3. Lógica Fuzzy. I. Junior, Tadayuki Yanagi. II. Gomes, Francisco
Carlos. III. Lacerda, Wilian Soares. IV. Andrade, Ednilton Tavares

**APLICAÇÃO DE MODELOS MATEMÁTICOS DE INTELIGÊNCIA
COMPUTACIONAL NA PREDIÇÃO DA RESISTÊNCIA À COMPRESSÃO
AXIAL DE CONCRETO DE CIMENTO PORTLAND**

**APPLICATION OF COMPUTATIONAL INTELLIGENCE MATHEMATICAL
MODELS TO PREDICT THE AXIAL COMPRESSIVE STRENGTH OF
PORTLAND CEMENT CONCRETE**

Dissertação apresentada à Universidade Federal de
Lavras, como parte das exigências do Programa de
Pós-Graduação em Engenharia de Sistemas e
Automação, para a obtenção do título de Mestre

APROVADA em 06 de agosto de 2021.

DSc. André Geraldo Cornélio Ribeiro (DAM/UFLA)

DSc. Sérgio Martins de Souza (DFI/UFLA)

DSc. Wilian Soares Lacerda (DAT/UFLA)

DSc. Yamid Fabián Hernández Julio (Universidad del Sinú/Colômbia)

DSc. Francisco Carlos Gomes (DEA/UFLA)

Prof. *DSc.* Tadayuki Yanagi Junior

Orientador

Prof. *DSc.* Francisco Carlos Gomes

Prof. *DSc.* Wilian Soares Lacerda

Prof. *DSc.* Ednilton Tavares de Andrade

Co-orientadores

LAVRAS – MG

2021

*A Deus.
À Nossa Senhora Aparecida.
À minha família.*
DEDICO

AGRADECIMENTOS

A Deus em seu infinito amor e misericórdia, pela vida, pelas oportunidades concedidas, força para enfrentar os desafios diários, por me guardar e guiar em todos os momentos;

Aos meus amados pais Diogo Tavares e Leonor Pereira dos Santos Tavares, pelo exemplo de vida, confiança em mim depositada, apoio, incentivo e dedicação incondicional;

À Clara Stefânia Pereira de Carvalho, minha namorada, pelo apoio, compreensão e motivação em todas as etapas do desenvolvimento desse trabalho;

À Terezinha de Nazaré Pereira Carvalho pelo imprescindível apoio e incentivo para realização do mestrado;

À Universidade Federal de Lavras (UFLA) e ao Departamento de Automática (DAT), pela oportunidade de realização do mestrado;

Ao professor DSc. Tadayuki Yanagi Junior, pela orientação, confiança, paciência, prestatividade e exemplo de profissionalismo;

Aos professores Francisco Carlos Gomes, Wilian Soares Lacerda e Ednilton Tavares de Andrade pela coorientação, disponibilidade para sempre me auxiliar e pelos conhecimentos transmitidos;

À Bruna pelo auxílio na pesquisa e modelagem com lógica *fuzzy*;

Aos professores e funcionários do Departamento de Engenharia Agrícola (DEA), Departamento de Automática (DAT) e do Departamento de Engenharia (DEG);

Aos colegas da Pós-Graduação pela troca de experiências e conhecimentos;

A todos que de alguma forma contribuíram para o desenvolvimento deste trabalho.

“Semeie um ato, e você colhe um hábito. Semeie um hábito, e você colhe um caráter. Semeie um caráter, e você colhe um destino.”

Charles Reade

RESUMO GERAL

A resistência à compressão axial é a principal propriedade do concreto, material estrutural mais utilizado em todo o mundo, porém não existem equações empíricas que forneçam, fácil e rapidamente, resultados confiáveis e precisos para predição desta importante propriedade que está diretamente relacionada ao desempenho estrutural e segurança das obras de construção civil. A dosagem do concreto e predição da resistência à compressão são obtidas por meio de ensaios laboratoriais conduzidos a partir de sucessivos ajustes em traços pilotos, o que demanda tempo e consumo de materiais. O objetivo deste trabalho consiste em aplicar as tecnologias de inteligência computacional, Redes Neurais Artificiais e Lógica *Fuzzy* para predição da resistência a compressão axial do concreto, a partir de uma base de dados composta por 1030 amostras com diferentes proporções de materiais constituintes e idades de cura. Foram testadas diversas configurações até a escolha de uma Rede Neural Artificial de arquitetura *feedforward* do modelo multilayer-perceptron (MLP) com uma camada de entrada, duas camadas ocultas e uma de saída. Também foram desenvolvidos vários sistemas *fuzzy* com diferentes métodos de inferência e defuzzificação que foram avaliados estatisticamente, sendo possível constatar que os métodos de inferência e defuzzificação adotados influenciam no resultado final e o melhor sistema foi com inferência Mamdani e defuzzificação centroide (centro de área). Os modelos desenvolvidos com inferência Mamdani e defuzzificação centroide, bissetor e mom, além da inferência Sugeno com defuzzificação *wtaver* e *wtsun* se mostraram confiáveis e capazes de fornecer resultados de alta precisão o que mostra ser promissor a aplicação de modelos de inteligência computacional na tecnologia do concreto, contribuindo para o avanço da industrialização e automatização da construção civil.

Palavras-chave: Concreto, Resistência à Compressão, Redes Neurais Artificiais, Lógica *Fuzzy*

GENERAL ABSTRACT

The axial compressive strength is the main property of concrete, the structural material most used worldwide, but there are no empirical equations that provide, easily and quickly, reliable and accurate results for prediction of this important property that is directly related to structural performance and safety of civil construction works. Concrete dosage and compressive strength prediction are obtained through laboratory tests conducted from successive adjustments in pilot batches, which requires time and consumption of materials. The objective of this work is to apply the technologies of computational intelligence, Artificial Neural Networks and Fuzzy Logic for predicting the axial compressive strength of concrete, from a database consisting of 1030 samples with different proportions of constituent materials and age of curing. Several configurations were tested until the choice of an Artificial Neural Network of feedforward architecture of the multilayer-perceptron (MLP) model with one input layer, two hidden layers and one output layer. It was also developed several fuzzy systems with different methods of inference and defuzzification that were statistically evaluated, being possible to verify that the methods of inference and defuzzification adopted influence the final result and the best system was with Mamdani inference and defuzzification center of area (centroid). The models developed with Mamdani inference and centroid, bisector and mom defuzzification, besides Sugeno inference with wtaver and wtsum defuzzification proved to be reliable and capable of providing high precision results, which shows the promise of applying computational intelligence models to concrete technology, contributing to the advancement of the industrialization and automation of civil construction.

Keywords: Concrete, Compressive strength, Artificial neural networks, Fuzzy logic

LISTA DE FIGURAS

PRIMEIRA PARTE

Figura 1 - Neurônio biológico.....	22
Figura 2 - Neurônio artificial	24
Figura 3 - Função de Limiar.....	25
Figura 4 - Função Linear por Partes.....	26
Figura 5 - Função Sigmóide.....	26
Figura 6 - Rede neural artificial feed-forward de camada única.....	27
Figura 7 - Rede neural artificial feed-forward de múltiplas camadas.....	28
Figura 8 - Rede neural artificial recorrente	28
Figura 9 - Lógica clássica x lógica <i>fuzzy</i>	34
Figura 10 - Operações com conjuntos <i>fuzzy</i>	36
Figura 11 - Funções de pertinência	37
Figura 12 - Sistema <i>fuzzy</i>	39
Figura 13 - Saídas parciais, inferência Mamdani.....	41
Figura 14 - Saída final, inferência Mamdani	41
Figura 15 - Saída do sistema <i>fuzzy</i> com inferência Sugeno para o exemplo dado	43

SEGUNDA PARTE

ARTIGO 1

Figure 1 – Artificial neuron.....	54
Figure 2 – Architecture chosen for RNA	58
Figure 3 – Graph for the sixth execution of the ANN that lists the MSE and the number of times required	60
Figure 4 – Values of the correlation coefficient R obtained in the sixth execution of the ANN.....	61
Figure 5 – Error histogram for the sixth ANN execution	62

ARTIGO 2

Figura 1 – Sistema <i>fuzzy</i> típico	67
Figura 2 – Funções de pertinência triangulares aplicadas às variáveis de entrada a) cimento (kg m ⁻³), b) escória de alto forno (kg m ⁻³), c) cinzas volantes (kg m ⁻³).....	69
Figura 3 – Funções de pertinência triangulares aplicadas às variáveis de entrada d) água (kg m ⁻³), e) aditivo super plastificante (kg m ⁻³), f) agregado graúdo (kg m ⁻³)	70
Figura 4 – Funções de pertinência triangulares aplicadas às variáveis de entrada g) agregado miúdo (kg m ⁻³) e h) idade (dias).....	71
Figura 5 – Variável de saída, resistência à compressão axial (MPa), representada por funções de pertinência triangulares na inferência Mamdani.....	71
Figura 6 – Variável de saída, resistência à compressão axial (MPa), representada por conjuntos <i>singletons</i> , na inferência Sugeno.....	72
Figura 7 – Representação gráfica dos métodos de defuzzificação centro da área (centroide), bissetor, menor dos máximos, média dos máximos e maior dos máximos ..	74
Figura 8 – Relação funcional entre os valores de resistência à compressão axial obtidos experimentalmente (R experimental) e preditos pelos sistemas <i>fuzzy</i> (R <i>fuzzy</i>), para defuzzificação (a) centroide, (b) bissetor, (c) mom, (d) lom e e) som.....	79
Figura 9 – Relação funcional entre os valores de resistência à compressão axial obtidos experimentalmente (R experimental) e preditos pelos sistemas <i>fuzzy</i> (R <i>fuzzy</i>), para defuzzificação (a) <i>wtaver</i> e (b) <i>wtsum</i>	80

LISTA DE QUADROS E TABELAS

PRIMEIRA PARTE

Quadro 1 - Siglas e classes de cimento Portland	17
Quadro 2 - Aditivos para concreto	19

SEGUNDA PARTE

ARTIGO 1

Table 1 - Examples of samples from the database	56
Table 2 - MSE, R and Times obtained with the RNA used in the study	59

ARTIGO 2

Tabela 1 - Teste t de Student e indicadores estatísticos das diferentes estruturas de sistemas de inferência <i>fuzzy</i> testados para predição da resistência à compressão axial ...	75
Tabela 2 - Frequência de ocorrência de erros absolutos dos diferentes sistemas de inferência <i>fuzzy</i> testados para predição da resistência à compressão axial	77

SUMÁRIO

INTRODUÇÃO.....	13
1.1 Objetivo geral	14
1.2 Objetivos específicos	14
2 REVISÃO DE LITERATURA	15
2.1 Concreto	15
2.1.1 Materiais constituintes do concreto	16
2.1.2 Dosagem e resistência à compressão do concreto	20
2.2 Redes neurais artificiais.....	21
2.2.1 Histórico das RNA's.....	23
2.2.2 Neurônio artificial.....	24
2.2.3 Arquitetura das RNA's	26
2.2.4 Treinamento das RNA's	29
2.3 Lógica <i>fuzzy</i>	33
2.3.1 Conjuntos <i>fuzzy</i>	34
2.3.2 Sistemas <i>fuzzy</i>	38
2.3.3 Métodos de Inferência: Mamdani e Sugeno	40
2.4 Trabalhos correlatos	44
3 CONSIDERAÇÕES GERAIS	47
4 REFERÊNCIAS BIBLIOGRAFICAS	48
SEGUNDA PARTE - ARTIGOS.....	52
ARTIGO 1	52
Use of artificial neural networks to predict concrete compression strength.....	52
ARTIGO 2	65
Implementação e avaliação de diferentes sistemas <i>fuzzy</i> para predição da resistência à compressão axial de concreto de cimento Portland.....	65
CONSIDERAÇÕES FINAIS	84

PRIMEIRA PARTE

1 INTRODUÇÃO

O concreto é um material estrutural empregado na construção de casas, edifícios, estádios, pontes, viadutos, túneis, estruturas de contenção, usinas geradoras de energia elétrica, portos, aeroportos, dentre outras obras fundamentais para o bom funcionamento da sociedade, o que faz desse material um dos mais importantes e utilizados pela humanidade. Em sua composição estão presentes diversos materiais com diferentes propriedades físico mecânicas, principalmente cimento, agregado miúdo, agregado graúdo e água, além da possibilidade de incorporação de aditivos químicos que potencializam algumas de suas propriedades.

A tarefa de dosagem do concreto e predição da resistência à compressão axial é complexa, tendo em vista que não existe uma equação eficaz para determinação da proporção dos componentes. Uma vez que, os materiais constituintes possuem propriedades bastante diferentes, a resistência à compressão fica ainda mais difícil de ser estimada. Desta forma, a maioria das dosagens são feitas a partir de ensaios experimentais ou pelo uso de tabelas disponibilizadas na literatura.

Neste sentido, a implementação de técnicas de inteligência computacional, como redes neurais artificiais (RNAs) e lógica *fuzzy*, com o intuito de facilitar a predição da resistência à compressão axial e, conseqüentemente, agilizar a tarefa de dosagem, proporciona avanço na tecnologia do concreto. O uso de RNAs e lógica *fuzzy* na solução de problemas de regressão não linear tem se mostrado satisfatório, possibilitando, desta forma, o uso destas metodologias na predição da resistência à compressão axial do concreto, com custo computacional relativamente baixo.

Neste contexto, as RNAs constituem importante metodologia cujo desenvolvimento foi inspirado no sistema nervoso central, sendo capaz de aprender e generalizar, desde que se disponha de um banco de dados que contenha as características necessárias para resolução do problema a ser explorado. Uma RNA é composta por sinais de entrada que são apresentados a rede e se propagam através dela por meio de uma ou mais camadas de neurônios artificiais interligados até que atinja a camada de saída. Esse procedimento é repetido diversas vezes até que a RNA aprenda o comportamento e as

características contidas nas amostras do banco de dados e se torne capaz de apresentar soluções satisfatórias para amostras nunca antes apresentadas a rede.

A lógica *fuzzy* também se destaca como uma técnica de inteligência computacional desenvolvida com base no raciocínio impreciso em que expressões qualitativas, vagas e incertas, comuns na comunicação humana, são convertidas em valores numéricos, tornando viável transformar a experiência humana em um padrão de linguagem adequado aos sistemas binários computacionais. Na matemática clássica os conjuntos possuem uma transição bem definida, já na lógica *fuzzy* os conjuntos difusos possuem uma transição gradual.

Essas técnicas de inteligência artificial vêm sendo estudadas para aplicação em diversas áreas, inclusive na predição da resistência à compressão axial e dosagem do concreto, seja ela convencional ou com a incorporação de outros materiais e até para dimensionamento e análise mecânica de elementos estruturais feitos em concreto armado como lajes, pilares e vigas. A motivação para o desenvolvimento desse trabalho baseia-se no baixo número de modelos matemáticos publicados para quantificação dos materiais constituintes do concreto e/ou predição da resistência à compressão axial e também na necessidade de inovação e implementação de novas tecnologias para promover a industrialização da construção civil.

1.1 Objetivo geral

Desenvolver uma rede neural artificial (RNA) e um sistema *fuzzy* capazes de predizerem a resistência à compressão axial do concreto de cimento Portland.

1.2 Objetivos específicos

- Treinar, testar e validar uma RNA para predizer a resistência à compressão axial do concreto de cimento Portland aos *j* dias de cura em função dos traços.
- Ajustar e avaliar sistemas *fuzzy* com diferentes inferências e métodos de defuzzificação capazes de predizer a resistência à compressão axial do concreto de cimento Portland aos *j* dias de cura em função dos traços.

2 REVISÃO DE LITERATURA

Neste capítulo apresenta-se o estado da arte, no que diz respeito a conceitos fundamentais da tecnologia do material concreto, temas gerais referentes às técnicas de inteligência computacional, redes neurais artificiais e lógica *fuzzy*, além de trabalhos correlatos com diversas aplicações dessas técnicas na indústria da construção civil.

2.1 Concreto

O concreto é um material de construção civil amplamente utilizado em todo o mundo, sendo composto basicamente pela mistura de cimento, agregado miúdo, agregado graúdo e água. As propriedades do concreto, tanto no estado fresco como no estado endurecido, especialmente sua resistência e durabilidade dependem diretamente das proporções de cada um de seus materiais constituintes.

O concreto é o material estrutural mais utilizado na construção civil e pode ser considerado como uma combinação de cimento, agregados e água. Os agregados são inertes e rígidos que formam o esqueleto granular. O cimento é o aglomerante hidráulico que une os materiais e a água promove o processo de hidratação do cimento e, conseqüentemente, o processo de cura.

Conforme Moretti et al. (2016), o concreto é um material heterogêneo e seu comportamento mecânico apresenta não linearidades. Para satisfazer os requisitos técnicos exigidos para o concreto é necessário definir propriedades em estado fresco e endurecido e, portanto, é preciso utilizar um método de dosagem que forneça a proporção adequada de seus materiais constituintes. Os métodos de dosagem originam diagramas e ábacos baseados em testes experimentais.

De acordo com Dogan, Arslan e Ceylan (2017), o concreto é o mais significativo dos materiais de construção e estudos acerca dos efeitos dos materiais constituintes no comportamento mecânico do concreto vem sendo desenvolvidos continuamente, assim como diversas teorias sobre dosagem e propriedades mecânicas. A estrutura heterogênea desse material e suas não linearidades têm instigado os pesquisadores.

2.1.1 Materiais constituintes do concreto

Basicamente o concreto é composto de cimento, que atua como um aglomerante para unificação dos materiais formando um bloco monolítico, agregados miúdos, agregados graúdos e água. Eventualmente pode-se incorporar ao concreto, aditivos químicos que podem potencializar suas propriedades em estado fresco ou endurecido.

Bauer (2014) definiu cimento como um produto oriundo da pulverização de *clinker* constituído essencialmente de silicatos hidráulicos de cálcio, com certa proporção de sulfato de cálcio natural, além de conter eventualmente, adições de algumas substancias que modificam suas propriedades ou facilitam a utilização.

Ainda conforme o mesmo autor, o processo produtivo do cimento se inicia com a extração da matéria prima que passa por um processo de britagem, em seguida esse material britado é encaminhado para depósitos de onde são processados em via seca ou via úmida. No processamento em via seca a matéria prima é transportada até uma estufa onde é secada e posteriormente conduzida a moinhos para produção de grãos homogêneos. Esse material é conduzido a silos onde aguarda o processo de queima. No processo por via úmida a matéria prima utilizada é a argila natural que, misturada com água forma uma lama espessa para posteriormente ser misturada com o calcário britado que é conduzido aos moinhos, em seguida aos silos de homogeneização e por fim, para o silo de armazenamento. Nessa etapa os processos por via seca e por via úmida se encontram para alimentação do forno para produção do *clinker* que é moído e misturado com gipsita para proporcionar controle no tempo de pega. O produto resultante, cimento Portland, é então ensacado ou conduzido a granel para veículos transportadores. Atualmente, a Associação Brasileira de Normas Técnicas (ABNT) por meio da norma NBR 16697 (2018), estabelece 10 classes de cimento Portland conforme listado no Quadro 1.

Quadro 1 - Siglas e classes de cimento Portland

Designação normalizada (tipo)	Subtipo	Sigla	Classe de resistência	Sufixo
Cimento Portland comum	Sem adição	CP I	25,32 ou 40 ^c	RS ^a ou BC ^b
	Com adição	CP I-S		
Cimento Portland composto	Com escória de alto forno	CP II-E		
	Com material carbonático	CP II-F		
	Com material pozolânico	CP II-Z		
Cimento Portland de alto-forno		CP III		
Cimento Portland pozolânico		CP IV		
Cimento Portland de alta resistência inicial		CP V	ARI ^d	
Cimento Portland branco	Estrutural	CPB	25,32 ou 40 ^c	
	Não estrutural	CPB	-	-

^a O sufixo RS significa resistente a sulfatos e se aplica a qualquer tipo de cimento Portland que atenda aos requisitos estabelecidos em 5.3 da NBR 16697 (ABNT, 2018), além dos requisitos para seu tipo e classe originais.

