



2026

Abordagens de aprendizado de máquina para previsão da resistência do concreto

Jorge Freitas da Silva Filho^a; Sidiclei Formagini^b

^a Aluno de Graduação em Engenharia Civil, jfreitassjfreitas.filho@gmail.com

^b Professor Orientador, Doutor, sidiclei.formagini@ufms.br

Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia. Universidade Federal de Mato Grosso do Sul. Av. Costa e Silva, s/nº | Bairro Universitário | 79070-900 | Campo Grande, MS, Brasil.

RESUMO

Este estudo aborda a melhoria do controle de qualidade na produção de concreto usinado, considerando o gargalo do prazo de 28 dias para aceitação da resistência à compressão (f_{ck}) e a sensibilidade do desempenho às variações de matérias-primas, umidade e operações. Propõe-se o uso de modelos preditivos para antecipar e verificar a adequação do traço antes da moldagem e ensaio das amostras. Com base na tríade produtor de concreto, laboratório e construtora, o trabalho avalia, no MATLAB, a eficácia de modelos de Regressão Linear e Redes Neurais Artificiais para prever a resistência do concreto, principalmente aos 28 dias, utilizando um banco de dados histórico de laboratório, composto pela amostragem de 113 traços experimentais para treinamento e de 10 traços para validação. As variáveis de entrada incluíram o tipo de cimento, agregados, água e aditivos químicos, sendo a saída a resistência à compressão. Nos modelos de **Regressão Linear** os melhores desempenhos foram obtidos com o algoritmo *Ensembles of Trees* (RMSE do treinamento 7,342 e eficiência média de teste de 87,94%). As análises gráficas indicaram bom ajuste de previsibilidade na faixa de resistência do concreto entre 20 e 40 MPa. Para as **Redes Neurais Artificiais**, tendo como base de cálculo o algoritmo de treinamento *Levenberg–Marquardt*, as eficiências médias de teste foram mais baixas em comparação com a Regressão Linear. Em resumo, a regressão mostrou-se a alternativa mais confiável e de implementação imediata como ferramenta de verificação rápida e ajuste proativo de traços, enquanto as RNAs, embora teoricamente aptas a capturar não linearidades, exigiriam um conjunto de dados muito maior e mais completo para mitigar o sobre ajuste.

Palavras-chave: Concreto usinado; Resistência à compressão; Traço de concreto; Redes Neurais Artificiais; Regressão Linear; e Previsibilidade

ABSTRACT

This study addresses the improvement of quality control in ready-mixed concrete production, considering the bottleneck posed by the 28-day waiting period required to accept compressive strength (f_{ck}), as well as the sensitivity of performance to variations in raw materials, moisture, and operations. The use of predictive models is proposed to anticipate and verify the adequacy of the concrete mix before molding and testing the samples. Based on the triad of concrete producer, laboratory, and construction company, the study evaluates, in MATLAB, the effectiveness of Linear Regression and Artificial Neural Network models to predict concrete strength, mainly at 28 days, using a historical laboratory database composed of hundreds of mix designs. The data were then divided into 113 mixes for training and 10 for testing. The input variables included type of cement, aggregates, water, plasticizer, and superplasticizer, with compressive strength as the output. In the Linear Regression models, the best performances were obtained with the Ensembles of Trees algorithm (training RMSE 7.342 and average test efficiency of 87.94%). Graphical analyses indicated a good fit in predictability within the concrete strength range of 20 to 40 MPa. For Artificial Neural Networks, using the Levenberg–Marquardt training algorithm as the calculation basis, the average test efficiencies were lower compared to Linear Regression. In summary, regression proved to be the most reliable and immediately implementable alternative as a tool for quick verification and proactive adjustment of mix designs, while ANNs, though theoretically able to capture nonlinearities, would require a much larger and more complete dataset to mitigate overfitting.

Keywords: Ready-mixed concrete; Compressive strength; Concrete mix design; Artificial Neural Networks; Linear Regression; and Predictability

1. INTRODUÇÃO

Além de desempenhar papel fundamental no desenvolvimento econômico e social, ser responsável por grande parte dos investimentos em infraestrutura e edificações, o setor da construção civil mantém-se como um dos pilares de crescimento acelerado da economia, elevando a demanda por concreto usinado e a necessidade de precisão técnica em sua produção. Nesse cenário, a tríade formada pela central de concreto (concreteira), o laboratório de ensaios e a construtora constitui o fundamento da segurança estrutural e da viabilidade econômica das obras. O laboratório atua como agente de controle de qualidade, sendo responsável pela elaboração do "traço", que garante parâmetros como a resistência característica à compressão (f_{ck}), durabilidade e consistência (abatimento). (Airlangga, 2024, p. 28-41; Ziolkowski & Nie-dostatkie-wicz, 2019, p.1256)

A resistência à compressão do concreto, usualmente avaliada aos 28 dias, constitui um dos principais parâmetros de aceitação do material em projetos estruturais, conforme estabelecido em normas técnicas. Para garantir o atendimento à resistência característica especificada (f_{ck}), as usinas de concreto solicitam aos laboratórios especializados estudos de dosagem que definem o traço adequado, considerando as propriedades dos materiais disponíveis, a classe de agressividade ambiental, a consistência desejada e o método de lançamento.

Entretanto, o processo tradicional de validação do traço apresenta limitações relevantes. O tempo mínimo de 28 dias necessário para a obtenção do resultado final de resistência, aliado à possibilidade de não conformidade nos ensaios, pode gerar retrabalhos, desperdício de materiais, aumento de custos e atrasos no atendimento às obras (Verma et al., 2022, p.12031). Além disso, pequenas variações na caracterização dos insumos, na correção de umidade dos agregados ou no controle operacional da usina podem impactar significativamente o desempenho do concreto produzido.