^b O sufixo BC significa baixo calor de hidratação e se aplica a qualquer tipo de cimento Portland que atenda aos requisitos estabelecidos em 5.4 da NBR 16697 (ABNT, 2018), além dos requisitos para seu tipo e classe originais.

^c As classes 25, 32 e 40 representam os mínimos de resistência à compressão aos 28 dias de idade, em megapascals (MPa), conforme método de ensaio estabelecido pela ABNT NBR 7215

^d Cimento Portland de alta resistência inicial, CP V, que apresenta a 1 dia de idade resistência igual ou maior que 14 MPa, quando ensaiado de acordo com a ABNT NBR 7215 e atende aos demais requisitos estabelecidos nesta Norma para esse tipo de cimento.

Fonte: Adaptado de ABNT (2018)

Bauer (2014) define agregado como um material particulado, não coesivo, com praticamente nenhuma atividade química, composto por misturas de partículas cobrindo grande variabilidade de tamanhos.

Os agregados podem ser classificados em miúdos, que são as areais e grãos que são as britas. A norma NBR 7211 (2019) da ABNT estabelece que os agregados miúdos são aqueles cujas partículas passam pela peneira com malha de 4,75 mm de abertura e ficam retidos na peneira de 0,15 mm em ensaio de granulometria a ser realizado seguindo os parâmetros da norma NBR NM 248 (ABNT, 2003).

Os agregados grãos, de acordo com a norma NBR 7211 (ABNT, 2009) são aqueles em que os grãos passam pela peneira com malha de 75 mm de abertura e ficam retidos na peneira com malha de 4,75 mm de abertura.

De acordo com Bauer (2014) os agregados também podem ser classificados de acordo com a origem. Os naturais, são aqueles que são encontrados na natureza já particulados, como areia e cascalho. Os agregados industrializados são aqueles que passam por processos industriais para fragmentação, como é o caso das rochas.

O uso de aditivos no concreto potencializa suas propriedades e de acordo com a norma NBR 11768 (ABNT, 2019), esses produtos podem ser incorporados ao concreto durante a mistura, com o intuito de modificar as propriedades do concreto em estado fresco e ou endurecido, exceto pigmentos inorgânicos para o preparo do concreto colorido. A incorporação de aditivos não deve ser superior a 5% da massa de cimento contida no concreto.

De acordo com a NBR 11768 (ABNT, 2019), os aditivos podem ser líquidos ou pó e sua incorporação no concreto pode ter diversas finalidades como retardar ou acelerar o tempo de pega, elevar a fluidez, impermeabilização, dentre outras. No quadro 2 estão listados os principais aditivos mencionados na NBR 11768, (ABNT, 2019) e suas respectivas funções no concreto.

Quadro 2 - Aditivos para concreto

Aditivo	Finalidade
Aditivo redutor de água / plastificante	Reduz o conteúdo de água sem alterar a consistência em estado fresco ou modifica a consistência sem alterar a quantidade de água ou mesmo produz os dois efeitos simultaneamente sem apresentar função secundária sobre a pega.
Aditivo redutor de água / superplastificante	Promove elevada redução no conteúdo de água sem alterar a consistência em estado fresco ou eleva consideravelmente o abatimento e a fluidez sem alterar a quantidade de água ou mesmo produz os dois efeitos simultaneamente sem apresentar função secundária sobre a pega.
Aditivo incorporador de ar	Permite incorporar uma quantidade controlada de pequenas bolhas de ar, durante o amassamento, uniformemente distribuídas que permanecem no estado endurecido
Aditivo acelerador de pega	Reduz o tempo de transição do estado plástico para o estado endurecido.
Aditivo acelerador de resistência	Eleva a taxa de desenvolvimento da resistência inicial do concreto com ou sem alteração no tempo de pega.
Aditivo retardador de pega	Eleva o tempo de transição do estado plástico para o estado endurecido.
Aditivo redutor de água e retardador de pega/plastificante retardador	Combina os efeitos do aditivo redutor de água/plastificante (função principal) com os efeitos do aditivo retardador de pega (função secundária).
Aditivo de alta redução de água e retardador de pega / superplastificante retardador	Combina os efeitos do aditivo redutor de água de alto desempenho /superplastificante (função principal) com os efeitos do aditivo retardador de pega (função secundária).
Aditivo redutor de água e acelerador de pega / plastificante acelerador	Combina os efeitos do aditivo redutor de água /plastificante (função principal) com os efeitos do aditivo acelerador de pega (função secundária).
Aditivo de alta redução de água e acelerador de pega / superplastificante	Combina os efeitos do aditivo redutor de água de alto desempenho /superplastificante (função principal) com os efeitos do aditivo acelerador de pega (função secundária).

Fonte: Adaptado de ABNT (2019)

A qualidade dos materiais constituintes do concreto é fator determinante para garantia da durabilidade do material. Os principais fatores que comprometem a vida útil das edificações são oriundos da degradação dos materiais devido a agentes agressivos presentes no ambiente, mas também nos insumos necessários para produção do concreto (RECENA, 2014).

A norma de desempenho de edificações NBR 15775-1 (ABNT, 2013) estabelece que a vida útil de projeto mínima para estruturas de concreto armado deve ser igual ou superior a 50 anos. Ainda de acordo com a mesma norma o comportamento em serviço das estruturas deve ser previstos no projeto de forma que os estados limites de serviço, por sua ocorrência, repetição ou duração não provoquem efeitos estruturais que prejudiquem o uso normal da edificação ou que comprometam a durabilidade da mesma.

2.1.2 Dosagem e resistência à compressão do concreto

A tarefa de dosagem do concreto consiste no conjunto de procedimentos a serem realizados para determinação do traço, ou seja, das proporções dos materiais constituintes do concreto de modo que ele atinja os parâmetros exigidos ao final de um período de cura do material.

Oliveira, Biondi Neto e Tavares (2007) afirmaram que os métodos de dosagem se fundamentam principalmente em estudos empíricos, não apresentando uma equação específica que consiga relacionar as propriedades requeridas, principalmente a resistência a compressão, com os materiais disponíveis para seu preparo. Existem muitos métodos de dosagem para determinação do traço de um concreto, podendo-se citar o proposto pelo Instituto Nacional de Tecnologia, o da Associação Brasileira de Cimento Portland (ABCP) e o estabelecido pelo *American Concrete Institute* (ACI). Apesar de existirem diversos métodos para determinação das proporções de materiais para a mistura do concreto, nenhum deles é capaz de fornecer traços que não necessite de ajustes experimentais.

Helene e Terzian (1993) afirmaram que a relação água/cimento (a/c) está intimamente ligada a durabilidade e resistência do concreto e, portanto, é o mais importante parâmetro do concreto estrutural. É recomendado a relação a/c de 0,65 para concretos protegidos e sem risco de ocorrência de condensação de umidade, 0,55 para

concretos expostos a intempéries, em atmosfera urbana ou rural e de 0,48 para peças expostas a intempéries em regiões industriais e marítimas.

De acordo com Khademi et al. (2016), a resistência a compressão do concreto é uma das principais propriedades mecânicas do material, sendo considerado um dos parâmetros mais importantes para garantia da qualidade.

Oliveira, Biondi Neto e Tavares (2007) afirmaram que a importância dessa propriedade é devido ao fato de que todo cálculo estrutural em concreto armado ou protendido é feito levando-se em conta o valor da resistência a compressão do concreto e normalmente despreza-se a resistência à tração, pois esta é em torno de 1/10 da resistência a compressão. O concreto é especificado, do ponto de vista da engenharia estrutural, em termos da resistência característica a compressão (f_{ck}), obtida aos 28 dias de cura e que possui 95% de probabilidade de ser ultrapassada no sentido favorável quando se ensaia um determinado número de corpos de prova.

A moldagem dos corpos de prova para posterior ensaio de compressão é padronizada no Brasil pela norma NBR 5738 (ABNT, 2015). Por sua vez, a ruptura dos corpos de prova via ensaio de compressão axial é padronizada pela NBR 5739 (ABNT, 2018).

2.2 Redes neurais artificiais


As redes neurais artificiais são uma metodologia de inteligência computacional bastante eficiente para aprendizado de padrões a partir de um conjunto de dados, desde que este possua amostras suficientes para descrever o problema a ser explorado e para que a RNA extraia suas características atingindo a capacidade de generalização (HAYKIN, 2001).

De acordo com Bas et al. (2016), as RNA's são definidas como algoritmos matemáticos inspirados em redes biológicas e que possuem a capacidade de aprender com amostras e generalizá-las. A característica mais importante de uma RNA é a capacidade de aprender a partir de uma fonte de dados. O processo de aprendizagem nada mais é do que encontrar os melhores valores a serem atribuídos aos pesos que conectam os neurônios artificiais.

Vazirizade, Nozhati e Zadeh (2017) afirmaram que basicamente uma RNA é constituída de nós e conexões que os ligam, sendo que cada conexão está associada a um peso. Essas conexões são o principal mecanismo que promove a capacidade de aprendizado. Antes que uma RNA possa ser utilizada para solução de problemas complexos é necessário que ela passe pelo processo de treinamento para ajustes dos pesos.

Os neurônios biológicos que serviram de inspiração para o desenvolvimento das RNAs basicamente são constituídos, conforme Freitas (2011), de corpo celular, dendritos e axônio. A Figura 1 ilustra, simplificada, um neurônio biológico e suas principais partes.

Figura 1 - Neurônio biológico



Fonte: Adaptado de Braga, Carvalho e Ludemir (2000).

Ainda de acordo com Freitas (2011), o corpo celular ou soma é o responsável pela recepção e geração dos impulsos nervosos, os dendritos recebem as informações de outros neurônios conduzindo-as para o corpo celular e os sinais processados para os outros neurônios. As sinapses são os pontos de conexão entre o axônio de um neurônio e o dendrito do outro, capazes de controlar a transmissão de impulsos entre os neurônios.

2.2.1 Histórico das RNA's

Inspirados no modelo do cérebro humano vários estudos tentaram simular o seu funcionamento para desenvolver sistemas com a capacidade de aprendizado a partir de experiências anteriores, para se chegar à capacidade de generalização para solução de problemas futuros.

Os estudos das RNAs se originaram com o trabalho de McCulloch e Pits (1943) que simularam o comportamento de um neurônio biológico utilizando circuitos elétricos. O neurônio artificial proposto continha diversas entradas e apenas uma saída, gerando apenas resultados binários.

Hebb (1949) afirmou que a capacidade de aprendizado das redes de neurônios biológicos provém das interações sinápticas entre os neurônios. Quanto mais usadas são as sinapses, mais elas são fortalecidas e aprimora-se a aprendizagem.

Rosenblatt (1958) desenvolveu um modelo de RNA, chamado “Perceptron”, para reconhecimento de caracteres. Nesse modelo, os neurônios artificiais eram estruturados em camada de entrada e saída em que os pesos de cada sinal de entrada eram ajustados até que a resposta fornecida pela rede fosse a mais próxima possível da resposta esperada. O processo iterativo era interrompido ao atingir um critério de parada previamente estabelecido.

Widrow e Hoff (1960) propuseram o neurônio artificial “Adaline” e a RNA “Madaline” que utiliza função de ativação do tipo linear, diferentemente do “Perceptron” que utiliza função degrau.

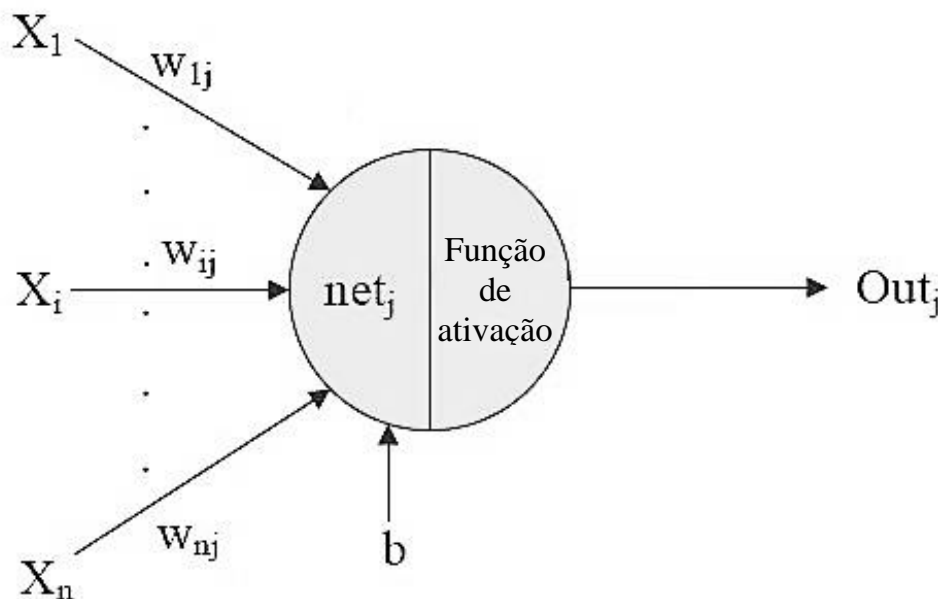
Muitas pesquisas relacionadas às RNAs foram desenvolvidas ao longo do tempo, entretanto, pode-se afirmar que um dos trabalhos mais importantes nessa área foi o desenvolvimento da técnica de treinamento “Backpropagation” por Rumelhart et al. (1985) em que o erro é distribuído por toda a rede para ajuste dos pesos sinápticos.

Atualmente, as RNAs encontram-se bastante difundidas e possuem aplicações nas mais diversas áreas, como engenharia, computação, *marketing*, finanças, ciências agrárias e medicina. Essa técnica de inteligência computacional possibilita o desenvolvimento de algoritmos, que tornam possível a solução de problemas altamente complexos, com base em conjuntos de dados.

2.2.2 Neurônio artificial

Os neurônios artificiais são unidades processadoras compostas por sinais de entrada e seus respectivos pesos, função somadora, função de ativação e a saída correspondente (GOLAFSHANI E BEHNOOD, 2018). A Figura 2 ilustra um neurônio artificial e todos os seus componentes

Figura 2 - Neurônio artificial



Fonte: Adaptado de Golafshani e Behnood (2018)

O princípio de funcionamento dos neurônios artificiais inicia-se com a apresentação dos sinais de entrada X_i , que são multiplicados pelos seus pesos correspondentes W_i . O “b” corresponde ao *bias* que é uma entrada especial, de valor constante +1 multiplicado por um peso b_k , que pode aumentar ou reduzir a importância dos sinais de entrada. Em seguida é feita a soma ponderada dos sinais de entrada, descrita por net_j , esse resultado passa pela função de ativação que produz a saída do neurônio artificial (GOLAFSHANI E BEHNOOD, 2018).

Golafshani e Behnood (2018) propuseram as equações (1) e (2) para descrição matemática do funcionamento de um neurônio artificial:

$$net_j = \sum_{i=1}^n w_{ij}x_i + b \quad (1)$$


$$out_j = f(net_j) \quad (2)$$

Haykin (2001) afirmou que a função de ativação define a saída do neurônio e apresenta três tipos básicos, conforme Equações 3, 4 e 5, bem como ilustrado nas Figuras 3, 4 e 5:

1. Função de limiar (equação 3)

$$f(net_j) = \begin{cases} 1 & \text{se } net_j \geq 0 \\ 0 & \text{se } net_j < 0 \end{cases} \quad (3)$$

Figura 3 - Função de Limiar




Fonte: Adaptado de Haykin (2001)

2. Função linear por partes (equação 4)

$$f(net_j) = \begin{cases} 1, & net_j \geq +\frac{1}{2} \\ net_j, & +\frac{1}{2} > net_j > -\frac{1}{2} \\ 0, & net_j \leq -\frac{1}{2} \end{cases} \quad (4)$$

Figura 4 - Função Linear por Partes




Fonte: Adaptado de Haykin (2001)

3. Função sigmoide (equação 5)

$$f(\text{net}_j) = \frac{1}{1 + \exp(-a \text{net}_j)} \quad (5)$$

Onde “a” é o parâmetro de inclinação da função Sigmóide. Variando-se o parâmetro, obtém-se funções com diferentes inclinações.

Figura 5 - Função Sigmóide



Fonte: Adaptado de Haykin (2001)

2.2.3 Arquitetura das RNA's


A determinação da arquitetura é de fundamental importância para que uma RNA obtenha a melhor resposta possível para o problema estudado. No entanto, não existem procedimentos bem definidos que acarretem na obtenção da arquitetura mais eficiente para solução de cada tipo de problema.

Segundo Siddique, Aggarwal e Aggarwal (2011), na maioria das vezes a determinação da melhor arquitetura para uma rede neural artificial, ou seja, aquela que é

mais eficiente para solução do problema abordado, é feita por meio de várias tentativas, até que se encontre uma que ofereça melhor desempenho possível. Para desenvolver uma RNA é necessário determinar o número de camadas ocultas da rede e o número de neurônios em cada camada, de modo a se obter uma rede de menor complexidade e maior capacidade de generalização possível.

Haykin (2001) estabeleceu que as RNAs podem ser divididas em três classes de arquiteturas fundamentalmente diferentes. As redes neurais podem ser do tipo alimentadas adiante (*feed-forward*) com única camada composta por uma camada de entrada que se projeta sobre uma camada de neurônios de saída, mas não ao contrário, sendo, portanto, estritamente alimentada para frente. A Figura 6 ilustra um modelo de RNA *feed-forward* de camada única, sendo que não se considera a camada de entrada porque nela não é realizada nenhuma computação.


Figura 6 - Rede neural artificial *feed-forward* de camada única



Fonte: Adaptado de Haykin (2001)

Haykin (2001) definiu redes alimentadas diretamente com múltiplas camadas, ou rede *feed-forward* de múltiplas camadas, como aquelas com a presença de uma ou mais camadas ocultas. Os neurônios ocultos intervêm de forma sutil entre a entrada externa e a saída da rede. Adicionando-se camadas ocultas eleva-se a capacidade da rede de extrair estatísticas de ordem elevada. A Figura 7 ilustra uma RNA *feed-forward* de múltiplas camadas.

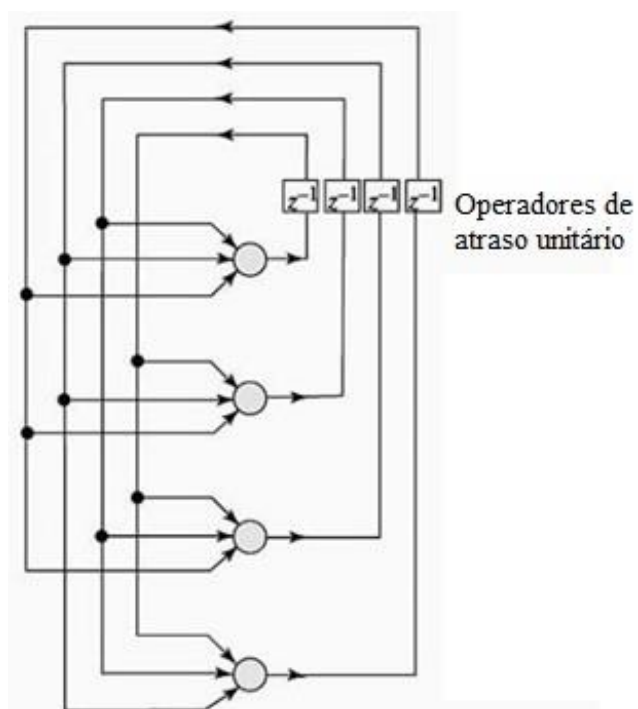
Figura 7 - Rede neural artificial *feed-forward* de múltiplas camadas



Fonte: Adaptado de Haykin (2001)

Existem ainda, as RNAs do tipo recorrentes em que a saída do neurônio é reinsertada na RNA, conforme ilustrado na Figura 8.