Diante desse cenário, torna-se desejável a utilização de ferramentas capazes de prever, de forma antecipada e confiável, a resistência à compressão do concreto aos 28 dias a partir dos parâmetros do traço. Métodos estatísticos e computacionais, como a Regressão Linear e as Redes Neurais Artificiais (RNAs), têm sido amplamente aplicados em problemas de engenharia por permitirem a modelagem de relações entre variáveis independentes e respostas de interesse, com base em dados históricos experimentais (Airlangga,

2024, p. 28-41; Khademi et al., 2017, p. 90-99). Enquanto a Regressão Linear apresenta simplicidade e interpretabilidade, as RNAs destacam-se pela capacidade de capturar relações não lineares complexas, frequentemente presentes em materiais cimentícios.

Portanto, o objetivo geral é avaliar a eficácia de modelos de Regressão Linear e Redes Neurais Artificiais (RNAs) na predição da resistência à compressão do concreto, fazendo uso do software Matlab.

Os objetivos específicos são:

- a) Compilar um banco de dados histórico de um laboratório de análise de concreto, com resultados de rompimentos de corpos de prova, preparando-os para serem usados no treinamento das redes neurais artificiais, tendo em vista as peculiaridades do Matlab.
- b) Comparar a precisão entre modelos lineares interpretáveis (regressão linear) e a capacidade de aprendizado de padrões complexos das RNAs.
- c) Verificar a viabilidade de utilizar resultados parciais de resistência à compressão nas idades de 7 e 14 dias para ajustes proativos no traço final.
- d) Propor um modelo de cálculo baseado na IA.

2. REFERENCIAL TEÓRICO

2.1. Regressão Linear Simples

A regressão linear é uma das ferramentas mais poderosas e fundamentais da estatística e do aprendizado de máquina. Ela nos permite entender como diferentes variáveis se relacionam e, mais importante, usar essa relação para prever o futuro. (Kohli et al., 2020, p.321-329; Roustaei, 2024, p. 151-159)

A regressão linear trabalha com duas variáveis: a dependente (Y), que é aquela que se quer prever, a variável de saída (no nosso estudo, a resistência à compressão do concreto), e a independente, que são as variáveis de entrada, os fatores usados para explicar Y (no nosso estudo, os componentes do traço). (Khademi et al., 2017, p. 90-99)

A fórmula básica é:

$$Y = \beta_0 + \beta_1 X + \epsilon \quad (1)$$

Onde β_0 é o ponto de partida (intercepto), β_1 é a inclinação da reta (coeficiente) e ϵ é a representação do erro aleatório.

Para que a regressão linear seja confiável, os dados devem respeitar quatro condições principais:

- a) Linearidade: A relação entre X e Y deve ser, aproximadamente, uma linha reta.
- b) Independência: As observações devem ser independentes entre si (o erro de um dado não deve prever o erro de outro).
- c) Homocedasticidade: A variação dos erros deve ser constante. Ou seja, a "nuvem" de pontos não deve abrir como um leque à medida que X aumenta.
- d) Normalidade dos Erros: Para fins de testes estatísticos, os resíduos (a diferença entre o valor real e o previsto) devem seguir uma distribuição normal (curva de sino).

Para fazer uso da regressão linear, o modelo deve ser ajustado e os resultados devem ser interpretados. Ajustar o modelo significa encontrar os valores de β que minimizam a distância entre a linha e os pontos reais (método dos Mínimos Quadrados). (Hubert & Branden, 2003, p. 537-549)

- a) Coeficiente Beta (β_1): Indica quanto Y muda para cada unidade de aumento em X. Se $\beta_1=2$, significa que se X aumenta 1, Y aumenta 2.
- b) R-Quadrado (R^2): É uma medida de 0 a 1 que indica o quanto o modelo explica a variação dos dados.
 - R² = 0,90: O modelo explica 90% da variação. Excelente!
 - R² = 0,10: O modelo explica apenas 10%. Algo está faltando.

Para se avaliar a qualidade dos resultados da regressão linear não basta criar a reta; é preciso saber se ela funciona na prática. Para isso é preciso ficar atento às seguintes informações:

- a) Erro de Previsão (RMSE): Calcula a média da diferença entre o previsto e o real. Quanto menor, melhor.
- b) *Overfitting* (Sobreajuste): Ocorre quando o modelo "decora" os dados atuais, mas falha com os novos. Ele fica complexo demais.
- c) Validação Cruzada: Técnica onde você treina o modelo com uma parte dos dados e testa com outra parte que ele nunca viu.

2.2. Rede Neural Artificial


2.2.1 Gênese

O desenvolvimento das Redes Neurais Artificiais (RNAs) fundamenta-se no mimetismo biológico, buscando replicar a capacidade de processamento de informações do cérebro humano em sistemas computacionais. (Schmidgall et al., 2024, v.2, n.2)

A comparação entre o neurônio biológico e o artificial é o alicerce do paradigma conexionista. O paradigma conexionista é uma abordagem na ciência da computação e neurociência cognitiva que modela processos mentais e de *machine learning* inspirados pela estrutura do cérebro humano. Baseia-se na ideia de que a inteligência emerge de redes interconectadas de unidades simples de processamento, que seriam análogas aos neurônios. (Arshavsky, 2016, p. 341-355; Cohen et al., 2022, p. 8514-8523)

Neurônio Biológico (Figura 1) é composto por dendritos (entrada de sinais), corpo celular (processamento/soma) e axônio (transmissão do impulso via sinapses).