Figura 8 - Rede neural artificial recorrente



Fonte: Adaptado de Haykin (2001)

Uma RNA recorrente, segundo Haykin (2001), possui pelo menos um laço de realimentação, podendo consistir, por exemplo, de camada única de neurônios, no qual cada neurônio alimenta seu sinal de saída de volta para as entradas de todos os outros neurônios (Figura 9).

2.2.4 Treinamento das RNA's

Segundo Haykin (2001), a habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho é de importância primordial para uma RNA.

Golafshani e Behnood (2018) afirmaram que o processo de treinamento de uma RNA é necessário para encontrar os melhores valores para os pesos dos neurônios que compõem a rede, de tal forma que as diferenças entre os valores de saída e o esperado são minimizadas.

Haykin (2001) estabeleceu a seguinte sequência de eventos que define o processo de aprendizagem em uma rede neural:

1. A rede é estimulada por um ambiente;
2. A rede sofre modificações em seus parâmetros livres devido a esta estimulação;
3. A rede responde de uma nova maneira ao ambiente, devido as modificações ocorridas.

Um conjunto pré-determinado de regras para solução de um problema de aprendizagem é denominado “algoritmo de aprendizagem”. Existe uma variedade de algoritmos de aprendizagem, cada qual oferecendo vantagens específicas. Os algoritmos se diferenciam basicamente pela forma em que é realizado o ajuste dos pesos sinápticos dos neurônios (HAYKIN, 2001).

O desenvolvimento do algoritmo de aprendizagem *backpropagation*, sem dúvida, foi um dos maiores avanços nos estudos em RNAs. Segundo Reis (2011), esse algoritmo foi pioneiro no ajuste de pesos em redes neurais multicamadas, permitindo o desenvolvimento de redes mais genéricas.

Isaac Júnior (2018) afirmou que o algoritmo de retropropagação do erro ou *backpropagation* consiste em duas fases. Inicialmente, realiza-se a propagação para frente, sendo que, os pesos gerados aleatoriamente são multiplicados pelos seus

respectivos sinais de entrada, realiza-se então, a soma e, a função de ativação fornece a saída da rede que é subtraída do valor da saída esperado. Em um segundo momento, os pesos são ajustados e propagados para trás para serem atualizados. O processo se repete até que a saída da RNA seja igual a saída esperada ou atenda aos critérios de interrupção do treinamento.

O algoritmo *backpropagation* é descrito matematicamente por Haykin (2001) da seguinte forma:

Na fase de propagação para frente, toma-se um exemplo de treinamento da época representado por $(x(n), d(n))$, com o vetor de entrada $x(n)$ aplicado na camada de entrada de neurônios e o vetor de saída esperada $d(n)$ apresentado a camada de saída de neurônios. O campo local induzido $v_j^{(l)}(n)$ para o neurônio j na camada l é determinado pela equação (6).

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(n) y_i^{l-1}(n) \quad (6)$$

em que,

$v_j^{(l)}(n)$: é o campo local induzido para o neurônio j na camada l ;

$y_i^{l-1}(n)$: é o sinal de saída do neurônio i na camada anterior $l - 1$, na iteração n ;

$w_{ji}^{(l)}(n)$: é o peso do neurônio j da camada l , alimentado pelo neurônio i da camada $l - 1$.

Para $i = 0$, tem-se $y_0^{l-1}(n) = +1$ e $w_{j0}^{(l)}(n) = b_j^{(l)}(n)$ é o *bias* aplicado ao neurônio j na camada l .

Utilizando uma função sigmoide, o sinal de saída do neurônio j na camada l é calculado pela equação (7).

$$v_j^{(l)} = \varphi_j(v_j(n)) \quad (7)$$

sendo,

$v_j^{(l)}$: é a saída do neurônio j na camada l ;

$\varphi_j(v_j(n))$: função de ativação sigmoide no j -ésimo neurônio na camada de saída no instante n .

Em seguida, calcula-se o sinal do erro pela equação (8).

$$e_j(n) = d_j(n) - o_j(n) \quad (8)$$

em que,

$d_j(n)$: é o j -ésimo elemento do vetor resposta desejada $d(n)$;

$o_j(n)$: é o sinal funcional na saída do neurônio j .

Posteriormente, inicia-se a fase de retropropagação do erro. Calcula-se os δ s (i.e., gradientes locais) da rede, definidos por:

para o neurônio j da camada de saída L usa-se a equação (9).

$$\delta_j^{(L)}(n) = e_j^{(L)}(n) \varphi_j'(v_j^{(L)}(n)) \quad (9)$$

e, para o neurônio j da camada oculta l adota-se a equação (10).

$$\delta_j^{(l)}(n) = \varphi_j'(v_j^{(l)}(n))' \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad (10)$$

em que, a apóstrofe em $\varphi_j'(\cdot)$ representa a diferenciação em relação ao argumento. Realiza-se o ajuste dos pesos da rede na camada l de acordo com a regra delta generalizada equação (11):

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha \left[w_{ji}^{(l)}(n-1) \right] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (11)$$

sendo,

η : é a taxa de aprendizado e α é a constante de momento.

Esse procedimento é executado até que seja satisfeito o critério de parada estabelecido.

De acordo com Haykin (2001) a taxa de aprendizado é uma constante que controla a taxa com que os pesos serão ajustados. Quanto menor for esse parâmetro, menores serão as variações dos pesos da rede, de uma iteração para outra e mais suave será a trajetória no espaço dos pesos, porém isso implica em um treinamento lento. Por outro lado, se a taxa de aprendizado for muito elevada, o treinamento será acelerado com grandes modificações nos pesos o que pode tornar a rede instável.

Ainda conforme o mesmo autor, a constante de momento é um número positivo que ao ser incorporado no algoritmo de retropropagação ou *backpropagation*, proporciona uma pequena modificação na atualização dos pesos. O termo de momento pode evitar que o processo de treinamento da RNA termine em um mínimo local na superfície de erro ao invés do mínimo global que é o objetivo do processo de aprendizagem.

O Levenberg-Marquardt é um algoritmo de retropropagação muito eficiente para o treinamento de RNAs, principalmente quando é necessária alta precisão. A taxa de convergência, a generalização e a precisão do Levenberg-Marquardt são superiores a outros algoritmos, sendo que, menos iterações são necessárias para atingir baixos níveis de erro (NADERPOUR, POURSAEIDI E AHMADI, 2018).

Ainda de acordo com Naderpour, Poursaeidi e Ahmadi (2018), o algoritmo de aprendizagem Levenberg-Marquardt apresenta rápida convergência e é muito eficiente em problemas de aproximação de funções para redes que possuem até algumas centenas de pesos. Essa vantagem é especialmente notável se for necessário um treinamento muito preciso.

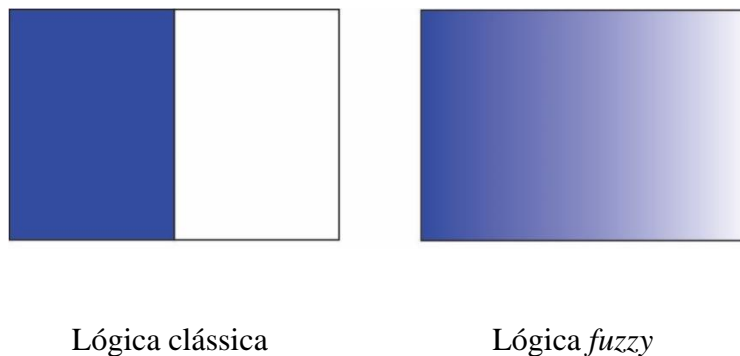
2.3 Lógica *fuzzy*

Inicialmente os conceitos elementares da lógica *fuzzy* foram desenvolvidos por Jan Lukasiewicz em 1920, que apresentou conjuntos com grau de pertinência parcial, tornando possível o tratamento de informações imprecisas. Esse trabalho combinado com a lógica clássica de Aristóteles embasou o trabalho do professor Lotfi Asker Zadeh, precursor da lógica *fuzzy* (RIGNEL; CHENCI E LUCAS, 2011).

Zadeh (1965) publicou um trabalho em que apresentou a lógica *fuzzy* por meio de uma teoria matemática aplicada a conceitos nebulosos ou incertos que assumia a possibilidade de valores variarem além do espectro binário. Dessa maneira, a teoria dos conjuntos clássicos em que um elemento pertence ou não pertence a um determinado conjunto foi modificada por meio da introdução de graus de incerteza, fazendo com que seja possível um elemento pertencer parcialmente a um conjunto.

Um controlador *fuzzy* comporta-se com raciocínio dedutivo, ou seja, os mesmos processos que as pessoas utilizam para inferir conclusões baseadas em informações já conhecidas. Operadores humanos são capazes de controlar processos industriais com características não lineares e comportamento dinâmico por meio da experiência adquirida e inferência de relações entre as variáveis do processo. Um controlador *fuzzy* pode capturar esse conhecimento tornando possível a implementação de um controlador computacional com o mesmo desempenho que o operador humano (SIMÕES E SHAW, 2007).

A lógica *fuzzy* constitui uma metodologia de inteligência computacional capaz de lidar com informações imprecisas usualmente empregadas na comunicação humana. A Figura 9 ilustra uma comparação entre a lógica clássica com fronteiras bem definidas e a lógica *fuzzy* com uma transição gradual.

Figura 9 - Lógica clássica x lógica *fuzzy*

Fonte: O autor

De acordo com Simões e Shaw (2007), a lógica clássica é bivalente, reconhecendo apenas dois valores: sim ou não; 0 ou 1, por outro lado a lógica *fuzzy* é multivalente, sendo capaz de reconhecer uma multitude de valores em que a verdade é uma questão de ponto de vista ou de graduação, atribuindo o grau de veracidade em um intervalo numérico. Sendo assim a lógica *fuzzy* é uma técnica de gerenciamento de incertezas, por meio da expressão de termos com determinado grau de certeza em um intervalo $[0,1]$, onde o valor 1 representa a certeza absoluta.

2.3.1 Conjuntos *fuzzy*

A teoria dos conjuntos *fuzzy* baseia-se no fato de que os conjuntos existentes no mundo real não possuem precisão nos limites. A propriedade fundamental da lógica *fuzzy* é que um elemento pode ser membro parcial de um conjunto, indicado por meio de um valor fracionário dentro do intervalo numérico, sendo que a função $\mu_A(x)$ tem todos os valores dentro do intervalo $[0,1]$. Um conjunto *fuzzy* é, portanto, um agrupamento indefinido e impreciso, onde a transição de pertinência para não pertinência é gradual, não abrupta, sendo que a incerteza de um elemento, ou seja, seu grau fracionário de pertinência, pode ser concebido como uma medida de possibilidade de que determinado elemento seja membro de um conjunto (SIMÕES E SHAW, 2007).

Carneiro (2016), afirmou que na teoria clássica de conjuntos, a pertinência de um elemento a um conjunto é definida por meio de uma função de pertinência f_A , mapeada em um conjunto A de um universo X :

$$f_A(x) = \begin{cases} 1 & \text{se e somente se } x \in A \\ 0 & \text{se e somente se } x \notin A \end{cases} \quad (12)$$

Ainda de acordo com o mesmo autor na extensão para os conjuntos *fuzzy*, a função de pertinência passa a ter maior abrangência, assumindo valores no intervalo $[0,1]$. Um conjunto *fuzzy* A do universo X é definido por meio de uma função de pertinência $\mu_A(x): X \rightarrow [0,1]$ e representado por um par ordenado $A = \{[x, \mu_A(x)] \mid x \in X\}$, em que $\mu_A(x)$ indica o quanto x é compatível com A .


Simões e Shaw (2007) afirmaram que o universo do discurso, matematicamente, corresponde a um conjunto de valores finitos e dessa maneira todo conjunto *fuzzy* seria na realidade sempre um subconjunto. Porém, nas aplicações em engenharia, não faz diferença essa distinção e para simplificar o tratamento é comum a denominação por conjuntos *fuzzy* como universo de discurso contínuo.

A exemplo da teoria clássica de conjuntos, existem operações envolvendo os conjuntos *fuzzy* que utilizam operadores mínimo e máximo. Carneiro (2016) afirmou que dados dois conjuntos *fuzzy* A e B do universo X , utilizando as funções mínimo e máximo, tem-se as seguintes definições para as operações básicas de união, intersecção e complemento:

- União: O conjunto união C de dois conjuntos *fuzzy* A e B , de um mesmo universo X , $C = A \cup B$ é definido como: $\{x \in X: C(x) = \max[\mu_A(x), \mu_B(x)] = \mu_A(x) \cup \mu_B(x)\}$;
- Intersecção: O conjunto intersecção de A e B , sendo ambos conjuntos *fuzzy* pertencentes ao universo X , $D = A \cap B$, é definido como: $\{x \in X: D(x) = \min[\mu_A(x), \mu_B(x)] = \mu_A(x) \cap \mu_B(x)\}$;
- Complemento: O conjunto complemento de A , um conjunto *fuzzy* normalizado, pertencente ao universo X é constituído pela subtração de $\mu_A(x)$ do valor unitário: $\{x \in X: \mu_A'(x) = 1 - \mu_A(x)\}$.

De acordo com Botelho (2012), as operações definidas dessa maneira podem ser consideradas como casos especiais de situações abrangentes de agregação de conjuntos *fuzzy*. A Figura 10 ilustra graficamente as operações de união, intersecção e complemento de conjuntos *fuzzy*.

Figura 10 - Operações com conjuntos *fuzzy*



Fonte: Botelho (2012)

Também é importante citar as propriedades dos conjuntos *fuzzy*, sendo que, de acordo com Simões e Shaw (2007), dado um universo X e três conjuntos *fuzzy* $A \subset X, B \subset X, C \subset X$, as seguintes propriedades são válidas:

Propriedade comutativa: $A \cup B = B \cup A$ $A \cap B = B \cap A$

Propriedade associativa: $(A \cup B) \cup C = A \cup (B \cup C)$ $(A \cap B) \cap C = A \cap (B \cap C)$

Indempotência: $A \cup A = A$ $A \cap A = A$

Distributividade: em relação à intersecção: $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$

Distributividade em relação à união: $A \cap (B \cup C) = (A \cup B) \cap (A \cup C)$

Conjuntos *fuzzy* e o seu complemento (*): $A \cap A' \neq \emptyset$ $A \cup A' \neq E$

Conjunto *fuzzy* e o conjunto nulo: $A \cap \emptyset = \emptyset$ $A \cup \emptyset = A$

Conjuntos *fuzzy* e o conjunto universal: $A \cap X = A$ $A \cup X = E$

Involução: $(A')' = A$

Teorema de Morgan: $(A \cap B)' = A' \cup B'$ $(A \cup B)' = A' \cap B'$

Conforme Simões e Shaw (2007), todas as propriedades aplicáveis a teoria clássica dos conjuntos são aplicáveis também na teoria dos conjuntos *fuzzy*, exceto a propriedade do conjunto *fuzzy* e seu complemento, marcada com (*).

Conforme mencionado anteriormente um conjunto *fuzzy* pode ser representado por uma função de pertinência com base na relação entre os valores dos elementos do conjunto e seus graus de pertinência. Dessa forma, cada conjunto *fuzzy* é definido por uma função de pertinência, dentre as quais destaca-se a triangular, trapezoidal e gaussiana.

Botelho (2012) apresentou as formas básicas e a representação gráfica das funções triangular, trapezoidal e gaussiana (Figura 11):

- Função triangular (equação 13):

$$\mu_A(x) = \begin{cases} 0; & \text{se } x \leq a \\ \frac{x-a}{b-a}; & \text{se } x \in [a, b] \\ \frac{c-x}{c-b}; & \text{se } x \in [b, c] \\ 0; & \text{se } x \geq c \end{cases} \quad (13)$$


- Função trapezoidal (equação 14):

$$\mu_A(x) = \begin{cases} 0; & \text{se } x \leq a \\ \frac{x-a}{b-a}; & \text{se } x \in [a, b] \\ 1; & \text{se } x \in [b, c] \\ \frac{d-x}{d-c}; & \text{se } x \in [c, d] \\ 0; & \text{se } x \geq d \end{cases} \quad (14)$$

- Função gaussiana (equação 15):

$$\mu_A(x) = \{e^{-\theta(x-m)^2}; \text{se } \theta > 0 \quad (15)$$

Figura 11 - Funções de pertinência



Fonte: Botelho (2012)

De acordo com Simões e Shaw (2007), para a resolução de um problema, o formato e a quantidade de funções em um universo de discurso são determinados com base na experiência, na natureza do processo a ser controlado ou na entrevista com um operador humano especializado. Dessa maneira, não é uma tarefa trivial e pode sofrer ajustes de acordo com os resultados observados.

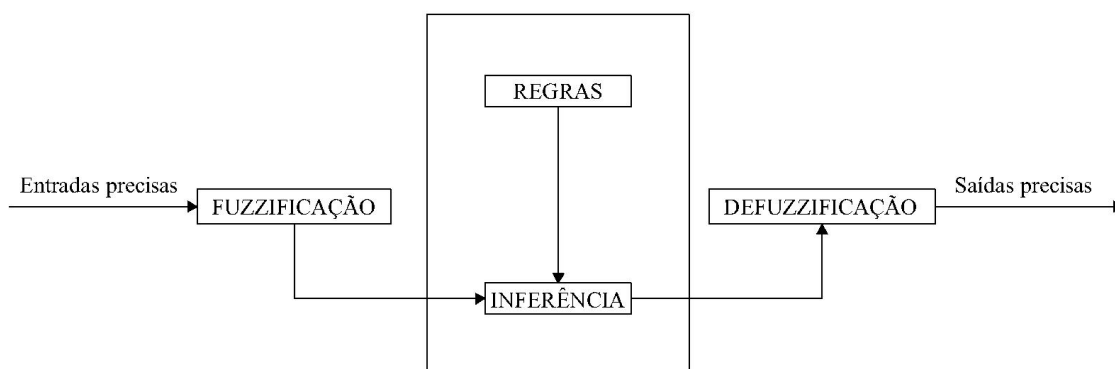
2.3.2 Sistemas *fuzzy*

Silva (2011) discorreu que no mundo real as ações humanas controlam diversos sistemas através de informações imprecisas, em que cada pessoa recebe dados que são interpretados a partir de seus parâmetros pessoais e então se toma uma decisão. A execução das tarefas, as decisões e o controle seguem uma sequência de ordens linguísticas, traduzidas por um conjunto de regras, capazes de serem decodificadas pelo controlador humano. Os sistemas *fuzzy* ou controladores *fuzzy* são uma técnica de inteligência computacional que tenta reproduzir a estratégia humana na execução de tarefas e tomada de decisão para produzir saídas para cada entrada *fuzzy*.

Simões e Shaw (2007) relataram que um sistema *fuzzy* é composto basicamente pela seguinte estrutura:

- Interface de fuzzificação;
- Base de conhecimento;
- Lógica de tomada de decisões;
- Interface de defuzzificação;

Essa estrutura representa a transformação que ocorre do domínio do mundo real, para o domínio *fuzzy*. Nessa transformação é usado um conjunto de inferências *fuzzy* para tomada de decisão e posteriormente ocorre a transformação inversa, para que ocorra o acoplamento entre a saída do algoritmo *fuzzy* e as variáveis de atuação (SIMÕES E SHAW, 2007). A Figura 12 ilustra a estrutura de um sistema *fuzzy* típico.