Figura 1 - Neurônio biológico



Fonte: Gemini Generated Image

Neurônio Artificial (Figura 2) é estruturado em sinais de entrada (equivalentes aos dendritos), pesos sinápticos (que determinam a força da conexão, são os " w_n " da entrada na Fig 2), uma função de soma e uma função de ativação que determina a saída (equivalente ao axônio). (Gundogdu et al., 2015, p. 927-935)

Figura 2 – Neurônio artificial



Fonte: Gemini Generated Image

2.2.2 Estrutura e Mecânica do Neurônio Artificial

A unidade fundamental de uma RNA opera como um integrador de sinais. O processo matemático de

processamento em um neurônio artificial (ou *perceptron*) segue uma sequência lógica rigorosa: (Kiranyaz et al., 2017, p. 247-2485; Ritter & Urcid, 2003, p. 282-295)

a) Entradas e Pesos (x_i e w_i): Cada dado de entrada x é multiplicado por um peso w , que representa a relevância daquela informação para o modelo.

b) Somatório Ponderado: O neurônio realiza a soma de todos os sinais de entrada ponderados, adicionando-se um termo de polarização denominado bias (b), responsável por deslocar a curva da função de ativação para melhor ajuste aos dados. (Biswas & Fitzgerald, 2022, v.4, n.2)

$$net = \sum_{i=1}^n (x_i * w_i) + b \quad (2)$$

c) Função de Ativação: O resultado da soma é submetido a uma função não linear (como Sigmoid, ReLU ou Tangente Hiperbólica). Esta função define se o neurônio deve "disparar" um sinal para a camada seguinte, permitindo que a rede apreenda padrões complexos e não lineares. (Chang et al., 2019, p. 1-2)

d) Treinamento e Ajuste de Pesos: O aprendizado ocorre via minimização de uma função de erro. Através de algoritmos de otimização, os pesos são recalibrados iterativamente para que a diferença entre a saída prevista e a real seja minimizada. (Kinaneva et al., 2021, p. 1-6)

2.2.3 Metodologias de Previsão e Conceitos Operacionais

As RNAs são amplamente empregadas em tarefas de regressão e classificação para previsão de dados futuros. As abordagens variam conforme a natureza do problema:

a) Aprendizado Supervisionado: O modelo é treinado com um conjunto de dados rotulados, onde a resposta correta é conhecida. É a base para a maioria das previsões de engenharia e economia. O treinamento é baseado nos padrões dos dados de entrada. (Kampezidou et al., 2024, p.384-416)

b) Algoritmo de Retropropagação (*Backpropagation*): É o mecanismo central de treinamento em redes multicamadas (*Multilayer Perceptron* - MLP). Ele propaga o erro da saída de volta para as camadas ocultas, ajustando os pesos proporcionalmente à contribuição de cada neurônio para o erro total. (Verma, 1997, p.1314-1320)

2.2.4 Os principais pontos para o desenvolvimento são:

a) Treinamento e Validação: Divisão do banco de dados para ensinar o modelo e, posteriormente, testar sua capacidade de resposta em dados não vistos durante o ajuste. (Karayiannis & Mi, 1997, p. 1492-1506)

b) Generalização: A habilidade da rede de produzir resultados coerentes para entradas inéditas.

c) *Overfitting*: Ocorre quando o modelo "decora" os ruídos dos dados de treinamento, perdendo sua capacidade de generalização e falhando ao ser aplicado em cenários reais.

O *overfitting* acontece quando um modelo aprende demais os dados de treinamento, a ponto de captar ruídos, erros e particularidades específicas desse conjunto de dados, em vez de aprender o padrão geral do fenômeno estudado. Dessa forma, o modelo passa a "decorar" os dados usados para treiná-lo. Ele apresenta excelente desempenho nos dados de treinamento, porém, quando é aplicado a novos dados (cenários reais), seu desempenho cai significativamente. E isso ocorre porque o modelo fica excessivamente complexo em relação à quantidade ou à qualidade dos dados disponíveis, perdendo a capacidade de generalização, que é justamente o objetivo principal de modelos estatísticos e de aprendizado de máquina. No exemplo do contexto da previsibilidade da resistência do concreto, um modelo que prevê a resistência aos 28 dias pode se ajustar perfeitamente aos ensaios de laboratório usados no treinamento, mas falhar ao prever a resistência de um novo traço produzido em condições reais de obra, pois aprendeu detalhes específicos daqueles ensaios e não o comportamento geral do material. (Zhu, 2024, p. 353-359)

d) A transição de modelos estatísticos lineares para modelos de aprendizado de máquina representa uma mudança paradigmática: abandona-se a modelagem estritamente matemática do fenômeno em favor de uma modelagem baseada em dados, capaz de captar nuances que métodos tradicionais frequentemente ignoram. (Letzgu et al., 2022, p. 40-58)

2.3. HIPÓTESES E LIMITAÇÕES

2.3.1. Hipóteses

Espera-se que as Redes Neurais Artificiais, por serem aproximadores universais de funções, apresentem resultados mais abrangentes e precisos que a Regressão

Linear em cenários de dados heterogêneos. (Adeli, 2001, p. 126-142)

2.3.2. Limitações

O sucesso da previsão está estritamente condicionado à qualidade e limpeza do banco de dados fornecido pelo laboratório. (Bu et al., 2021, p. 3921)

3. METODOLOGIA USADA NA PESQUISA

O trabalho é desenvolvido por meio de métodos quantitativos, com base em experimentos e análise dos dados obtidos de diversos ensaios de compressão de corpo de prova realizados por um laboratório de análise de concreto. O método consiste na alimentação de algoritmos de aprendizado de máquina com dados históricos de ensaios de laboratório (caracterização de insumos, f_{ck} , idade de controle e slump). Serão treinados modelos de Regressão Linear para identificar tendências globais e Redes Neurais para capturar nuances não-lineares, validando-os com dados de rompimento real de 28 dias, podendo ser estendida a pesquisa para os rompimentos de 7 e 14 dias.

O fluxo de atividades que compõem o ciclo do concreto usinado é formado pelas seguintes fases: (1) Planejamento e Especificação Técnica, de responsabilidade da construtora; (2) Contratação e Homologação de Insumos, de responsabilidade da construtora e

concreteira; (3) Estudo de Dosagem do Traço, de responsabilidade do laboratório; e (4) Programação Operacional, Produção, Transporte e Entrega, de responsabilidade da concreteira.

Definido do f_{ck} do concreto, inicia-se o estudo de dosagem em laboratório. O traço é produzido experimentalmente com base numa quantidade de insumos e são moldados corpos de prova para serem ensaiados à compressão nas idades de 7, 14 e 28 dias.

Os resultados experimentais foram fornecidos por um laboratório privado, com amostragem de 123 concretos, sendo 113 amostras para o treinamento de Redes Neurais Artificiais e Regressão Linear e 10 resultados para validação do modelo.

O banco de dados (Tabela 1) é composto por várias classes de resistência, cada uma detalhando os resultados de dosagem para misturas solicitadas para diversas condições, como abatimento e resistência em diversas idades. Por exemplo, a planilha correspondente a $f_{ck} = 10$ MPa inclui todas as misturas e suas respectivas dosagens solicitadas por usinas de concreto e construtoras ao longo de mais de dez anos. Este banco de dados abrangente cobre dosagens para valores de f_{ck} que variam de 10 MPa a 50 MPa.

Tabela 1 – Banco de dados de traços do Laboratório (2014 a 2025)

Ident.	Datas		Idt	Resistência do Concreto				Relação	Classe	Materiais	
Traço	Moldagem	Ruptura	Ensaio	Carga	Tensão	Média	C. Var (%)	Resistência.	Abatimento	Descrição	Consumo
			dias	(kN)	(MPa)	(MPa)		f_{ci}/f_{c28}	(cm)		(kg/m³)
TR02	01/12/14	02/12/14	1	45.5	5.8	5.8	0.0	0.19	8 a 12	CP II F 32	391
		04/12/14	3	122.1	15.5	15.1	4.4	0.50		Escória de Alto-forno	
				114.8	14.6				Ex-per.:	Sílica ativa	
		08/12/14	7	157.6	20.1	20.5	3.1	0.69	13 cm	Areia Fina	691
				261.8	33.3					Pedrisco	
				196.6	25.0					Brita nº0	
		02/02/15	63	283.9	36.1	36.1	0.0	1.21		Brita nº1	1063
				283.9	36.1					Brita nº2	
		01/06/15	182	331.7	42.2	42.2	0.0	1.46		SPlastificante	
				331.7	42.2					Água	203
TR21	20/05/15	21/05/15	1	63.1	8.0	8.0	0.3			CP II F 32	378
				62.8	8.0					Escória de Alto-forno	
		23/05/15	3	120.9	15.4	15.4	0,5%		Ex-per.:	Sílica ativa	

Dosagem $f_{ck}=10$ MPa Dosagem $f_{ck}=15$ MPa Dosagem $f_{ck}=20$ MPa **Dosagem $f_{ck}=25$ MPa** Dosagem $f_{ck}=30$ MPa Dosagem $f_{ck}=35$ MPa Dosagem $f_{ck}=40$ MPa Dosagem $f_{ck}=45$ MPa Dosagem $f_{ck}=50$ MPa

Fonte: Mecfor Engenharia Ltda

Para usar as informações desse banco de dados no MatLab, há necessidade de se preparar a planilha, eliminando informações desnecessárias, inconsistentes e lacunas com insumos não utilizados.

essa nova planilha ajustada, os dados de entrada no software são os valores dos insumos da dosagem e a saída é o valor do f_{ck} em data determinada. (Tabela 2)

Tabela 2 – Banco de dados com os traços adaptados ao modelo

CPV (Kg/m ³)	CP32 (Kg/m ³)	CP40 (Kg/m ³)	AgrF (Kg/m ³)	AgrM (Kg/m ³)	AgrG (Kg/m ³)	Pdrc (Kg/m ³)	Brt_0 (Kg/m ³)	Brt_1 (Kg/m ³)	Brt_2 (Kg/m ³)	Ág (Kg/m ³)	Plast (Kg/m ³)	SPst (Kg/m ³)	fc7d (MPa)	fc14d (MPa)	fc28d (MPa)	fc63d (MPa)
--	--	360	--	807	--	--	580	454	--	179	2.9	--	33.0	34.1	37.3	40.3
--	315	--	803	--	--	394	--	758	--	202	--	--	15.7	21.1	22.1	0.0
--	450	--	745	--	--	336	--	790	--	195	--	--	20.8	28.0	31.2	0.0
--	340	--	796	--	--	920	--	--	--	214	--	--	15.0	18.8	20.2	20.1
--	260	--	801	--	--	394	--	803	--	199	--	--	14.3	16.5	17.1	0.0
--	370	--	784	--	--	372	--	749	--	200	--	--	19.5	0.0	23.6	27.0
--	264	--	1489	--	--	--	--	--	--	346	--	--	0.0	0.0	6.6	0.0
--	415	--	--	752	--	--	1070	--	--	197	--	--	19.5	23.8	0.0	0.0
290	--	--	752	--	165	--	508	508	--	202	--	--	29.2	36.6	0.0	0.0

Fonte: Autor

(CPV=Cimento Portland ARI; CP32=Cimento Portland 32MPa; CP40= Cimento Portland 40MPa; AgrF=Agregado Fino; AgrM=Agregado Médio; AgrG=Agregado Graúdo; Pdrc=Pedrisco; Brt_0=Brita 0; Brt_1=Brita 1; Brt_2=Brita 2; Ag=Água; Plast=Plastificante; Spst=Superplastificante; Fc7d= F_{ck} da resistência do concreto com 7 dias)

Os dados de entrada da rede são: (1) o tipo de cimento, podendo ser o CPV ARI, CP II F/E/Z 32 e o CP II F 40; (2) agregado miúdo fino; (3) agregado miúdo médio; (4) agregado graúdo; (5) agregado graúdo pedrisco; (6) agregado brita 0; (7) agregado graúdo brita 1; (8) agregado graúdo brita 2; (9) água; (10) plastificante; e (11) superplastificante. Na saída da rede temos o resultado da resistência do concreto na data de 28 dias. Existe a possibilidade de análise ser estendida para as datas de 7, 14 e 63 dias.