Figura 12 - Sistema *fuzzy*

Fonte: O autor

Moreira (2020) afirmou que o processo de fuzzificação consiste na conversão dos dados oriundos de observação ou experimentos, expressos em valores numéricos, para linguístico, ou seja, transformar aspectos quantitativos da entrada precisa em aspectos qualitativos. São elementos típicos nestes sistemas termos como alto, médio e baixo. Cada conjunto *fuzzy* expresso por uma variável linguística é definido por uma função de pertinência.

Em um universo U , a variável linguística X é aquela em que os valores são conjuntos *fuzzy* que correspondem a termos linguísticos. Simplificando é possível dizer que uma variável linguística é um substantivo e seus valores são adjetivos. O termo temperatura, por exemplo, pode ser utilizado como uma variável linguística que assume os atributos frio, agradável ou quente (CORCOLL-SPINA, 2010).

O comportamento de um sistema *fuzzy* é definido por um conjunto de regras que devem ser elaboradas por profissionais especialistas com amplo conhecimento do problema/fenômeno a ser modelado. As regras elaboradas são do modelo “Se – Então” e representam o processo que determina o conjunto de saída e devem ser em quantidade suficiente para considerar todas as possíveis combinações entre entradas e saídas (MOREIRA, 2020).

Ainda de acordo com o mesmo autor, no processo de inferência, que define a forma operacional do sistema *fuzzy*, o conjunto de regras é utilizado na transformação dos valores de entrada em saída. Basicamente os métodos de inferência mais utilizados são o Mandami e o Takagi-Sugeno-Kang (MOREIRA, 2020).

Por fim a defuzzificação consiste na conversão da saída dada pelo processo de inferência, que é um conjunto *fuzzy*, em um conjunto clássico ou número real. Existem diversos métodos de defuzzificação, dentre os quais destaca-se o centróide, centro dos máximos e a média dos máximos (CORCOLL-SPINA, 2010).

O defuzzificador centróide é o mais utilizado e consiste na determinação dos centros das áreas de todas as figuras representadas pelos conjuntos de saída. O método do centro dos máximos é considerado um procedimento radical em que são considerados apenas as regiões de maior possibilidade entre todos os possíveis valores da variável que modela conceito *fuzzy* em questão. A média dos máximos é um método de defuzzificação em que se obtém um valor que representa a média dos valores centrais do conjunto de saída (CORCOLL-SPINA, 2010).

2.3.3 Métodos de Inferência: Mamdani e Sugeno

Moreira (2020) afirmou que no método de inferência de Mamdani a construção das regras é dada pela superposição dos consequentes de regras individuais do tipo: Regra y : Se x é A_y então z é B_y , em que $y = 1, 2, \dots, n$. Sendo que, n é o número de regras, x é a variável linguística de entrada, z é a variável linguística de saída e A_y e B_y correspondem a conjuntos *fuzzy* dos universos de discurso U e V , respectivamente.

Ainda de acordo com Moreira (2020), a equação (16) representa a execução do método de Mamdani:


$$\begin{aligned}
 & Se(X_1 \text{ é } a_{1,1}) e (X_2 \text{ é } a_{1,2}) e \dots e(X_n \text{ é } a_{1,n}) \text{ então } (Y \text{ é } d_1)(W_1) \\
 & Se(X_1 \text{ é } a_{2,1}) e (X_2 \text{ é } a_{2,2}) e \dots e(X_n \text{ é } a_{2,n}) \text{ então } (Y \text{ é } d_2)(W_2) \\
 & Se(X_1 \text{ é } a_{m,1}) e (X_2 \text{ é } a_{m,2}) e \dots e(X_n \text{ é } a_{m,n}) \text{ então } (Y \text{ é } d_m)(W_m)
 \end{aligned} \tag{16}$$

O conjunto selecionado na etapa de inferência depende do operador de composição “e” (S-norma), no qual se seleciona o conjunto com maior valor de pertinência, ou “ou” (T-norma) em que se seleciona o conjunto de menor valor de pertinência (MOREIRA, 2020).

Um sistema *fuzzy* de inferência Mamdani é ilustrado nas Figuras 13 e 14, na qual a saída real z é gerada a partir das entradas x e y reais e regra de composição max-min,


sendo a saída $z \in \mathbb{R}$ obtida através da defuzzificação da saída fuzzy $C = C_1 \cup C_2$ (SILVA, 2011).

Figura 13 - Saídas parciais, inferência Mamdani



Fonte: Silva (2011)

Figura 14 - Saída final, inferência Mamdani



Fonte: Silva (2011)

De acordo com Moreira (2020) o método de inferência Takagi-Sugeno-Kang, ou simplesmente Sugeno se trata de uma simplificação do método de inferência de Mamdani, em que o consequente das regras é uma função das variáveis linguísticas de entrada. Nesse método as regras também são do tipo “Se-Então”, em que o consequente pode ser tanto uma função linear como uma constante, conforme ilustrado na equação (17):

$$\text{Se } X_1 \text{ é } A_{1i} \text{ e } X_2 \text{ é } A_{2i} \text{ e } \dots \text{ e } x_n \text{ é } A_{ni}, \text{ Então } y = f_i(X_1, X_2, \dots, X_n) \quad (17)$$

Sendo que $A_{1i}, A_{2i}, \dots, A_{ni}$ correspondem a conjuntos *fuzzy* dos antecedentes, sendo o conseqüente uma função das variáveis de entrada, podendo ser constante ou linear, que será definida de acordo com os requisitos do projeto. Se for constante a saída será um valor fixo, não dinâmico e se for linear será uma função de primeiro grau (MOREIRA, 2020).

Moreira (2020) afirmou que para uma entrada (X_1, X_2, \dots, X_n) , a saída com número k de regras do tipo “Se-Então” corresponde a média ponderada das funções de pertinência acionadas pelo antecedente podendo ser expressa pela equação (18):

$$y = \frac{\sum_{i=1}^k w_i \cdot f_i(x_1, x_2, \dots, x_n)}{\sum_{i=1}^k w_i} \quad (18)$$

Barros e Bassanezi (2006) apresenta um exemplo de sistema *fuzzy* com duas entradas e uma saída em que os conjuntos *fuzzy* envolvidos, A_{ij} , são números *fuzzy* triangulares e as saídas das regras são funções g_i , lineares afins. A Figura 15 ilustra graficamente, para cada par de entrada x_0 e y_0 , a saída que representa o controle adotado para as entradas. A base de regras deste exemplo é expressa por:

R1: "Se x é A_{11} e y é A_{12} então u é $u_1 = g_1(x, y) = a_1x + b_1y + c_1$ "


ou

R2: "Se x é A_{21} e y é A_{22} então u é $u_2 = g_2(x, y) = a_2x + b_2y + c_2$ "

O sistema *fuzzy* exemplificado é dado pela equação (19):

$$u = \frac{w_1 u_1 + w_2 u_2}{w_1 + w_2} = \frac{w_1 g_1(x_0, y_0) + w_2 g_2(x_0, y_0)}{w_1 + w_2} \quad (19)$$

Figura 15 - Saída do sistema *fuzzy* com inferência Sugeno para o exemplo dado



Fonte: Barros e Bassanezi (2006)

O consequente *fuzzy* com inferência Sugeno, possui saída dinâmica dada por funções em que a complexidade depende da região de saída. No caso de saída trivial utiliza-se funções simples, reduzindo o número de regras, porém caso seja necessário representar uma não-linearidade, são utilizadas funções mais complexas e um maior número de regras. Nesse método de inferência é utilizado o conceito de linearidade ou não-linearidade local, desse modo o método de inferência de Sugeno pode aproximar um sistema não linear através de uma combinação de vários sistemas lineares, por meio da decomposição do espaço de entrada em vários espaços parciais (MOREIRA, 2020).

Ainda de acordo com o mesmo autor o método de Sugeno apresenta algumas vantagens em relação ao método de Mamdani, dentre as quais destaca-se a maior eficiência computacional, a capacidade de trabalhar com técnicas adaptativas, facilidade maior para realização de análises matemáticas, possibilidade de trabalhar com sistemas não lineares por meio da linearidade local.

2.4 Trabalhos correlatos

As Redes Neurais Artificiais e os sistemas *fuzzy* têm sido aplicadas em diversos segmentos da indústria da construção civil, contribuindo para o avanço da industrialização desse setor, que ainda é caracterizado predominantemente por trabalhos artesanais com pouca ou nenhuma automatização.

Sitton, Zeinali e Story (2017), realizaram a classificação de solos para uso na produção de blocos ecológicos para alvenaria, utilizando RNAs. O desempenho dos blocos depende da qualidade do solo usado e essa análise pode ser demorada e demanda equipamentos laboratoriais caros e que não se mostram acessíveis em campo. Desta forma, foi proposto um modelo para realizar essa classificação rapidamente, com base em dados qualitativos e quantitativos do solo em campo, o que se mostrou muito útil ao reduzir os custos e tornar mais ágil o processo de classificação. A precisão média das classificações de solo da RNA foi de 89,35%.

Hamdia, Arafa e Alqedra (2018), apresentaram um modelo de avaliação baseado em lógica *fuzzy* que estima a importância dos critérios de avaliação de danos estruturais em edifícios de concreto armado. Os critérios de avaliação são baseados em inspeções visuais e inspeções simples, sem a necessidade de realização de ensaios complexos e de longo prazo, incluindo histórico da edificação, capacidade estrutural, condições ambientais, além da durabilidade. O modelo proposto mostrou que o critério de avaliação com maior importância é a capacidade estrutural com fator de ponderação de 50,1%, seguido pela durabilidade com fator de ponderação de 22,5%.

Bre, Gimenez e Fachinotti (2018), aplicaram RNAs na predição de coeficientes de pressão de ventos em edifícios. A análise da força exercida pelo vento é de suma importância para o projeto estrutural de edificações altas, uma vez que a carga crítica pode ser a força lateral exercida pelo vento e não o peso da estrutura. Os resultados da pesquisa se mostraram satisfatórios, sendo possível observar valores de R^2 da ordem de 0,9990 a 0,9996.

Zehtabchi, Hashemi e Asadi (2018), utilizaram um sistema *fuzzy* com inferência Mamdani para predição da resistência a compressão de corpos de prova do asfalto em diferentes cenários, incluindo a porcentagem ótima de betume, adição de betume modificado com polímero granular e utilizando diferentes porcentagens de partículas

fraturadas. Os resultados foram comparados com os experimentos laboratoriais, sendo possível constatar um coeficiente de correlação R^2 de 0,9488, comprovando a viabilidade da implementação de lógica *fuzzy* na predição da resistência a compressão de misturas asfálticas.

Moura, Queiroz e Farias (2018) compararam a solução da equação diferencial da viga utilizando o método das diferenças finitas e RNAs para obtenção da deflexão, momento fletor e esforço cortante. Os resultados mostraram que as soluções foram estatisticamente semelhantes. Para pontos, na curva de deflexão, que não pertencem ao conjunto de treinamento, basta realizar produtos matriciais com os pesos sinápticos da RNA. A rede proposta possui apenas uma camada escondida com 20 neurônios artificiais com função de ativação sigmoide. O desvio na aproximação por redes neurais artificiais é de aproximadamente 10^{-5} .

Biezma, Agudo e Barron (2018) implementaram um sistema baseado em lógica *fuzzy* combinado com dados de inspeção *in-situ* para predição da taxa de corrosão externa de tubulações de oleodutos e gasodutos. O sistema proposto determina a taxa de corrosão com base na combinação de parâmetros das características do solo e uma quantidade reduzida dados de taxas de corrosão, fornecendo um procedimento relativamente fácil de ser utilizado, reduzindo custos de inspeção, uma vez que se torna necessário um menor número de inspeções *in-situ*. Foi obtido R^2 de 0,9985 na predição da taxa de corrosão.

Staniek e Czech (2018), realizaram o diagnóstico de patologias em pavimentos de rodovias utilizando RNAs e validaram o modelo proposto em uma rodovia com tráfego intenso, o que confirmou a eficácia do modelo computacional proposto. O sistema apresentou precisão da ordem de 88,4% no diagnóstico.

Ning et al. (2016), desenvolveram um modelo para o planejamento do *layout* do canteiro de obras de grandes empreendimentos baseado em lógica *fuzzy*. O sistema proposto mostrou ser uma ferramenta útil para tomada de decisão na seleção do *layout* para o canteiro de obras mais eficaz.

D'Amico et al. (2019), desenvolveram um estudo sobre o equilíbrio energético e ambiental de edifícios utilizando RNAs que se mostraram bastante eficientes para auxiliar na tomada de decisões mais sustentáveis no que diz respeito a demanda energética das

edificações. Os valores de R^2 obtidos variaram de 0,9993 (RNA menos eficiente) a 0,9999 (RNA mais eficiente).

Allali, Abed e Mebarki (2018) realizaram a avaliação pós-terremoto de danos estruturais em edifícios utilizando um sistema *fuzzy*. Foram consideradas dados de 27.000 edifícios para realização dos ajustes no sistema, sendo necessário um pequeno número de regras para obtenção de alto desempenho do modelo proposto. A previsão teórica obtido pelo sistema inteligente é comparada com os danos observados pelos inspetores. Os resultados apresentaram 90% de confiabilidade no sistema proposto.

Zhong et al. (2019), realizaram a classificação automática de queixas sobre problemas apresentados por edificações após serem finalizadas pelas respectivas construtoras, utilizando RNAs, com o intuito de melhorar a qualidade das edificações e facilitar na escolha da melhor solução para as patologias apresentadas nas construções.

Sellitto et al. (2018) desenvolveram um sistema baseado em lógica *fuzzy* para controle contínuo de processos em fábricas de cimento como intuito de controlar as operações de moagem. O sistema é baseado em variáveis linguísticas, emulando o julgamento de um controlador humano que se baseia em informações incompletas. A implantação do sistema proposto resultou em ganhos de produtividade e redução da ordem de 3% a 5% no consumo energético.

3 CONSIDERAÇÕES GERAIS

A resistência a compressão axial do concreto é a principal propriedade físico-mecânica deste material utilizada no dimensionamento estrutural e é obtida por meio da realização da tarefa de dosagem que consiste na quantificação das proporções dos materiais constituintes. Os métodos de dosagem se baseiam em ensaios experimentais, pois não existe um procedimento matemático bem definido para obtenção do traço, principalmente devido a heterogeneidade do concreto.

A utilização de técnicas de inteligência computacional, como as redes neurais artificiais e sistemas *fuzzy*, pode contribuir para que seja possível prever com agilidade o comportamento mecânico do material concreto, no que diz respeito a resistência à compressão axial, caso algum dos materiais constituintes fossem substituídos ou tivessem suas proporções levemente alteradas no canteiro de obras por motivos diversos. A aplicação dessa tecnologia na construção civil torna mais ágil o processo de tomada de decisão, evitando a necessidade de realização de uma nova dosagem experimental em laboratório, confecção de corpos de prova e ruptura após 28 dias de cura.

4 REFERÊNCIAS BIBLIOGRÁFICAS

ALLALI, S. A.; ABED, M.; MEBARKI, A. Post-earthquake assessment of buildings damage using fuzzy logic. **Engineering Structures**, v. 166, n. July, p. 117-127, 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 11768**: Aditivos químicos para concreto de cimento Portland - Requisitos. Rio de Janeiro, 2019.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7211**: Agregados para concreto - Especificação. Rio de Janeiro, 2019.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR NM 248**: Agregados - Determinação da composição granulométrica. Rio de Janeiro, 2003.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 16697**: Cimento Portland - Requisitos. Rio de Janeiro, 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5738**: Concreto - Procedimento para moldagem e cura de corpos de prova. Rio de Janeiro, 2015.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5739**: Concreto – Ensaio de compressão de corpos de prova cilíndricos. Rio de Janeiro, 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7215**: Cimento Portland – Determinação da resistência à compressão de corpos de prova cilíndricos. Rio de Janeiro, 2019.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15775-1**: Edificações habitacionais – Desempenho Parte 1: Requisitos gerais. Rio de Janeiro, 2013.

BARROS, L. C.; BASSANEZI, R. C. **Tópicos de Lógica Fuzzy e Biomatemática**. Campinas: UNICAMP/IMECC, 2006.

BAS, E.; USLU, V. R.; EGRIOGLU, E. Robust learning algorithm for multiplicative neuron model artificial neural networks. **Expert Systems with Applications**, v. 56, p. 80–88, 2016.

BAUER, L. A. F. **Materiais de Construção**: Novos materiais para construção civil. 5. ed. Rio de Janeiro: Editora LTC, 2014.

BIEZMA, M. V.; AGUDO, D.; BARRON, G. A Fuzzy Logic method: Predicting pipeline external corrosion rate. **International Journal of Pressure Vessels and Piping**, v. 163, n. June, p. 55-62, 2018.

BOTELHO, T. G. **Uma Nova Proposta para Implementação Computacional do Princípio de Extensão de Zadeh**. 2012. 78 f. Dissertação (Mestrado em Engenharia de

Sistemas e Automação) – Departamento de engenharia, Universidade Federal de Lavras, Lavras – MG.

BRAGA, A. de P.; CARVALHO, A. C. P. de L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000. 262 p.

BRE, F.; GIMENEZ, J. M.; FACHINOTTI, V. D. Prediction of wind pressure coefficients on building surfaces using artificial neural networks. **Energy and Buildings**, v. 158, p. 1429–1441, 2018.

CARNEIRO, A. R. T. **Lógica Fuzzy na Recomendação de Cultivares de Feijoeiro Comum Quanto à Adaptabilidade e Estabilidade**. 2016. 125 f. Dissertação (Mestrado em Produção Vegetal) – Instituto de ciências agrárias, Universidade Federal de Minas Gerais, Montes Claros – MG.

CORCOLL-SPINA, C. O. **Lógica fuzzy: reflexões que contribuem para a questão da subjetividade na construção do conhecimento matemático**. 2010. 165 f. Tese (Doutorado em Educação) – Faculdade de Educação, Universidade de São Paulo, São Paulo – SP.

D'AMICO, A. et al. Artificial Neural Networks to assess energy and environmental performance of buildings: An Italian case study. **Journal of Cleaner Production**, v. 239, p. 117993, 2019.

DOGAN, G.; ARSLAN, M. H.; CEYLAN, M. Concrete compressive strength detection using image processing based new test method. Measurement: **Journal of the International Measurement Confederation**, v. 109, p. 137–148, 2017.

FREITAS, L. P. S. **Discriminação entre pacientes normais e hemiplégicos utilizando plataforma de força e redes neurais**. 2011. 84 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira – SP.

GOLAFSHANI, E. M.; BEHNOOD, A. Application of soft computing methods for predicting the elastic modulus of recycled aggregate concrete. **Journal of Cleaner Production**, v. 176, p. 1163–1176, 2018.

HAMDIA, K. M.; ARAFA, M.; ALQEDRA, M. Structural damage assessment criteria for reinforced concrete buildings by using a Fuzzy Analytic Hierarchy Process. **Underground Space**, v. 3, n. September, p. 243-249, 2018.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. Ed. Porto Alegre: Editora Bookman, 2001.

HEBB, D. O. **The organization of behavior: A neuropsychological theory**. New York: Editora John Wiley And Sons inc., 1949.

HELENE, P.; TERZIAN, P. **Manual de Dosagem e Controle do Concreto**. 1. ed. São Paulo: Editora PINI, 1993.

ISAAC JÚNIOR, M. A. **Modelo misto e rede neural artificial para estimativas dendométricas de árvores individuais**. 2018. 82 f. Tese (Doutorado em Engenharia Florestal) - Departamento de ciências florestais, Universidade Federal de Lavras, Lavras – MG.

KHADEMI, F. et al. Predicting strength of recycled aggregate concrete using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and Multiple Linear Regression. **International Journal of Sustainable Built Environment**, v. 5, n. 2, p. 355–369, 2016.

McCULLOCH, W. S; PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v.5, p. 115-133, 1943.