O processo para se encontrar o menor percentual de erro no levantamento da previsibilidade da resistência do concreto, é por tentativa e erro. No caso da Regressão Linear, os dados serão rodados até que se encontre o menor Erro de Previsão (RMSE), para as Redes Neurais Artificiais, serão feitas mudanças na arquitetura da rede para se encontrar a melhor resposta, com alterações do número de neurônios na camada oculta, bem com a alternância dos algoritmos de análise de previsibilidade. (Khademi et al., 2017, p. 90-99; Nikoo et al., 2015, p. 1-8)

Depois de ser encontrado a melhor resposta da rede treinada e testada, o código que gerou a previsibilidade será copiado para futuras aplicações em novos traços a serem elaborados pelo laboratório de análise de concreto.

4. MODELOS DE PREVISIBILIDADE

Nem todos os traços elaborados pelo laboratório são constituídos com os mesmos insumos. Isso faz com que o banco de dados em estudo apresente diversas lacunas, como pode ser observado na Tabela 2.

Para tratar as lacunas do banco de dados, foram tomadas as seguintes diretrizes: (1) preenchimento das lacunas com “zeros”; (2) preenchimento das lacunas com valores muito pequenos em comparação com as quantidades de insumos de cada coluna. As colunas dos insumos que não contribuíram na confecção dos traços foram deletadas (Tabelas 3 e 4).

Tabela 3 – Banco de dados com lacunas zeros

C_CPV	CPF32	CPF40	Agr_F	AgrM	Agr_G	Ptrc	Brt_0	Brt_1	Brt_2	Ág	Plast	SPlast	fc_28d
0	0	360	0	807	0	0	580	454	0	179	2.9	0	37.3
0	315	0	803	0	0	394	0	758	0	202	0	0	22.1
0	450	0	745	0	0	336	0	790	0	195	0	0	31.2
0	340	0	796	0	0	920	0	0	0	214	0	0	20.2

Fonte: Autor

Tabela 4 – Banco de dados com lacunas de valores pequenos

CCPV	CPF32	CPF41	AgrF	AgrM	AgrG	Pttrc	Brt1	Brt1	Brt2	Ag	Plast	SPlast	fc28d
1	1	361	1	817	1	1	581	454	1	179	2.9	0.001	37.3
1	315	1	813	1	1	394	1	758	1	202	0.001	0.001	22.1
1	451	1	745	1	1	336	1	791	1	195	0.001	0.001	31.2
1	341	1	796	1	1	921	1	1	1	214	0.001	0.001	20.2
1	261	1	811	1	1	394	1	813	1	199	0.001	0.001	17.1
1	371	1	784	1	1	372	1	749	1	200	0.001	0.001	23.6
1	264	1	1489	1	1	1	1	1	1	346	0.001	0.001	6.6
1	261	1	811	1	1	394	1	813	1	199	0.001	0.001	17.1
1	282	1	1	715	1	287	874	1	1	197	0.001	1.8	25.5

Fonte: Autor

Após o ajuste da amostra de 123 traços selecionados do banco de dados, iniciou-se o estudo sobre a previsibilidade da resistência do concreto.

Esses traços ajustados foram separados em duas matrizes, uma de Treinamento, com 113 traços, e outra de Teste, com 10 traços não treinados.

4.1. Regressão Linear

No MatLab, utilizando o aplicativo de Regressão Linear, a matriz de treinamento foi implementada. Cabe salientar que na Regressão Linear essa matriz é salva com todas as quantidades de insumos que compõem os traços e respectivos valores da resistência do concreto rompido na data de 28 dias (semelhante às Tabelas 3 e 4).

Os traços da matriz de treinamento, 113 misturas, passa por uma “validação cruzada” (*crossvalidation*) que é um conjunto de procedimentos para avaliar e selecionar modelos de forma mais confiável, especialmente importante em redes neurais, que têm alta capacidade de ajuste.

A *crossvalidation* consiste em dividir a base de dados de forma aleatória em K subconjuntos (em que K é definido previamente, correspondendo ao número de iterações que serão feitas) com aproximadamente a mesma quantidade de amostras em cada conjunto dividido. A cada iteração, treino e teste, um conjunto formado por K-1 subconjuntos são utilizados para treinamento e o subconjunto restante será utilizado para teste, gerando um resultado de métrica para avaliação. Esse processo garante que cada subconjunto seja utilizado para teste em algum momento da avaliação do modelo.

Para o banco de dados com 113 traços, caso seja escolhido que o número de iterações seja 5, o banco de dados será dividido por esse valor, sendo uma parte

utilizada para teste e as demais para treinamento da regressão. (Figura 3)

Figura 3 – Divisão do banco de dados por *crossvalidation*



<https://medium.com>

O MatLab possibilita realizar o treinamento do banco de dados utilizando vários modelos de cálculo. Em se optar por rodar todos os modelos disponíveis, é possível verificar qual deles apresenta o menor valor de Erro de Previsão (RMSE). Esse erro representa a média da diferença entre o valor previsto e o valor real. Quanto menor, melhor.

4.1.1. Matriz de Treinamento com Zeros Preenchendo as Lacunas

Ao se compilar esse banco de dados e depois de serem feitas todas as simulações, o modelo *Ensembles of Trees* (Conjunto de Árvores) apresentou o menor RMSE = 7,342. Com esse valor, foi possível realizar todos os estudos relacionados à melhor performance de regressão linear. Esse modelo, posteriormente, foi exportado para servir de base de cálculo de previsibilidades futuras, com as 10 amostras previamente separadas.

Nessa primeira parte da pesquisa, observou-se que o percentual de acerto ficou em torno de 87,94%. Teve-

se previsão de resistência de traço com percentual de 99,11%. (Tabela 5)

Tabela 5 – Previsibilidade na Regressão preenchendo lacunas de insumos com zeros


CCPV	CPF32	CPF40	AgrF	AgrM	AgrG	Ptrc	Brt0	Brt1	Brt2	Ag	Plast	SPlast	fc28d	Pre- visão	%Acer- to
262	0	0	591	0	0	1286	0	0	0	121.5	0	0	24.9	29.45	81.74
0	365	0	0	748	0	0	1136	0	0	173.5	0	2.5	37.6	33.26	88.47
0	0	280	308	513	0	0	0	1091	0	191.6	0	2.24	29.1	33.89	83.53
0	360	0	737	0	0	214	888	0	0	190.4	0	2.22	25.8	31.80	76.75
0	370	0	730	0	0	750	345	0	0	180.7	0	1.2	23.8	27.00	86.56
0	390	0	730	0	0	750	317	0	0	170.4	2.36	1.66	27.8	30.19	91.41
0	0	330	730	0	0	1135	0	0	0	180.1	1.65	1.98	37.4	33.47	89.50
0	0	310	748	0	0	1135	0	0	0	179.2	0.93	2.48	33.2	32.91	99.11
300	0	0	795	0	0	0	0	1096	0	191.5	2.4	0	41.3	37.86	91.68
321	0	0	748	0	0	0	0	1123	0	180.2	1.6	1.92	40.9	44.74	90.62
MÉDIA ACERTO															87.94

Fonte: Autor

A) Gráfico de Respostas (valor “real” versus valor “previsto”)

Na Figura 3 tem-se no eixo “x” o número de registro do banco de dados, os 113 traços. No “y”, a resistência de compressão do concreto na data de 28 dias correspondendo a cada traço. Os pontos azuis são os resultados reais de resistência do concreto registrado na tabela e os laranjas são os valores preditos, que no exemplo em pauta segue o modelo *Ensembles of Trees* (Conjunto de Árvores). O modelo acompanha razoavelmente bem a tendência geral dos valores reais. As previsões capturam o nível médio das resistências, bom ajuste de previsibilidade na faixa de 20 a 40 MPa, porém há dispersão significativa, além de ser observado que o modelo tende a suavizar extremos, acima de 40 Mpa (subestima valores altos de resistência e superestima valores muito baixos).

Figura 4 – Gráfico valor real versus previsto




Fonte: Matlab

Na análise, pode-se inferir que o modelo tem boa capacidade preditiva global, mas ainda apresenta erros relevantes na amostragem, especialmente em resistências com valores mais elevados.

B) Gráfico de Validação da Previsão versus Representação Ideal

Figura 5 – Gráfico validação (previsão versus ideal)



Fonte: Matlab

Observando a Figura 4, o eixo “x” representa as respostas reais da resistência do concreto correspondente aos traços da planilha de treinamento e o eixo “y” a resistência prevista pelo modelo selecionado (*Ensembles of Trees*). A linha diagonal significa a previsão perfeita, ou seja, os valores previstos serem exatamente os de entrada na rede.

A maioria dos pontos se distribui próxima à linha de previsão perfeita, indicando que o modelo captura


bem a tendência geral dos dados. Há boa capacidade preditiva na faixa de 20 a 40 MPa, onde se concentra a maior parte das observações. Para valores mais altos de resistência (> 45 MPa), observa-se maior dispersão e tendência de subestimação.

O modelo consegue prever adequadamente a resistência do concreto para a maior parte dos traços usuais, mas apresenta perda de precisão para resistências mais elevadas.

C) Gráfico de Validação Residual

O gráfico da Figura 6 refere-se à resíduos da previsão em função da resposta verdadeira, o que é muito comum em estudos de regressão aplicados à resistência do concreto.

Figura 6 – Gráfico Validação Residual



Fonte: Matlab

No eixo “x” encontra-se o valor real da resistência do concreto na data de 28 dias e no “y”, o erro do modelo. A linha horizontal representa a previsão perfeita, erro zero.

O modelo de *Ensembles of Trees* captura razoavelmente a tendência geral, mas apresenta erros sistemáticos que aumentam com o valor da resposta, especialmente para valores mais altos de resistência.

Com relação à tendência dos resíduos pode-se afirmar que:

a) Para valores baixos de resistência de ≈ 10 a 25 Mpa, os resíduos são predominantemente negativos o que indica superestimação da resistência pelo modelo. A diferença é feita subtraindo o valor real do previsto.

b) Para valores médios de ≈ 25 a 40 Mpa, os resíduos são mais concentrados em torno de zero, representando um melhor desempenho preditivo.

c) Para valores altos, acima de 40 Mpa, os resíduos são crescentemente e positivos, indicando subestimação da resistência do concreto.

Com a rede treinada e ajustada e depois de ter sido feita a análise gráfica da previsibilidade, o modelo pode ser salvo em forma de uma função e o código ser replicado em protótipos para a previsão da compressão do concreto, podendo ser usado como ferramenta de checagem de dados pelo laboratório.

4.1.2. Matriz de Treinamento com Unidades Preenchendo as Lacunas

Da mesma forma como na seção anterior, os dados foram compilados para que fossem feitas todas as simulações, e o algoritmo de aprendizado de máquina Linear SVM (*Support Vec-tor Machine Linear* ou Máquinas de Vetores de Suporte) apresentou o menor RMSE=7,2035, garantindo a melhor performance de regressão linear como será visto. Quando a matriz de teste foi compilada, com os 10 traços não treinados, novamente os resultados foram surpreendentes, o que pode ser constatado na Tabela 7.