MOREIRA, H. A. M. **Controle Neuro-Fuzzy para Eficiência Energética de Sistemas de Abastecimento de Água com Demanda Variável**. 2020. 106 f. Dissertação (Mestrado em Engenharia Mecânica) – Centro de Tecnologia, Universidade Federal da Paraíba, João Pessoa – PB.

MORETTI, J. F. et al. Prediction of modulus of elasticity and compressive strength of concrete specimens by means of artificial neural networks. **Acta Scientiarum. Technology**, v. 38, n. 1, p. 65, 2016.

MOURA, H. B. S.; QUEIROZ, K. F. R.; FARIAS, V. J da. C. Solução da equação diferencial da viga usando diferenças finita e redes neurais artificiais. **XXXVIII CNMAC. Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 6, n. 2, 2018.

NADERPOUR, H.; POURSAEIDI, O.; AHMADI, M. Shear resistance prediction of concrete beams reinforced by FRP bars using artificial neural networks. **Measurement: Journal of the International Measurement Confederation**, v. 126, p. 299–308, 2018.

NING, X. et al. A multi-attribute model for construction site layout using intuitionistic fuzzy logic. **Automation in Construction**, v. 72, n. December, p. 380-387, 2016.

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.

RECENA, F. A. P. **Retração do concreto**. Porto Alegre: EDIPUCRS, 2014.

RIGNEL, D. G. S.; CHENCI, G. P.; LUCAS, C. A. Uma introdução a Lógica *Fuzzy*. **Revista Eletrônica de Sistemas de Informação e Gestão Tecnológica**, v. 01, p. 17-28, 2011.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6., 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. La Jolla: Institute for Cognitive Science-University of California, 49 p., 1985.

SELLITTO, M. A. et al. A Fuzzy Logic Control application to the Cement Industry. **IFAC-PapersOnLine**, v. 51, p. 1542-1547, 2018.

SIDDIQUE, R.; AGGARWAL, P.; AGGARWAL, Y. Prediction of compressive strength of self-compacting concrete containing bottom ash using artificial neural networks. **Advances in Engineering Software**, v. 42, n. 10, p. 780–786, 2011.

SILVA, F. F. B. **Desvendando a Lógica Fuzzy**. 2011. 129 f. Dissertação (Mestrado em Matemática) – Universidade Federal de Uberlândia, Uberlândia – MG.

SIMÕES, M. G.; SHAW, I. S. **Controle e Modelagem Fuzzy**. 2. ed. São Paulo: Editora Blucher-Fapesp, 2007.

SITTON, J. D.; ZEINALI, Y.; STORY, B. A. Rapid soil classification using artificial neural networks for use in constructing compressed earth blocks. **Construction and Building Materials**, v. 138, p. 214–221, 2017.

STANIEK, M.; CZECH, P. Self-correcting neural network in road pavement diagnostics. **Automation in Construction**, v. 96, n. February, p. 75–87, 2018.

VAZIRIZADE, S. M.; NOZHATI, S.; ZADEH, M. A. Seismic reliability assessment of structures using artificial neural network. **Journal of Building Engineering**, v. 11, n. November 2016, p. 230–235, 2017.

WIDROW, B.; HOFF, M. E. **Adaptative switching circuits**. Ire Convention Record, p. 96-104, 1960.

ZADEH, L. A. Fuzzy sets. **Information and control**, v. 8, n. 3, p. 338-353, 1965.

ZEHTABCHI, A.; HASHEMI, S. A. H. H.; ASADI, S. Predicting the strength of polymer-modified thin-layer asphalt with fuzzy logic. **Construction and Building Materials**, v. 169, n. April, p. 826-834, 2018.

ZHONG, B. et al. Convolutional neural network: Deep learning-based classification of building quality problems. **Advanced Engineering Informatics**, v. 40, n. February, p. 46–57, 2019.

SEGUNDA PARTE - ARTIGOS**ARTIGO 1**

Artigo publicado na Revista Científica “Brazilian Journal of Development”.

DOI: <http://dx.doi.org/10.34117/bjdv6n7-050>

Use of artificial neural networks to predict concrete compression strength**Uso de redes neurais artificiais na predição da resistência à compressão do concreto**

Dennis Santos Tavares
David Augusto Ribeiro
Tadayuki Yanagi Junior
Wilian Soares Lacerda
Eduardo Tadeu Tiradentes
Robson Guilherme Teixeira

ABSTRACT: Concrete is one of the most widely used building materials, being composed of different components with different properties, which makes the task of dosing and strength determination complex. Artificial Neural Networks is a tool that has the ability to generalize and learn from previous experiences that are provided by a previously built database. This work aims the implementation of RNA in determining the compressive strength of concrete of various ages. The input data is the material quantities and the output is the compressive strength. The results obtained are satisfactory and promising from the point of view of civil engineering

Keywords: Concrete, Compressive strength, Artificial neural networks.

RESUMO: O concreto é um dos materiais de construção civil mais utilizados, sendo composto de diferentes componentes com diversas propriedades, o que torna a tarefa de dosagem e determinação da resistência complexas. As Redes Neurais Artificiais (RNA) são ferramentas que possuem a capacidade de generalização e aprendizado a partir de experiências anteriores que são fornecidas por um banco de dados previamente construído. Este trabalho tem como objetivo a implementação de RNA na determinação da resistência a compressão do concreto de várias idades. Os dados de entrada são as quantidades dos materiais e a saída é a resistência à compressão. Os resultados obtidos se mostraram satisfatórios e promissores do ponto de vista da engenharia civil.

Palavras-chave: Concreto, Resistência à compressão, Redes Neurais Artificiais.

1. INTRODUCTION

Concrete is a structural material used in the construction of houses, buildings, stadiums, bridges, viaducts, tunnels, containment structures, power generation plants, ports, airports, among other works of fundamental importance for the good functioning of society, the that makes this material one of the most important and used by humanity.

Concrete is characterized by heterogeneity due to the fact that it is composed by the union of several components. Basically, it is composed of Portland cement, which together with water acts as a binder for aggregates that are subdivided into coarse aggregates (gravel) and fine aggregates (sand).

Moretti (2010) stated that the concrete is heterogeneous and that the mathematical description of this material falls into non-linearity. Its behavior is sensitive to several factors and the generalization and scope of the dosage methods and determination of the compressive strength of this material is difficult. This task falls on previous laboratory experiments that take into account the type of cement and the technical characteristics of the aggregates used. In routine practice, regional materials are used and their successive experiments are conditioned to very representative diagrams. Eventually, new chemical elements and additives are added to the mixture, which enhance their properties both in the fresh and in the hardened state and do not compromise the accuracy of the diagrams commonly used for dosing and predicting the compressive strength of the material.

Colombo et al. (2013) stated that the durability of concrete is a fundamental factor, considering that it depends on the mixture of the components, the consistency, the slump and the curing time. In this mixture, it is necessary for the paste composed of Portland cement and water to present good hydration to obtain an increase in durability.

Younis and Pilakoutas (2013) reported that it is important for concrete to contain coarse porous aggregates to house fine particles, which improves their packaging when filling empty spaces. It is important to pay attention to the material's microstructure, in view of the fact that small aggregates harbor greater water absorption when compared to coarse aggregates. This, when in contact with the mortar cement particles, results in more dense and beneficial structures the diffusion of fine cement grains with the outermost layers of the coarse aggregates.

There are several methods for dosing concrete as well as for determining its resistance to compression according to the constituent materials, among which one can mention the one proposed by the American Concrete Institute (ACI) and that of the Brazilian Portland Cement Association (ABCP). Despite the existence of so many methods, none of them can provide a trace (proportion of materials) that does not require experimental adjustment. After obtaining the proportion of the materials that make up the concrete, it is necessary to prepare an experimental mixture and perform its compression test to verify that the desired properties have been achieved, and some corrections in the proportion of the mixture are normally necessary (OLIVEIRA et al. (2007)).

The basic principle of operation of an artificial neuron is illustrated by Figure 1 and begins with the presentation of the standardized inputs that are multiplied by their respective weights, in addition to the bias that is an input, always +1 value which is also multiplied by your weight. The results of these operations are summed up and later undergo a function called activation, which introduces non-linearity and provides the neuron's output.

An artificial neural network is composed of several units (artificial neurons) that perform a single simple processing, but the set of units that form the network is capable of solving complex problems. Its use for determining the mix strength and compressive strength of concrete can be very promising. ANNs are widely used in several areas of science, including engineering, in view of their ability to learn from previous experiences and generate solutions for new samples of a given problem.




Figure 1 - Artificial neuron.

Using the ability to generalize the ANN, using a pre-existing database that is adequate and consistent with the problem, it is possible to solve complex and non-linear problems such as the dosage of concrete with acceptable errors (AKPINAR et al .; BEHNOOD et al .; NIKBIN et al, 2017; ACUÑA et al., 2014).

Arora, Singh and Bhardwaj (2019), in addition to implementing RNA in determining the strength of recycled concrete, made a comparison with Random Forests, which is a learning machine algorithm. The ANN, proposed by him, proved to be a little more efficient than the other technique studied.

For self-compacting concretes, there are studies that implement RNA, both for traditional selfcompacting mixtures, and for others that used fly ash, ash from industrial waste incineration and silica fume to partially replace cement in concrete. These researches obtained excellent results with the implementation of RNA to capture non-linear interactions between the various parameters that are added in self-compacting concrete and are not present in conventional concretes, which further raises the dosage task (BEHNOOD et al., 2018; YAMAN et al., 2017; SIDDIQUE et al., 2011).

The objective of the present work is to verify several models and arrive at an artificial neural network that is capable of presenting the compressive strength of the concrete with the least possible error, based on the input data that are the constituent materials of the concrete at different ages. of cure. A database obtained from the existing literature was used to implement the RNA technique in predicting the compressive strength of concrete.

2. MATERIAL AND METHODS

The data used by I-Cheng Yeh (1998) are composed of 1030 concrete mix samples and their respective compressive strengths, between 2 and 80 MPa, at the most varied curing ages at which the specimens were broken, varying from 3 to 365 days.

To determine the compressive strength, the following quantitative input data were used to make 1 m³ of concrete:

- Cement (kg/m³);
- Water (kg/m³);
- Coarse aggregate (kg/m³);
- Fine aggregate (kg/m³);
- Blast furnace slag (kg/m³);
- Fly ash (kg/m³);
- Plasticizer additive (kg/m³);
- Age of concrete (days).

The quantitative output value to be achieved through these inputs is the concrete's resistance to compression in MPa (Mega Pascal) shown in Table 1 used in this work.

Table 1 - Examples of samples from the database

Cement (kg/m³)	Blast furnace slag (kg/m³)	Fly ash (kg/m³)	Water (kg/m³)	Plasticizer additive (kg/m³)	Coarse aggregate (kg/m³)	Fine aggregate (kg/m³)	Days	Resistance (MPa)
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

For the training, testing and validation of the ANN, the nftool toolbox of the MATLAB® software, version R 2011 b, developed by MATHWORKS®, was used.

Some architecture of feedforward networks with 1 and 2 hidden layers were tested, in addition to the variation in the number of artificial neurons. For the network of a hidden layer, 8 to 18 neurons were varied in the hidden layer and for neural network with 2 hidden layers, the number of neurons was varied between 8 and 18 for the first layer and between 5 and 15 in the second layer. The number of layers and neurons were

defined by trial and error, but the starting point was based on the works developed by Oliveira et al (2007) and Getahun et al. (2018).

For training the artificial neural network, the Levenberg-Marquardt backpropagation algorithm, which is the default of the nftool toolbox, was used. This algorithm has a higher computational cost to the detriment of others available in the toolbox, but has excellent results.

The data were divided into 70% for training the neural network, 15% for testing and 15% for validation, configurations also belonging to the software default.

The error metric used was the MSE (Mean Squared Error) which is the mean square error, with smaller values being better and for a zero value MSE it means that there is no error.

The parameter R was also used, which is a coefficient that indicates the correlation between the obtained output and the desired output for the problem in question.

The training is interrupted at the exact moment when the ability to generalize the neural network stops improving, a moment evidenced by an increase in the mean square error of the samples used for validation.

Basically the experimental procedure started with the import of the input and output data properly formatted for the working environment of the software used. Then, the nftool toolbox was accessed and the imported data was added, in addition to defining the percentages of the data that would be used for training, validation and testing. Then, to determine the number of neurons, initially 10 was used, which is the default, for later modification in the script, considering that it is not possible to make this modification in the environment of the nftool toolbox. Then the training algorithm was defined. Finally, the artificial neural network created was trained and tested to extract the results. The experiment was repeated 10 times. Regarding the number of repetitions practiced, this amount is enough to have confidence that the training of the ANN was not by mere luck in the drawing of the initial weights of ANN training, this amount being considered as reliable for this experiment.

3. RESULTS AND DISCUSSION

The choice of the best architecture for artificial neural networks is of paramount importance for the modeling of a network that best suits the problem in question. There are no precise and clear guidelines for determining the architecture, which is usually chosen based on the experience of the network designer or by trial and error. After many attempts, the artificial neural network chosen was a network with two hidden layers, the first consisting of 15 neurons and the second comprising 10 neurons. Figure 2 illustrates the architecture of the chosen ANN, in which the entries are presented in small red rectangles, the artificial neurons of the hidden layers that are expressed by blue circles and the output of the network, presented by a green circle.

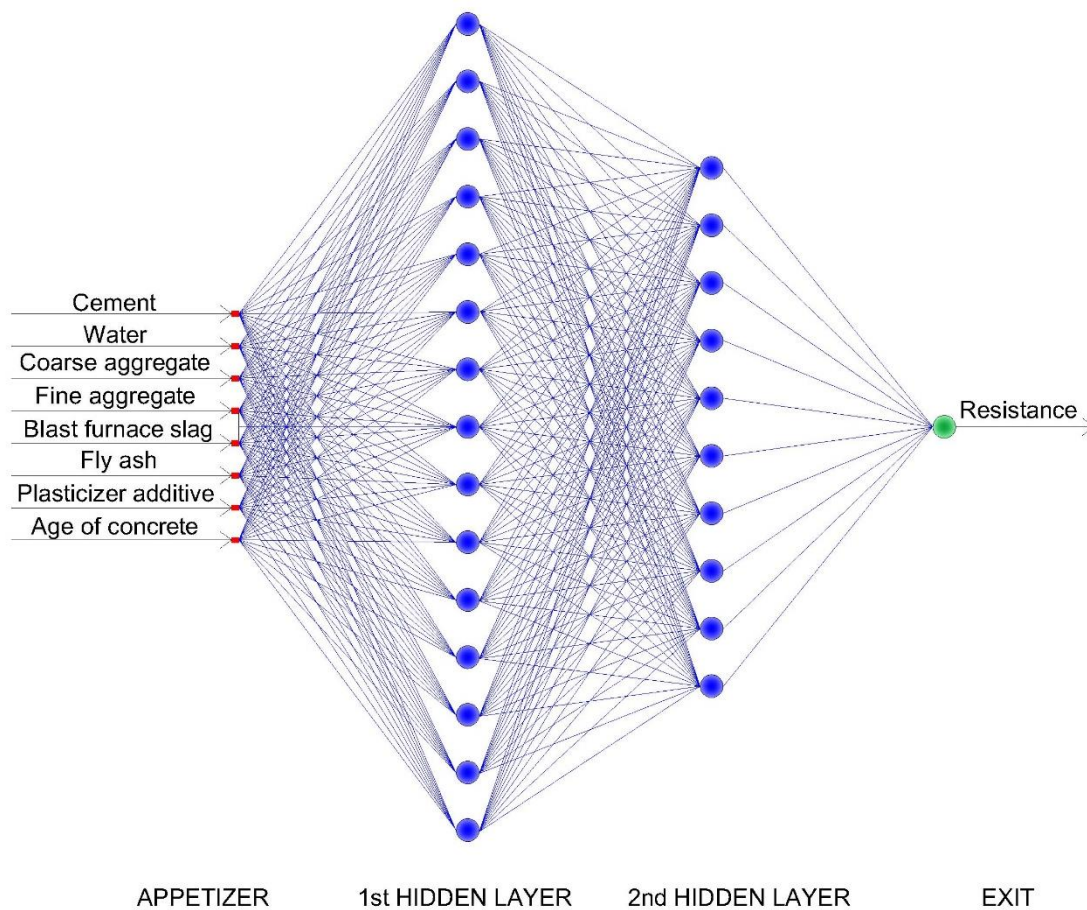


Figure 2 - Architecture chosen for RNA.

Getahun et al. (2018) used an ANN with 15 entrances and only one hidden layer, and two exits that correspond to compressive strength and traction. The proposed RNA overestimated the compressive strength by approximately 12.3%.

On the other hand, Acuña et al (2014) used an RNA similar to that used in this work, containing two hidden layers with 10 and 4 neurons. Later they also used an Elman-type RNA with three hidden layers with 9, 8 and 3 neurons.

The chosen network was trained, tested and validated, the process was repeated 10 times and the results obtained for the MSE at the time the training was interrupted. The correlation coefficient R between the obtained output and the desired output and the number of times required are shown in Table 2, as well as the mean and the standard deviation value for these values.

Table 2 - MSE, R and Times obtained with the RNA used in the study.

Execution	MSE	R	Epochs
1	31.7026	0.96193	17
2	21.4910	0.96968	21
3	37.6369	0.95600	18
4	33.0209	0.95302	16
5	20.3395	0.97344	20
6	15.8038	0.97070	23
7	28.1591	0.96806	23
8	27.2261	0.96496	34
9	30.0285	0.96639	19
10	28.9092	0.97171	27
Mean	27.4318	0.96559	21.8
Standard deviation	6.5313	0.00676	5.39

Looking at Table 2, it is possible to notice that in the execution of number 6 the artificial neural network obtained the best results. The value obtained for the MSE was 15.8038, which is well below the average obtained in the 10 executions, which was 27.4318.

The value obtained for the correlation coefficient between the obtained output and the target output of the network was 0.97070, which was higher than the average found, which was 0.96559.

Acuña et al (2014) obtained values between 0.933 and 0.975 for the correlation coefficient R, values very close to those found in this study.

On the other hand, in the sixth execution of the ANN it is observed that 23 times were necessary until the training was interrupted at the moment when the error stops decreasing, and the average number of times required was approximately 22.

In the work by Oliveira et al (2007) the errors were much greater, reaching 20%, which they considered to be high for the standards used in concrete technology.

Figure 3 shows the exact point where the smallest error for the artificial neural network was obtained in the graph that relates the number of epochs and the MSE.




Figure 3 - Graph for the sixth execution of the ANN that lists the MSE and the number of times required.

Figure 4 illustrates the values of the correlation coefficient R in the sixth execution of the ANN. For the training set the value was 0.98412, for the test the value found was 0.90372, and for validation 0.97126 was obtained. Considering all the data, the R value

found was 0.97070. The graphs list the values obtained by the artificial neural network and the values that were the targets.

In figure 5, it is possible to observe the histogram of the errors found by the ANN used in this study. The graph lists the error and the number of samples, and it is possible to note that the vast majority of training, validation and test samples are found in the column whose error is 0.6602. The orange colored line on the graph represents the zero error. The ANN training time was 64 seconds.