Por se tratar valores de previsão próximos e a diferença entre as Médias de Acerto ser muito pequena, em comparação à matriz com preenchimento de lacunas com zeros (87,94 e 88,18), a análise gráfica feita no tópico anterior são é a mesma deste.

4.2. Redes Neurais Artificiais

A pesquisa da previsibilidade da resistência do concreto com o uso de Redes Neurais Artificiais é similar da Regressão Linear. No MatLab existe um aplicativo específico para esse fim, o *Neural Net Fitting*. A diferença do que foi feito no tópico anterior em comparação a este, é a manipulação das matrizes de treinamento e de teste, podendo variar a modelagem da arquitetura da rede, isso sem contar com a possibilidade de uso de três algoritmos para cada simulação dos treinamentos.

No treinamento, a matriz de entrada é dividida em duas: uma com 113 traços, sem o resultado da resistência do concreto (Tabela 8); e outra somente com o registro da compressão desses traços (Tabela 9). Uma terceira matriz, de teste, continua sendo a mesma, com 10 traços que não foram treinados para se obter a previsibilidade correspondente, tal qual foi feito na Regressão Linear.

Tabela 7 – Previsibilidade na Regressão preenchendo lacunas valores unitários (pequenos)

CCPV	CPF32	CPF41	AgrF	AgrM	AgrG	Ptrc	Br1	Br1	Br2	Ag	Plast	SPlast	fc28d	Previsão	%Acerto
262	1	1	591	1	1	1286	1	1	1	121.5	0.001	0.001	24.9	29.08	83.20
1	365	1	1	748	1	1	1136	1	1	173.5	0.001	2.5	37.6	32.84	87.36
1	1	281	318	513	1	1	1	1191	1	191.6	0.001	2.24	29.1	34.55	81.26
1	361	1	737	1	1	214	888	1	1	190.4	0.001	2.22	25.8	31.71	77.07
1	371	1	731	1	1	751	345	1	1	180.7	0.001	1.2	23.8	26.92	86.85
1	391	1	731	1	1	751	317	1	1	170.4	2.36	1.66	27.8	29.8	92.63
1	1	331	731	1	1	1135	1	1	1	180.1	1.65	1.98	37.4	33.11	88.53
1	1	311	748	1	1	1135	1	1	1	179.2	0.93	2.48	33.2	32.67	98.43
311	1	1	795	1	1	1	1	1196	1	191.5	2.4	0.001	41.3	38.7694	93.87
321	1	1	748	1	1	1	1	1123	1	180.2	1.6	1.92	40.9	43.915	92.63
MÉDIA ACERTO															88.18

Fonte: Autor

Tabela 8 – Entrada de dados com zeros nas lacunas

CCPV	CPF32	CPF40	AgrF	AgrM	AgrG	Ptrc	Br0	Br1	Br2	Ag	Plast	SPlast
0	0	360	0	807	0	0	580	454	0	179	2.9	0
0	315	0	803	0	0	394	0	758	0	202	0	0
0	450	0	745	0	0	336	0	790	0	195	0	0
0	340	0	796	0	0	920	0	0	0	214	0	0
0	260	0	801	0	0	394	0	803	0	199	0	0
0	370	0	784	0	0	372	0	749	0	200	0	0
0	264	0	1489	0	0	0	0	0	0	346	0	0
0	260	0	801	0	0	394	0	803	0	199	0	0
0	282	0	0	705	0	287	874	0	0	197	0	1.8

Fonte: Autor

Tabela 9 – Saída

fc28d
37.3
22.1
31.2
20.2
17.1
23.6
6.6
17.1
25.5

Fonte: Autor

Depois das matrizes de treinamento estarem prontas e alocadas, e antes de se rodar o aplicativo para encontrar a melhor performance da rede, são precisos algumas tomadas de decisão. Existe a possibilidade de se mudar o percentual de treinamento dos 113 dados da matriz de entrada em três partes: dados de treinamento propriamente dito; dados de validação; e dados de teste. Por padrão, esses percentuais são, respectivamente, 70% (que na pesquisa corresponde a 79 traços dos 113), 15% (17 traços); e 15% (17 traços).


O aplicativo foca em redes Multilayer Perceptron (MLP), composta de:

a) Camada Oculta, que por padrão é única, podendo ser expandida. O usuário define quantas camadas ocultas quer trabalhar e também quantos neurônios podem compor cada uma dessas camadas. Por padrão, o aplicativo apresenta uma camada com 10 neurônios.

b) Funções de Ativação: (1) Sigmoide Tangente Hiperbólica usada nas camadas ocultas,

para capturar não-linearidades; e (2) Linear, usada na camada de saída, para permitir qualquer valor de regressão. (Figura 7)

Figura 7 – Diagrama da rede



Fonte: Matlab

Existem três algoritmos que podem ser usados no treinamento da rede: (1) *Levenberg-Marquardt*, usado como padrão por ser o mais rápido, sendo o ideal para redes de tamanho moderado; (2) *Bayesian Regularization*, mais lento, porém excelente para dados ruidosos (irrelevante, incorretos ou indesejados) ou conjuntos pequenos; e (3) *Scaled Gradient*, recomendado para redes muito grandes ou com poucos recursos de memória. Por padrão o aplicativo seleciona o primeiro.