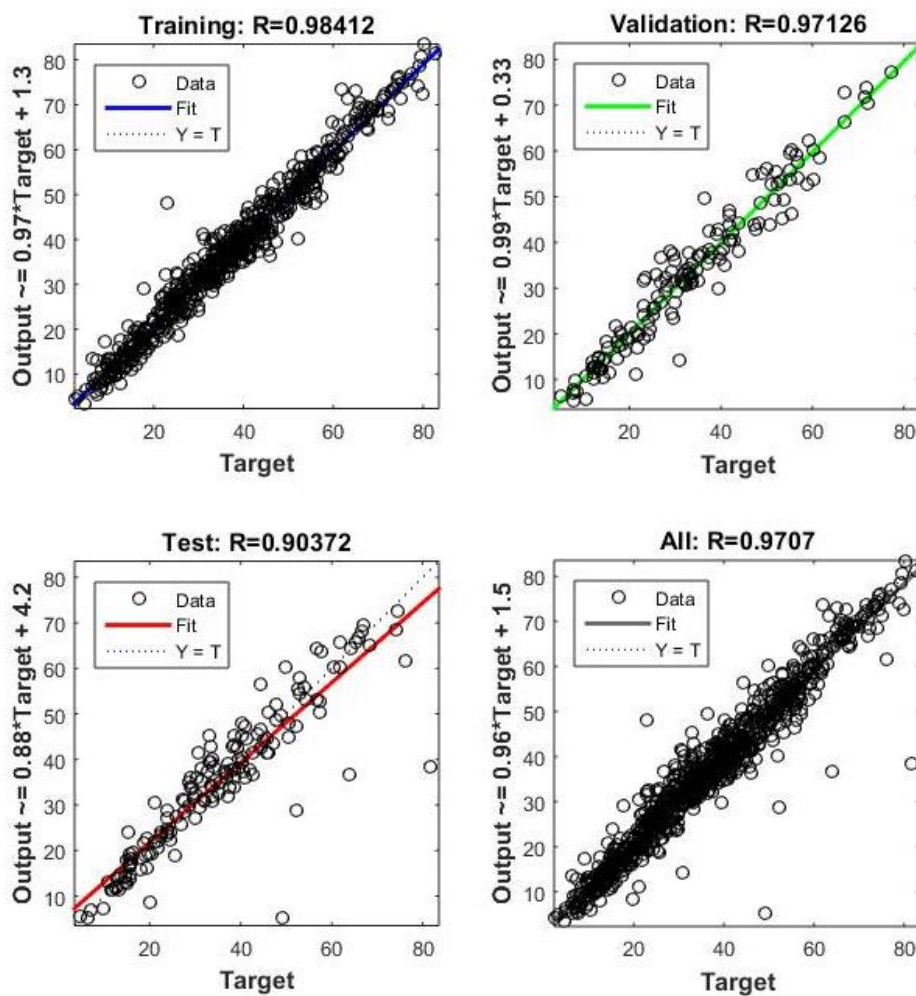


Figure 4 - Values of the correlation coefficient R obtained in the sixth execution of the ANN.




Figure 5 - Error histogram for the sixth ANN execution.

4. CONCLUSION

In this work a model of artificial neural network was developed in order to obtain the strength of the concrete from data of the materials that constitute it beyond the curing time employed. Observing the results found in this work, it is possible to affirm that Artificial Neural Networks are a computational intelligence methodology that can contribute a lot in the field of civil engineering, more specifically in the area of concrete.

The ability to learn and generalize an artificial neural network can be of great value in the arduous task of dosing and determining the compressive strength of concrete. It would be possible to train an ANN for materials from different regions, considering that each region has materials with different characteristics. The average correlation coefficient obtained was 0.96559, which is higher than that found in the study by Oliveira et al. (2007) and very similar to that found by Acuña et al. (2014).

The RNA used proved to be agile and reliable in view of the very low errors found. The Brazilian Standard NBR 6118 determines that in the design of reinforced concrete structures the strength of the concrete is reduced by 40% and the value of the actions acting on the structure is increased by 40% and the experimental RNA obtained about 95% efficiency

REFERENCES

- ACUÑA, L.; TORRE, A. V.; MOROMI, I.; GARCÍA, F. Uso de las redes neuronales artificiales en el modelado del ensayo de resistencia a compresión de concreto de construcción según la norma ASTM C39/C 39M. *Informacion Tecnologica*, v. 25, n. 4, p. 3–12, 2014.
- AKPINAR, P.; KHASHMAN, A. Intelligent classification system for concrete compressive strength. *Procedia Computer Science*, v. 120, p. 712–718, 2017. Disponível em: <<https://doi.org/10.1016/j.procs.2017.11.300>>.
- ARORA, S.; SINGH, B.; BHARDWAJ, B. Strength performance of recycled aggregate concretes containing mineral admixtures and their performance prediction through various modeling techniques. *Journal of Building Engineering*, v. 24, p. 100741, 2019. Disponível em: <<https://doi.org/10.1016/j.job.2019.100741>>.
- BEHNOOD, A.; GOLAFSHANI, E. M. Predicting the compressive strength of silica fume concrete using hybrid artificial neural network with multi-objective grey wolves. *Journal of Cleaner Production*, v. 202, p. 54–64, 2018. Disponível em: <<https://doi.org/10.1016/j.jclepro.2018.08.065>>.
- COLOMBO, I. G. et al. Textile reinforced concrete: experimental investigation on design parameters. *Materials and Structures*, Dordrecht, v. 46, p. 1933-1951, 2013.
- 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>>.
- I-CHENG YEH, "Modeling of strength of high performance concrete using artificial neural networks," *Cement and Concrete Research*, Vol. 28, No. 12, pp. 1797-1808 (1998).
- MORETTI, J. F. Sistema Inteligente Baseado nas Redes Neurais Artificiais para Dosagem do Concreto, 2010. 95p. Tese (Doutorado em engenharia elétrica) – Universidade Estadual Paulista Júlio de Mesquita Filho, Ilha Solteira, 2010.
- NIKBIN, I. M.; RAHIMI R., S.; ALLAHYARI, H. A new empirical formula for prediction of fracture energy of concrete based on the artificial neural network. *Engineering Fracture Mechanics*, v. 186, p. 466–482, 2017. Disponível em: <<https://doi.org/10.1016/j.engfracmech.2017.11.010>>.
- 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.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. La Jolla: Institute for Cognitive Science-University of California, 1985.49 p. (ICS Report, 8506).
- SIDDIQUE, R.; AGGARWAL, P.; AGGARWAL, Y. Prediction of compressive strength of self-compacting concrete containing bottom ash using artificial neural networks. *Advances in Engineering Software*, v. 42, n. 10, p. 780–786, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.advengsoft.2011.05.016>>.

- WIDROW, B.; LEHR, M. A. 30 Years of adaptive neural networks: perceptron, madaline, and backpropagation. Proceedings of the IEEE, New York, v.78, n.9, p. 1415-1442, 1999.
- YAMAN, M. A.; ELATY, M. A; TAMAN, M. Predicting the ingredients of self compacting concrete using artificial neural network. Alexandria Engineering Journal, v. 56, n. 4, p. 523–532, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.aej.2017.04.007>>.
- YOUNIS, K. H.; PILAKOUTAS, K. Strength prediction model and methods for improving recycled aggregate concrete. Construction and Building Materials, Amsterdam, v.49, p.688-701, 2013.

SEGUNDA PARTE – ARTIGOS

ARTIGO 2

Artigo redigido conforme norma da Revista Científica “Journal of Building Engineering”.

Implementação e avaliação de diferentes sistemas *fuzzy* para predição da resistência à compressão axial de concreto de cimento Portland

Dennis Santos Tavares
Tadayuki Yanagi Junior
Bruna Campos Amaral
Francisco Carlos Gomes
Ednilton Tavares de Andrade

RESUMO: O concreto é o principal material estrutural de construção civil e sua principal propriedade físico-mecânica é a resistência à compressão axial. Rotineiramente a predição dessa propriedade se restringe a equações empíricas falhas e/ou em dosagens experimentais. O objetivo deste estudo é o desenvolvimento de sistemas *fuzzy* capazes de predizerem adequadamente a resistência à compressão axial do concreto, a partir dos dados dos traços e tempo de cura. Foram desenvolvidos vários sistemas *fuzzy* com diferentes métodos de inferência e defuzzificação. Para as variáveis de entrada foram adotadas funções de pertinência triangular em todos os sistemas e para as variáveis de saída, funções triangulares na inferência Mamdani e funções *singletons* para a inferência Sugeno. Os modelos desenvolvidos foram simulados e avaliados estatisticamente. Os sistemas com inferência Mamdani e defuzzificação centroide, *bissetor* e *mom*, além da inferência Sugeno com defuzzificação *wtaver* e *wtsum* se mostraram confiáveis e altamente eficazes. O melhor desempenho foi obtido pelo sistema *fuzzy* com método de inferência Mamdani e defuzzificação centroide.

Palavras-chave: Concreto, Resistência à Compressão, Lógica *Fuzzy*

1. INTRODUÇÃO

O concreto é o principal material estrutural de construção civil amplamente utilizado em todo o mundo, desde artefatos pré-fabricados, pequenas edificações residenciais até grandes obras de infraestrutura. Isso se deve principalmente à sua versatilidade para produção e manipulação, o que permite a moldagem em qualquer formato, além da grande durabilidade que o material proporciona. O concreto é heterogêneo, uma vez que é constituído por diferentes materiais com diferentes propriedades físico-mecânicas. Basicamente a composição desse material consiste em cimento, agregados miúdos e agregados graúdos.

Os efeitos dos materiais constituintes do concreto em seu comportamento mecânico, assim como teorias sobre a determinação das proporções dos materiais constituintes vem sendo continuamente investigados. A heterogeneidade do material e suas não linearidades têm instigado os pesquisadores [1].

Uma das principais propriedades do concreto é a resistência à compressão, sendo considerada um dos mais importantes parâmetros para garantia da qualidade [2]. Esta propriedade está diretamente relacionada a segurança e estabilidade das edificações, uma vez que todo dimensionamento estrutural em concreto armado é feito com base na resistência à compressão do concreto. Portanto, esta propriedade do concreto é fundamental para o desempenho estrutural durante todo o ciclo de vida do empreendimento, no entanto, a natureza heterogênea do concreto faz dele um sistema altamente complexo, tornando um desafio prever com precisão a resistência à compressão do material [3-5].

Vários parâmetros influenciam na resistência à compressão e demais propriedades do concreto, como a relação água/cimento, quantidade e qualidade de agregados além do tipo de cimento, além da presença de impurezas nos materiais constituintes. Tradicionalmente a modelagem dos efeitos desses parâmetros nas propriedades físico-mecânicas do concreto, para fins de determinação das proporções de cada material constituinte do concreto ou mesmo predição da resistência à compressão, se resume a equações empíricas que são falhas na compreensão do cenário real, ou em dosagens experimentais realizadas em laboratório [6-7].

Neste contexto, a lógica *fuzzy* constitui uma importante metodologia de inteligência computacional que em muito pode contribuir para a otimização de processos, como a predição da resistência à compressão do concreto, bem como para promover a industrialização e automatização do setor da construção civil.

A lógica *fuzzy* é muito útil para aplicação em processos de difícil controle por métodos convencionais ou discretos. Sistemas de controle baseados em lógica *fuzzy* aplicam uma linguagem próxima da utilizada por controladores humanos, ou seja, com informações incertas/imprecisas para descrever relações de entrada e saída do processo controlado [8].

Basicamente um sistema *fuzzy* é constituído por: (1) uma interface de fuzzificação em que as entradas são convertidas em informações qualitativas que o mecanismo de inferência adotado pode utilizar para ativar e replicar regras, (2) base de regras, elaboradas por profissionais especialistas no problema abordado, que contém a descrição linguística no padrão “Se-Então”, (3) um mecanismo de inferência que determina a forma operacional do sistema e converte os valores de entrada em saída, utilizando as regras estabelecidas, (4) uma interface de defuzzificação que converte a saída do mecanismo de inferência em um conjunto clássico [9]. Um sistema *fuzzy* típico é ilustrado na Figura 1.

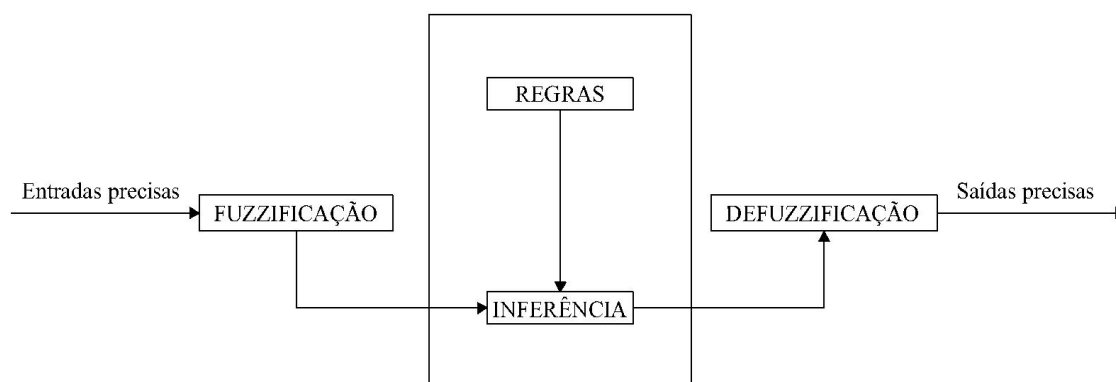


Figura 1. Sistema *fuzzy* típico.

Vários estudos têm utilizado sistemas *fuzzy* com várias aplicações na construção civil, como predição da resistência a compressão do concreto e asfalto, avaliação de danos estruturais em concreto armado, patologia em edificações, predição da taxa de corrosão de tubulações e estimativa da geração de resíduos em obras, o que mostra ser promissor esse campo de estudo para toda indústria da construção civil, contribuindo para redução de custos e otimização de processos por meio da automatização desse setor [10-16].

Neste contexto, objetivou-se com o presente estudo desenvolver sistemas *fuzzy* com diferentes mecanismos de inferência e diferentes metodologias de defuzzificação afim de verificar a viabilidade de aplicação desta metodologia de inteligência computacional na predição da resistência a compressão axial do concreto e determinar, através de diferentes índices estatísticos, qual sistema *fuzzy* proposto se mostra mais eficaz.

2. METODOLOGIA

2.1. Base de dados

A base de dados utilizada neste trabalho é de autoria de I-Cheng Yeh [17], professor da Chung-Hua University, em Taiwan e se encontra disponível no UCI Machine Learning Repository. São constituídos de 1030 amostras de diferentes traços de concreto de cimento Portland com resistência à compressão axial variando de 2 a 80 Mpa, para diversas idades de cura até a ruptura dos corpos de prova, variando de 3 a 365 dias.

2.2. Desenvolvimento dos sistemas *fuzzy*

Os sistemas *fuzzy* foram desenvolvidos utilizando o *software* MATLAB® (R2011b) no módulo *Fuzzy Logic Toolbox* criado pela MathWorks™. Esta ferramenta oferece suporte completo para o desenvolvimento de modelos *fuzzy* e também para simulações dos sistemas desenvolvidos, sendo completa para trabalhos com modelos difusos [18]. O banco de dados contempla um total 1030 (mil e trinta) linhas de dados, que foram utilizadas para o desenvolvimento e validação dos sistemas *fuzzy*.

As variáveis de entrada do modelo, ou seja, variáveis independentes, são constituídas pelo consumo de cimento Portland comum (C, kg m⁻³), escória de alto forno (E, kg m⁻³), cinzas volantes (V, kg m⁻³), água (A, kg m⁻³), aditivo super plastificante (P, kg m⁻³), agregado graúdo (G, kg m⁻³), agregado miúdo (M, kg m⁻³) e idade (I, dias). Combinando as variáveis de entrada, tomando como referência os dados colhidos, este modelo prediz a variável de saída, resistência à compressão axial do concreto (R, MPa).

Os sistemas *fuzzy* foram desenvolvidos a partir de dois métodos de inferência, Mamdani [19] e Takagi-Sugeno [20]. As funções de pertinência de saída são as principais diferenças entre estes dois métodos, enquanto para Mamdani são utilizados conjuntos

difusos, em Sugeno as funções de pertinência de saída empregadas foram do tipo constante.

Para ambos os métodos de inferência, Mamdani e Sugeno, adotou-se as funções de pertinência do tipo triangular para as variáveis de entrada (Figuras 2, 3 e 4). Para a variável de saída, adotou-se as funções triangulares (Figuras 5) para a inferência Mamdani e, as funções *singletons* (Figura 6) para a inferência Sugeno. Os dados coletados foram reorganizados e divididos em intervalos, onde, cada intervalo representa uma função de pertinência.

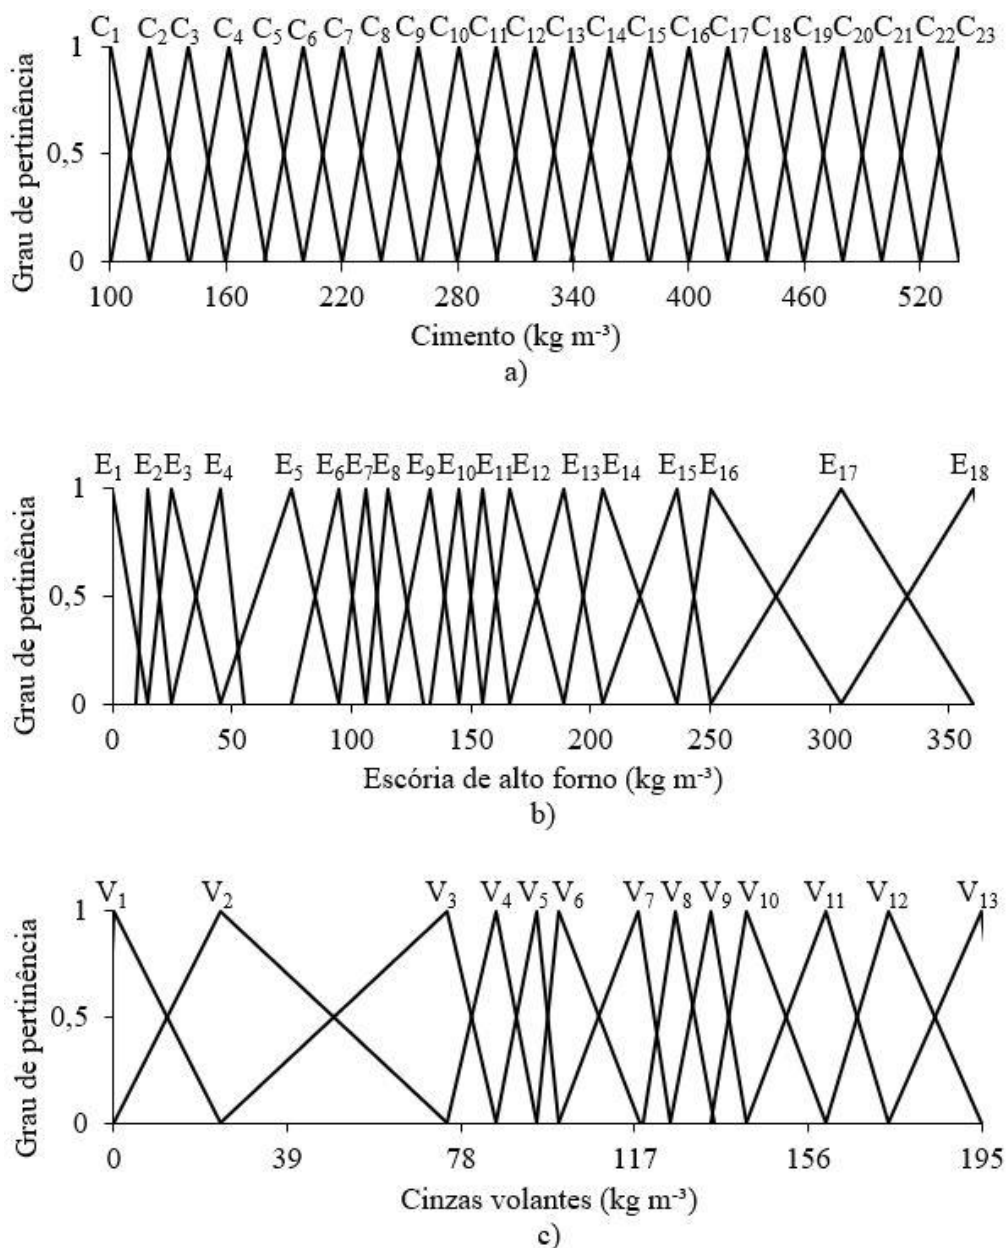


Figura 2. Funções de pertinência triangulares aplicadas às variáveis de entrada a) cimento (kg m^{-3}), b) escória de alto forno (kg m^{-3}), c) cinzas volantes (kg m^{-3}).

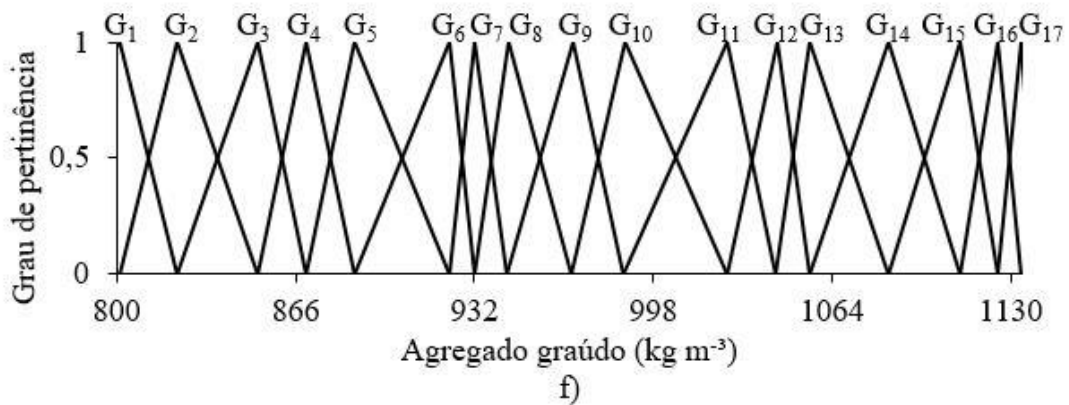
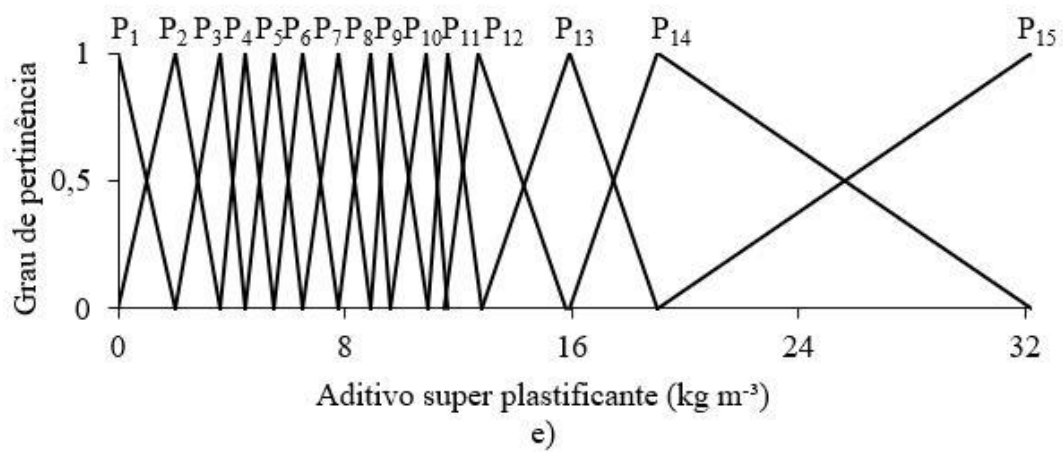
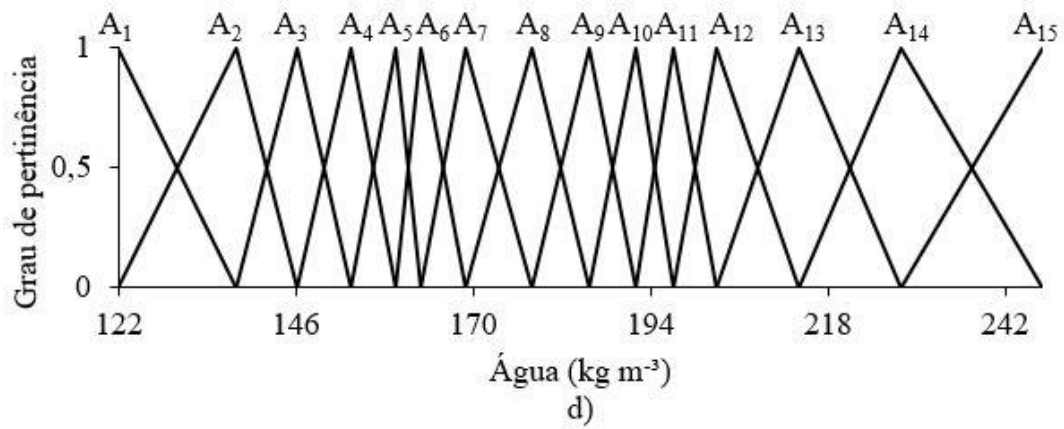


Figura 3. Funções de pertinência triangulares aplicadas às variáveis de entrada d) água (kg m^{-3}), e) aditivo super plastificante (kg m^{-3}), f) agregado graúdo (kg m^{-3}).

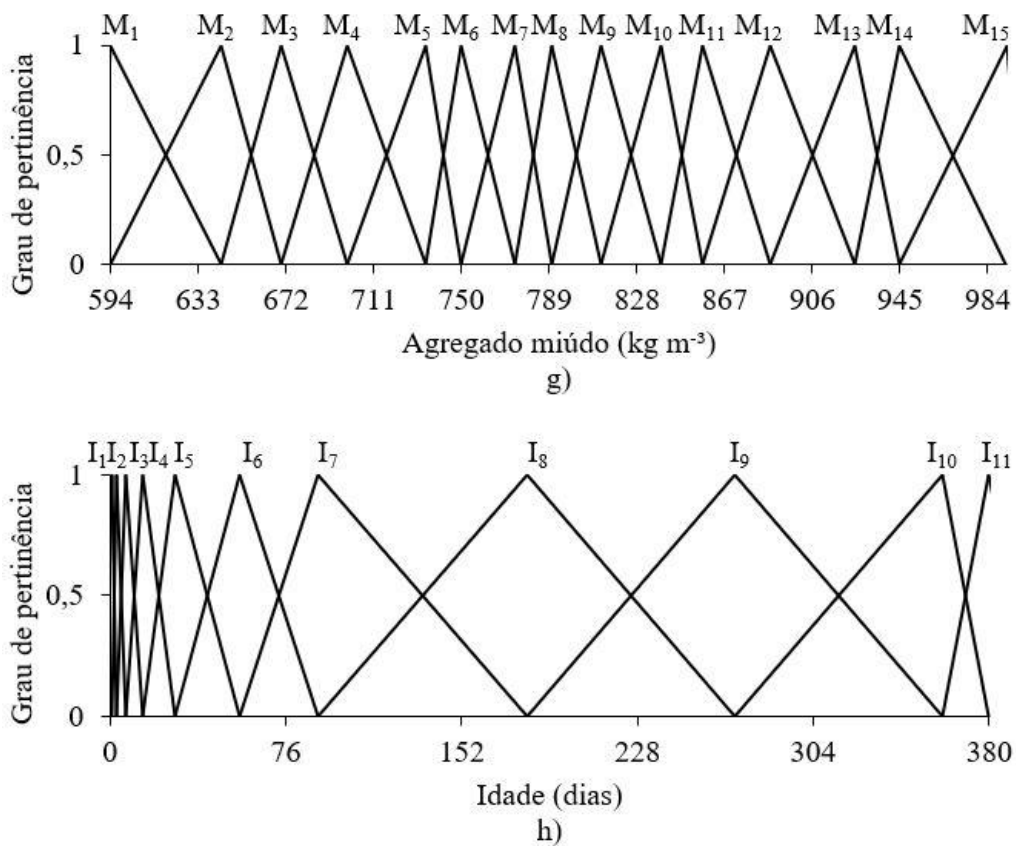


Figura 4. Funções de pertinência triangulares aplicadas às variáveis de entrada g) agregado miúdo (kg m⁻³) e h) idade (dias).

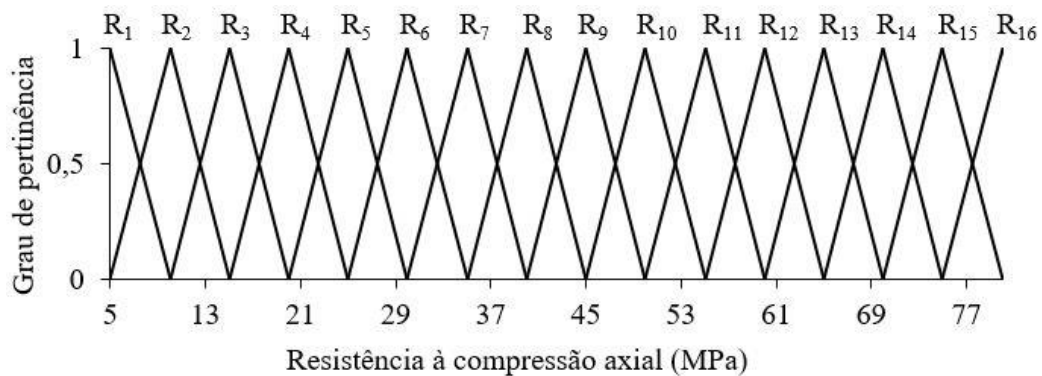


Figura 5. Variável de saída, resistência à compressão axial (MPa), representada por funções de pertinência triangulares na inferência Mamdani.




Figura 6. Variável de saída, resistência à compressão axial (MPa), representada por conjuntos *singletons*, na inferência Sugeno.

Após a construção das funções de pertinência foi realizada a elaboração das regras *fuzzy* que o modelo deve obedecer. As regras foram desenvolvidas através da combinação das variáveis de entrada, conforme as linhas de dados que foi coletada, totalizando 916 (novecentos e dezesseis) regras. Nesta etapa três especialistas das áreas de tecnologia do concreto e lógica *fuzzy* avaliaram as regras conforme a metodologia *fuzzy* de seleção de especialistas das áreas, proposta por CORNELISSEN et al. [21].

As regras desenvolvidas são processadas concomitantemente, ou seja, todas elas são analisadas ao mesmo tempo, e ao final obtém-se uma resposta em formato de conjunto *fuzzy*, com isso faz-se necessário um processo de defuzzificação para que a saída do sistema seja um número real. Para a inferência Mamdani foram avaliados os cinco métodos de defuzzificação disponíveis no módulo *Fuzzy Logic Toolbox*: centro de gravidade da área (centroide), bissetor da área (bissetor), menor dos máximos (*som*), média dos máximos (*mom*) e maior dos máximos (*lom*). Por sua vez, para a inferência Sugeno foram avaliados dois métodos de defuzzificação disponíveis: soma ponderada (*wtsun*) e média ponderada (*wtaver*).

O método de defuzzificação mais comum é o centroide ou centro da área, que encontra um ponto que representa o centro de gravidade do conjunto agregado conforme a expressão matemática descrita na Equação (1).

$$SD(x_k, y_k) = \frac{\sum_{i=1} u_i \mu_i(x_k, y_k, u_i)}{\sum_{i=1} \mu_i(x_k, y_k, u_i)} \quad (1)$$

Em que, $SD(x_k, y_k)$ é a saída defuzzificada, $\mu_i(x_k, y_k, u_i)$ é a função do conjunto agregado e u_i é a saída *fuzzy*.

A defuzzificação pelo método bissetor da área corresponde a uma linha vertical que divide a área em duas regiões com áreas idênticas, expressa pela Equação (2). Não necessariamente a linha correspondente ao bissetor da área coincide com o centroide.

$$\sum_{i=1}^M \mu_u(x_k, y_k, u_i) = \sum_{i=1}^N \mu_u(x_k, y_k, u_i), \quad (2)$$

$$SD(x_k, y_k) = u_M$$

O menor dos máximos (*som*) consiste em um método de defuzzificação em que se escolhe o menor dos pontos com grau de pertinência mais elevado inferido pelas regras estabelecidas, conforme Equação (3).

$$SD(x_k, y_k) = \{ \min (u_i | \mu_u(x_k, y_k, u_i) = \max (\mu_u(x_k, y_k, u_i))) \} \quad (3)$$

A defuzzificação pelo método da média dos máximos (*mom*) consiste em um método de defuzzificação em que se calcula a média dos pontos com grau de pertinência mais elevado inferido pelas regras estabelecidas, conforme Equação (4).

$$SD(x_k, y_k) = \sum_{i=1}^l \frac{u_i}{l}, \quad (4)$$

sendo que, l corresponde ao número de elementos u que alcançam os máximos valores de $\mu_u(x_k, y_k, u_i)$.

O maior dos máximos (*lom*) consiste em um método de defuzzificação em que se escolhe o maior dos pontos com grau de pertinência mais elevado inferido pelas regras estabelecidas, conforme Equação (5).

$$SD(x_k, y_k) = \{ \max (u_i | \mu_u(x_k, y_k, u_i) = \max (\mu_u(x_k, y_k, u_i))) \} \quad (5)$$

Os métodos de defuzzificação do centro de gravidade, bissetor, menor dos máximos, média dos máximos e maior dos máximos para uma mesma função é ilustrado na Figura 7 [22].




Figura 7. Representação gráfica dos métodos de defuzzificação centro da área (centroide), bissetor, menor dos máximos, média dos máximos e maior dos máximos.

O método de defuzzificação *wtsum* é calculado através da soma ponderada das saídas dos conjuntos *fuzzy*, conforme Equação (6).

$$SD(x_k, y_k) = \sum_{i=1}^m \mu_u(x_k, y_k, u_i) u_i \quad (6)$$

O método de defuzzificação *wtaver* é calculado através da média ponderada das saídas dos conjuntos *fuzzy*, conforme Equação (7).

$$SD(x_k, y_k) = \frac{\sum_{i=1}^m \mu_u(x_k, y_k, u_i) u_i}{\sum_{i=1}^m \mu_u(x_k, y_k, u_i)} \quad (7)$$

2.3. Análises estatísticas

Ao final foram realizadas as simulações para cada mecanismo de inferência e metodologia de defuzzificação, sendo os resultados comparados com os dados obtidos da literatura. Com isso foi possível avaliar o desempenho dos sistemas *fuzzy* desenvolvidos por meio de oito diferentes índices estatísticos: teste t de Student ($p < 0,05$), erro quadrático médio (MSE), erro sistemático (Bias), desvio padrão médio (σ), erro absoluto médio (Ea), erro percentual médio (Ep), coeficiente de determinação (R^2) e raiz quadrada do erro quadrático médio (RMSE).

3. RESULTADOS E DISCUSSÃO

Os indicadores estatísticos t-teste, *Bias*, *Ea*, *MSE*, *RMSE*, σ , *Ep*, R^2 e obtidos através da comparação entre os dados encontrados na literatura e os dados simulados a partir dos sistemas *fuzzy* desenvolvidos estão representados na Tabela 1.

Tabela 1

Teste t de Student e indicadores estatísticos das diferentes estruturas de sistemas de inferência *fuzzy* testados para predição da resistência à compressão axial.

Sistema	Inferência	Funções	Defuzzificação	Indicadores de desempenho dos sistemas							
				t-test	Bias	Ea	MSE	RMSE	σ	Ep	R ²
1	Mamdani	Entrada Triangular Saída Triangular	centroide	p= 0,6858 ^{NS}	-0,0334	1,5643	6,9985	2,6455	1,1062	6,1020	0,9749
2			bissetor	p= 0,5611 ^{NS}	-0,0518	1,5898	8,1750	2,8592	1,1242	6,1091	0,9707
3			<i>mom</i>	p= 0,6130 ^{NS}	-0,0427	1,5687	7,3438	2,7099	1,1092	6,0291	0,9737
4			<i>lom</i>	p= 0,0000	1,8501	2,1763	11,3911	3,3751	1,5389	8,7007	0,9715
5			<i>som</i>	p= 0,0000	-1,9348	2,3246	13,5443	3,6803	1,6438	8,3356	0,9649
6	Sugeno	Entrada Triangular Saída Singleton	<i>wtaver</i>	p= 0,5790 ^{NS}	-0,0477	1,5535	7,5921	2,7554	1,0985	6,2995	0,9728
7			<i>wtsum</i>	p= 0,5790 ^{NS}	-0,0477	1,5535	7,5921	2,7554	1,0985	6,2995	0,9728

Nota: - Valores de p pelo Teste t, NS = não significativo ($p > 0,05$), erro sistemático (Bias), erro absoluto médio (Ea), erro quadrático médio (MSE), raiz quadrada do erro quadrático médio (RMSE), desvio padrão médio (σ), erro percentual médio (Ep) e coeficiente de determinação (R²).

- Métodos de defuzzificação: centro de gravidade da área (centroide), bissetor da área (bissetor), média dos máximos (*mom*), maior dos máximos (*lom*), menor dos máximos (*som*), média ponderada (*wtaver*), soma ponderada (*wtsum*).

Ao analisar os valores obtidos através do teste t de *Student*, considerando um nível de significância de 5%, é possível afirmar que não houve diferença estatisticamente significativa entre os valores experimentais e os simulados nos métodos de defuzzificação centroide, bissetor e *mom* na inferência Mandani e, também, nos métodos *wtaver* e *wtsum* na inferência Sugeno. O Sistema 1 (defuzzificação centroide) apresentou a menor variação média entre as medidas, aferida por meio dos índices estatísticos.

O índice Bias indica o desvio médio dos valores simulados pelo sistema *fuzzy* em relação aos dados obtidos experimentalmente, apontando assim uma tendência em superestimar ou subestimar os valores simulados. Para valores mais próximos de zero, menor será a significância do erro sistemático do modelo desenvolvido. Na Tabela 1 é possível observar que o método de inferência Mandani com defuzzificação centroide (Sistema 1) apresentou o valor mais próximo de zero (-0,0334) indicando que para este sistema houve menor magnitude do erro sistemático.

AKKURT et al. [23] e TAYFUR et al. [24] ao utilizarem a metodologia *fuzzy* para prever a resistência a compressão do concreto, adotaram o método de defuzzificação centroide da inferência Mandani e obtiveram como resultado valores de E_a de 2,6900 e 3,6800, respectivamente. Por sua vez, AGGARWAL & AGGARWAL [25] ao preverem a resistência a compressão do concreto pela metodologia *fuzzy* utilizaram a inferência Sugeno com defuzzificação *wtaver*, encontrando E_a de 4,8850. A partir da comparação destes trabalhos temos que a metodologia Mandani se adequou melhor para a predição da resistência à compressão de concreto, porém neste estudo os valores de E_a variaram de 1,5535 a 2,3246 entre as duas inferências, indicando alta eficiência dos sistemas desenvolvidos independentemente do tipo de inferência aplicada.

KHADEMI et al. [2], FALADE & IQBAL [26] e SHARIFI & HOSSEINPOUR [27] utilizaram o sistema *neuro-fuzzy* adaptativo para prever a resistência à compressão de concreto, obtendo valores de MSE de 25,4530; 25,4500 e 48,5435, respectivamente. Neste estudo, os valores obtidos para MSE variaram de 6,9985 a 13,5443, indicando a eficiência de predição dos sistemas desenvolvidos, com destaque para o Sistema 1 que apresentou melhor resultado (6,9985).

Analisando os resultados de R^2 e RMSE apresentados na Tabela 1 é possível observar que o Sistema 1 apresentou os melhores valores, sendo eles 0,9749 e 2,6455 respectivamente. CIHAN [28] em seu estudo avaliou a eficiência de sistemas *fuzzy* em prever a resistência à compressão do concreto, obtendo valores de R^2 e RMSE de 0,9280

e 1,4420, respectivamente. Estes resultados demonstram a capacidade da metodologia *fuzzy* aplicada em concretos.

Ao analisar os valores obtidos de desvio padrão (σ) verifica-se que, os menores valores obtidos (1,0985) foram pela inferência Sugeno para ambos os métodos de defuzzificação (*wtaver* e *wtsum*). Apesar dos Sistemas 6 e 7 terem apresentado os melhores valores de σ , é possível observar que houve pequena variação com os valores encontrados pela inferência Mandani nos Sistemas 1, 2 e 3.

Para os valores obtidos de erro percentual médio (E_p) nota-se que a inferência Mandani e defuzzificação *mom* apresentou o melhor resultado (6,0291%). NASROLLAHZADEH & NOUHI [29] fizeram uso de sistemas *fuzzy* com inferência Sugeno para a predição da resistência a compressão axial de concreto, encontrando valor para E_p de 18,6640% para as funções de pertinência de saída do tipo constante. ZHOU et al. [30] por sua vez utilizaram redes neurais artificiais e obtiveram E_p de 18,3900%. Portanto, os resultados de E_p deste estudo mostraram que é possível predizer com melhor eficiência utilizando sistemas *fuzzy*, com destaque para a inferência Mamdani.

Na Tabela 2 estão listadas as frequências dos erros absolutos para cada sistema desenvolvido. Para os sistemas baseados na inferência Mandani (1, 2 e 3), as ocorrências de erros absolutos menores que 4 MPa foram de 96,41%, 96,51% e 97,09%, respectivamente. Para os sistemas 6 e 7, baseados na inferência Sugeno, observou-se que, 96,99% dos erros absolutos ocorrem até 4 MPa.

Tabela 2

Frequência de ocorrência de erros absolutos dos diferentes sistemas de inferência *fuzzy* testados para predição da resistência à compressão axial.

Frequência de ocorrência dos erros absolutos (%)							
Sistema	Inferência	Funções	Defuzzificação	Intervalos de erro absoluto (MPa)			
				[0,0 – 2,0[[2,0 - 4,0[[4,0 – 6,0[≥ 6,0
1	Mamdani	Entrada Triangular Saída Triangular	Centroide	76,02	20,39	1,84	1,75
2			Bissetor	76,80	19,71	1,55	1,94
3			<i>mom</i>	76,60	20,49	0,87	2,04
4			<i>lom</i>	55,53	33,88	8,16	2,43
5			<i>som</i>	52,72	35,44	9,22	2,62
6	Sugeno	Entrada Triangular Saída Singleton	<i>wtaver</i>	76,89	20,10	1,26	1,75
7			<i>wtsum</i>	76,89	20,10	1,26	1,75

Nota: Métodos de defuzzificação: centro de gravidade da área (centroide), bissetor da área (bissetor), maior dos máximos (*lom*), média dos máximos (*mom*), menor dos máximos (*som*).

Nas Figuras 8 e 9 estão ilustrados os gráficos de correlação da resistência a compressão axial obtidas pela literatura (valores experimentais) e as preditas pelos sistemas *fuzzy*. A reta à 45° traçada pela origem auxilia observar as diferenças de predição dos sistemas. Os valores acima da reta indicam que os resultados da predição foram superestimados, e para os valores que se encontram abaixo da reta apontam valores subestimados. De forma geral os valores superestimados se encontram mais afastados da reta e em menor quantidade, quando comparados aos valores subestimados que se encontram mais próximos da reta e em maior quantidade.

No geral os sistemas 1, 2, 3, 6 e 7 desenvolvidos se apresentaram eficientes em prever a resistência a compressão axial de concreto, porém o Sistema 1 constituído pela inferência Mamdani e método de defuzzificação centroide, apresentou maior número de índices estáticos com os melhores valores.

Apesar de autores como [25] e [29] terem utilizado a inferência Sugeno para prever a resistência a compressão de concreto, neste trabalho concluímos que a inferência Mandani se mostrou mais eficiente. Ademais, a resistência à compressão do concreto apresenta comportamento semelhante às variáveis de saída da inferência Mamdani (funções de pertinência triangular), por apresentarem um ponto com grau de pertinência 1 e variação linear a partir deste ponto.

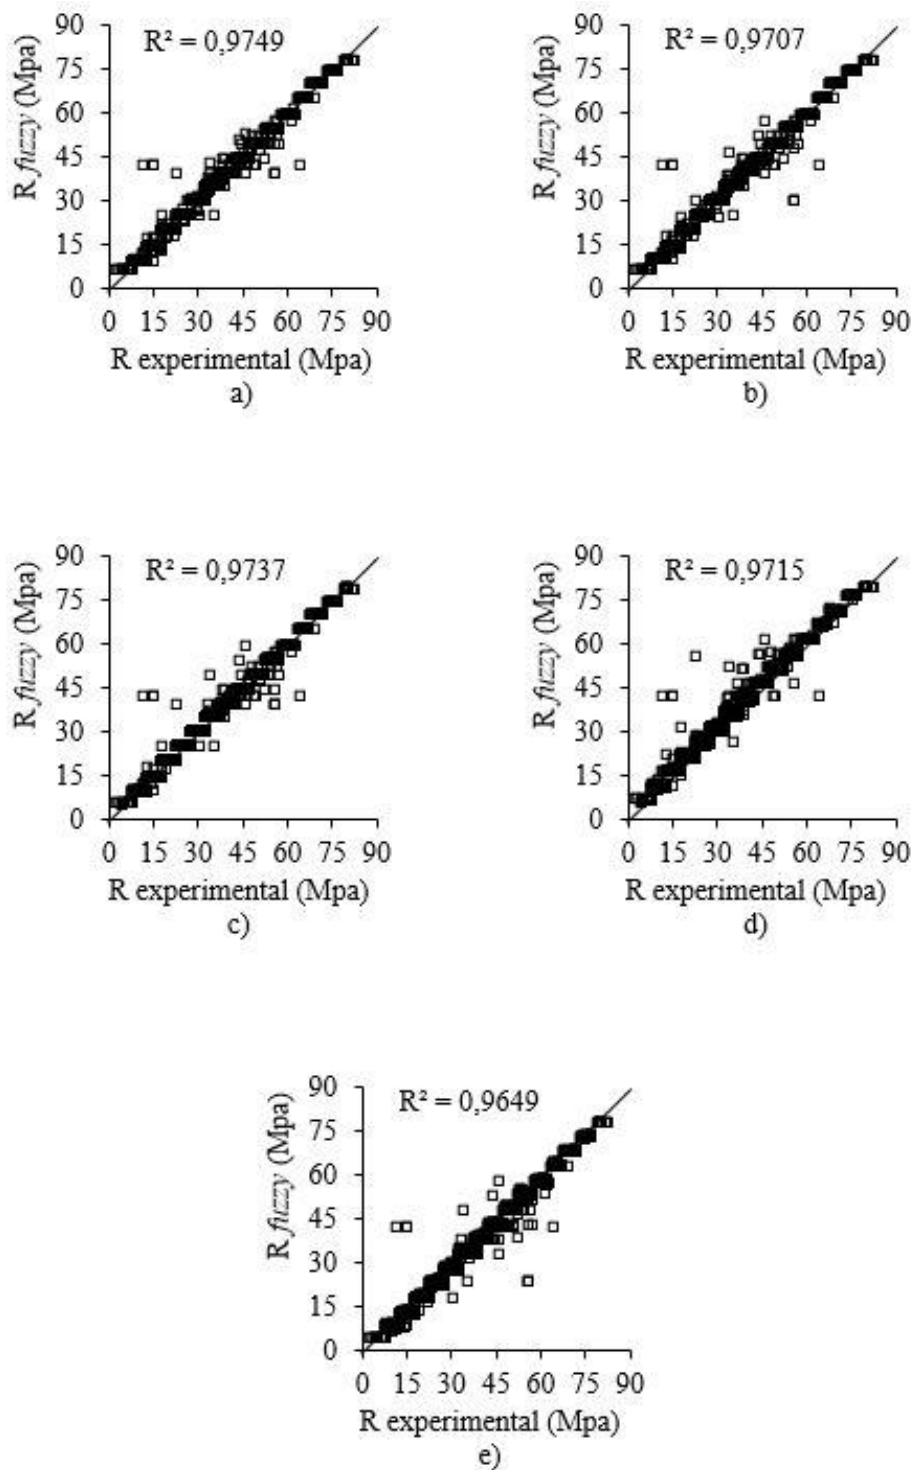


Figura 8. Relação funcional entre os valores de resistência à compressão axial obtidos experimentalmente ($R_{\text{experimental}}$) e preditos pelos sistemas *fuzzy* (R_{fuzzy}), para defuzzificação (a) centroide, (b) bissetor, (c) mom, (d) lom e e) som.




Figura 9. Relação funcional entre os valores de resistência à compressão axial obtidos experimentalmente ($R_{\text{experimental}}$) e preditos pelos sistemas *fuzzy* (R_{fuzzy}), para defuzzificação (a) *wtaver* e (b) *wtsum*.

4. CONCLUSÃO

Este trabalho discute a possibilidade de implementação de sistemas *fuzzy* para predição da resistência à compressão axial do concreto de cimento Portland, a partir de dados que incluem a proporção dos materiais constituintes e tempo de cura. Foram avaliados estatisticamente diversos sistemas *fuzzy* com diferentes métodos de inferência e defuzzificação. Os resultados indicam que os sistemas *fuzzy* estudados apresentaram desempenho satisfatório com inferência Mamdani e defuzzificação centroide, bissetor e *mom*, além da inferência Sugeno com defuzzificação *wtaver* e *wtsum*. O coeficiente de correlação R^2 variou de 0,9707 (sistema como pior desempenho) a 0,9749 (sistema com melhor desempenho), tendo em vista que os sistemas nos quais o teste t foram significativos não são considerados. Os diferentes métodos de inferência e defuzzificação exercem influência no resultado final.

O melhor desempenho nas análises estatísticas foi obtido pelo sistema *fuzzy* com método de inferência Mamdani e defuzzificação centroide, sendo obtido os melhores resultados nos índices t-test, Bias, MSE, R^2 e RMSE.

A maioria dos sistemas propostos se mostraram confiáveis e capazes de fornecer resultados com alta precisão, tornando possível afirmar que a implementação de lógica *fuzzy* na tecnologia do concreto é viável e contribui significativamente para o avanço tecnológico da construção civil.

REFERÊNCIAS

- [1] G. Dogan, M.H. Arslan, M. Ceylan, Concrete compressive strength detection using image processing based new test method, *Meas. J. Int. Meas. Confed.* 109 (2017) 137–148. <https://doi.org/10.1016/j.measurement.2017.05.051>.
- [2] F. Khademi, S.M. Jamal, N. Deshpande, S. Londhe, Predicting strength of recycled aggregate concrete using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and Multiple Linear Regression, *Int. J. Sustain. Built Environ.* 5 (2016) 355–369. <https://doi.org/10.1016/j.ijbsbe.2016.09.003>.
- [3] D. Feng, J. Li, Stochastic Nonlinear Behavior of Reinforced Concrete Frames. II: Numerical Simulation, *J. Struct. Eng.* 142 (2016) 04015163. [https://doi.org/10.1061/\(asce\)st.1943-541x.0001443](https://doi.org/10.1061/(asce)st.1943-541x.0001443).
- [4] D. Feng, X. Ren, J. Li, Stochastic damage hysteretic model for concrete based on micromechanical approach, *Int. J. Non. Linear. Mech.* 83 (2016) 15–25. <https://doi.org/10.1016/j.ijnonlinmec.2016.03.012>.
- [5] D.C. Feng, Z.T. Liu, X.D. Wang, Y. Chen, J.Q. Chang, D.F. Wei, Z.M. Jiang, Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach, *Constr. Build. Mater.* 230 (2020) 117000. <https://doi.org/10.1016/j.conbuildmat.2019.117000>.
- [6] P. Chopra, Sharma, R K., M. Kumar, Regression models for the prediction of compressive strength of concrete with & without fly ash, *Int. J. Latest Trends Eng. Technol.* 3 (2014) 400–406.
- [7] R. Rajeshwari, S. Mandal, Prediction of compressive strength of high-volume fly ash concrete using artificial neural network, *Lect. Notes Civ. Eng.* 25 (2019) 471–483. https://doi.org/10.1007/978-981-13-3317-0_42.
- [8] V. Agrawal, B.K. Panigrahi, P.M.V. Subbarao, Review of control and fault diagnosis methods applied to coal mills, *J. Process Control.* 32 (2015) 138–153. <https://doi.org/10.1016/j.jprocont.2015.04.006>.
- [9] D. Pacheco Bautista, E. Cortés Rito, F. Aguilar Acevedo, Diseño de un controlador de carga de tres etapas para sistemas fotovoltaicos usando lógica difusa, *Ingeniare. Rev. Chil. Ing.* 27 (2019) 540–550. <https://doi.org/10.4067/s0718-33052019000400540>.
- [10] B. Abolpour, B. Abolpour, R. Abolpour, H. Bakhshi, Estimation of concrete compressive strength by a fuzzy logic model, *Res. Chem. Intermed.* 39 (2013) 707–719. <https://doi.org/10.1007/s11164-012-0591-0>.
- [11] G. Tayfur, T.K. Erdem, Ö. Kirca, Strength Prediction of High-Strength Concrete by Fuzzy Logic and Artificial Neural Networks, *J. Mater. Civ. Eng.* 26 (2014) 04014079. [https://doi.org/10.1061/\(asce\)mt.1943-5533.0000985](https://doi.org/10.1061/(asce)mt.1943-5533.0000985).
- [12] A. Zehtabchi, S.A.H. Hashemi, S. Asadi, Predicting the strength of polymer-modified thin-layer asphalt with fuzzy logic, *Constr. Build. Mater.* 169 (2018) 826–834. <https://doi.org/10.1016/j.conbuildmat.2018.02.002>.
- [13] K.M. Hamdia, M. Arafa, M. Alqedra, Structural damage assessment criteria for reinforced concrete buildings by using a Fuzzy Analytic Hierarchy process,

- Undergr. Sp. 3 (2018) 243–249. <https://doi.org/10.1016/j.undsp.2018.04.002>.
- [14] A. T. Gurmu, A. Krezel, C. Ongkowijoyo, Fuzzy-stochastic model to asses defects in low-rise residential buildings, *Journal of Building Engineering*. 40 (2021). <https://doi.org/10.1016/j.jobbe.2021.102318>.
- [15] M.V. Biezma, D. Agudo, G. Barron, A Fuzzy Logic method: Predicting pipeline external corrosion rate, *Int. J. Press. Vessel. Pip.* 163 (2018) 55–62. <https://doi.org/10.1016/j.ijpvp.2018.05.001>.
- [16] L.M.F. Maués, B. do M.O. do Nascimento, W. Lu, F. Xue, Estimating construction waste generation in residential buildings: A fuzzy set theory approach in the Brazilian Amazon, *J. Clean. Prod.* 265 (2020). <https://doi.org/10.1016/j.jclepro.2020.121779>.
- [17] I.-C. Yeh, Modeling of Strength of High-Performace Concrete Using Artificial Neural Networks, *Cement and Concrete Research*. 28 (1998) 1797-1808.
- [18] MATHWORKS. MATLAB: Fuzzy Logic Toolbox™: User’s Guide. Natick, 2020. 782p.
- [19] E.H. Mamdani, Application of fuzzy algorithms for control of simple dynamic plant. *Proceedings of the Institution of Electrical Engineers Control & Science*. 121 (1974)
- [20] T. Takagi, M. Sugeno, Fuzzy Indentification of Systems and Its Applications to Modeling and Control. *IEEE Transactions on Systems, Mam, and Cybernetics*. 15 (1985)
- [21] Cornelissen et al., Eliciting Expert Knowledge for Fuzzy Evaluation of Agricultural Production Systems, (2003).
- [22] S. Naaz, A. Alam, R. Biswas, Effect of different defuzzification methods in a fuzzy based load balancing application, *Ijcsi*. 8 (2011) 261–7.
- [23] S. Akkurt, G. Tayfur, S. Can, Fuzzy logic model for the prediction of cement compressive strength, *Cem. Concr. Res.* 34 (2004) 1429–1433. <https://doi.org/10.1016/j.cemconres.2004.01.020>.
- [24] G. Tayfur, T.K. Erdem, Ö. Kırca, Strength Prediction of High-Strength Concrete by Fuzzy Logic and Artificial Neural Networks, *J. Mater. Civ. Eng.* 26 (2014) 04014079. [https://doi.org/10.1061/\(asce\)mt.1943-5533.0000985](https://doi.org/10.1061/(asce)mt.1943-5533.0000985).
- [25] P. Aggarwal, Prediction of compressive strength of self-compacting concrete with fuzzy logic, *World Acad. Sci. Eng. Technol.* 77 (2011) 847–854. <https://doi.org/10.5281/zenodo.1330501>.
- [26] F. Falade, T. Iqbal, Compressive strength Prediction recycled aggregate incorporated concrete using Adaptive Neuro-Fuzzy System and Multiple Linear Regression, *Int. J. Civil, Environ. Agric. Eng.* 1 (2019) 19–24. <https://doi.org/10.34256/ijceae1913>.
- [27] Y. Sharifi, M. Hosseinpour, Adaptive neuro-fuzzy inference system and stepwise regression for compressive strength assessment of concrete containing metakaolin, *Iran Univ. Sci. Technol.* 9 (2019) 251–272.
- [28] M.T. Cihan, Prediction of Concrete Compressive Strength and Slump by Machine

- Learning Methods, Adv. Civ. Eng. 2019 (2019).
<https://doi.org/10.1155/2019/3069046>.
- [29] K. Nasrollahzadeh, E. Nouhi, Fuzzy inference system to formulate compressive strength and ultimate strain of square concrete columns wrapped with fiber-reinforced polymer, Neural Comput. Appl. 30 (2016) 69–86.
<https://doi.org/10.1007/s00521-016-2658-0>.
- [30] Q. Zhou, F. Wang, F. Zhu, Estimation of compressive strength of hollow concrete masonry prisms using artificial neural networks and adaptive neuro-fuzzy inference systems, Constr. Build. Mater. 125 (2016) 417–426.
<https://doi.org/10.1016/j.conbuildmat.2016.08.064>.

CONSIDERAÇÕES FINAIS

Os resultados do primeiro artigo indicam que a aplicação de redes neurais artificiais na predição da resistência à compressão axial do concreto de cimento Portland fornecem resultados precisos, com MSE médio da ordem de 27,4318 e coeficiente de correlação R médio de 0,96559.

Por sua vez, os resultados do segundo artigo indicam que a implementação de sistemas *fuzzy* para predição da resistência a compressão axial do concreto de cimento Portland também fornecem resultados de altíssima precisão. Foi obtido MSE da ordem de 6,9985 (melhor sistema) a 13,5443 (pior sistema) e coeficiente de correlação R^2 variou de 0,9707 (sistema como pior desempenho) a 0,9749 (sistema com melhor desempenho). Os sistemas nos quais o teste t foram significativos não são considerados. Observou-se também que os métodos de inferência e defuzzificação utilizados exercem influência no resultado final.

Tendo em vista os expressivos fatores de segurança empregados no dimensionamento estrutural em concreto armado, que evidentemente cobrem pequenos desvios na resistência dos materiais empregados, minorando a resistência do concreto e majorando as ações que atuam na estrutura é possível afirmar que os resultados obtidos são satisfatórios para os padrões da tecnologia do concreto. Com isso, outros trabalhos de pesquisa podem ser desenvolvidos com o intuito de verificar a possibilidade de implementação de outras técnicas de inteligência computacional como redes *neuro-fuzzy*, florestas aleatórias e algoritmos genéticos, além de verificar a eficácia das técnicas de inteligência computacional na predição de outras propriedades do concreto, como o módulo de elasticidade e o abatimento de tronco de cone.