4.2.1. Matriz de Treinamento com Zeros Preenchendo as Lacunas

Depois de todos os preparativos prontos, o treinamento foi iniciado. Nesta fase são obtidos os resultados da rede treinada. Posteriormente, para que seja possível realizar a previsão da resistência do concreto, há necessidade de se exportar o código que foi gerado para ser usado na Matriz de Teste, com os 10 traços que não foram treinados, com o intuito de se aferir a performance da rede na previsão de dados futuros. Mais uma vez os resultados foram satisfatórios, com a melhor previsão sendo de 97,81%. (Tabela 10)


Tabela 10 – Previsibilidade na Rede Neural (lacunas com zeros)

CCPV	CPF32	CPF40	AgrF	AgrM	AgrG	Ptrc	Brto	Brto1	Brto2	Ag	Plast	SPlast	fc28d	Previsão	%Acerto
262	0	0	591	0	0	1286	0	0	0	121.5	0	0	24.9	23.68	95.11
0	365	0	0	748	0	0	1136	0	0	173.5	0	2.5	37.6	33.22	88.36
0	0	280	308	513	0	0	0	1091	0	191.6	0	2.24	29.1	35.75	77.16
0	360	0	737	0	0	214	888	0	0	190.4	0	2.22	25.8	33.04	71.93
0	370	0	730	0	0	750	345	0	0	180.7	0	1.2	23.8	27.25	85.50
0	390	0	730	0	0	750	317	0	0	170.4	2.36	1.66	27.8	33.93	77.97
0	0	330	730	0	0	1135	0	0	0	180.1	1.65	1.98	37.4	31.48	84.17
0	0	310	748	0	0	1135	0	0	0	179.2	0.93	2.48	33.2	33.93	97.81
300	0	0	795	0	0	0	0	1096	0	191.5	2.4	0	41.3	29.12	70.52
321	0	0	748	0	0	0	0	1123	0	180.2	1.6	1.92	40.9	28.28	69.14
MÉDIA ACERTOS															81,77

Fonte: Autor

A) Padrão de treinamento de uma rede neural *feedforward* cujos gráficos são apresentados na Figura 8.

Figura 8 – Painéis do treinamento da rede neural



Fonte: Matlab

Uma rede neural *feedforward* é aquela que durante o treinamento calcula o erro (diferença entre a saída real e a prevista) e usa a retropropagação para ajustar os pesos e vieses anteriores, melhorando suas previsões. Isso pode ser evidenciado nos três painéis da Figura 8:

a) No primeiro painel está representado o Gradiente Decrescente (usado para encontrar o mínimo de uma função, no caso o menor erro pré-estabelecido) que atinge o valor mínimo, de aproximadamente 7,6324 na 11ª Época. Isso demonstra que o treinamento processou 11 vezes o percurso da rede, da entrada até a saída, ajustando os pesos para o menor valor de erro. Neste painel observa-se que o algoritmo de treinamento, *Levenberg-Marquardt*, está convergindo, ou seja, o erro está sendo reduzido de forma consistente.

b) O segundo painel registra que o valor de μ (Mu), parâmetro de amortecimento, cresce inicialmente e depois se estabiliza na 11ª Época. A estabilização sugere que o algoritmo encontrou uma região de mínimo aceitável.

c) O terceiro painel demonstra o *Validation Checks* (Verificações de Validação), que é um mecanismo de controle durante o treinamento da rede neural usado para prevenir o *overfitting*, que ocorre quando a rede memoriza os dados de treino em vez de aprender a generalizar. Os


Validation Checks funcionam como um mecanismo de parada antecipada durante o treinamento. Este painel mostra 6 (seis) “*validation checks*” até a 11ª Época, que é exatamente o limite padrão do MATLAB.

Pode-se concluir que o modelo aprendeu os padrões principais dos traços, mas começou a perder capacidade de generalização, indicando início de sobreajuste (*overfitting*). Isso quer dizer que o modelo de aprendizado de máquina aprende tão bem os dados de treinamento, incluindo ruídos e detalhes irrelevantes, mas falha ao generalizar para novos dados.

B) Desempenho do aplicativo

O gráfico da Figura 9 representa a comparação do número de épocas (eixo X) com a variação de erros (eixo Y) em relação aos três bancos de dados do treinamento da rede.

Figura 9 – Desempenho do aplicativo



Fonte: Matlab


Na interpretação central observa-se que o erro de treinamento (azul) diminui continuamente. O de validação diminui até 7ª Época, com Performance de Validação = 68,4478, onde atinge seu mínimo, quando para de melhorar. A partir deste ponto o erro de teste mantém valores mais elevados.

Pode-se concluir que a rede neural apresenta boa performance de aprendizado inicial, mas começa a perder capacidade de generalização após a Época 7, caracterizando *overfitting*.

C) Regressão Linear

A Figura 10 é uma representação gráfica da regressão para os dados de Treinamento, Validação, Teste e o Conjunto Total de Dados (113 traços).

Figura 10 – Representação da Regressão



Fonte: Matlab

a) Com relação aos dados de treinamento, 79 traços, a regressão $R = 0,95143$ o que mostra uma excelente correlação linear entre valores previstos pela rede e valores reais (a maioria dos dados próximos à reta ideal). Pode-se afirmar que a rede neural ajusta muito bem os dados de treinamento.

b) Para os 17 traços de validação a regressão $R = 0,29747$ o que significa uma correlação muito fraca, com grande dispersão dos pontos em relação à reta, demonstrando que o modelo não generalizou bem para os dados de validação.

c) Os outros 17 traços de teste têm o $R=0,68382$ representando uma correlação moderada, melhor que validação, mas ainda distante do treino.

d) Em avaliação global, com os 113 traços, a regressão $R = 0,81793$ com resultado total aparentemente bom, com bastante influência do conjunto de treinamento. Pode-se afirmar que o modelo apresenta *overfitting* claro: aprende muito bem no treino, mas perde desempenho na validação e no teste.

4.2.2. Matriz de Treinamento com Unidades Preenchendo as Lacunas

Seguindo os passos do que feito no tópico 4.2.1 os resultados alcançados foram satisfatórios, como pode ser observado na Tabela 11.

Observa-se que os valores previstos para a resistência do concreto são próximos dos que foram encontrados no banco de dados com zeros, o que pode ser comprovado pelas Médias de Acerto serem pouco diferentes (81,77 e 82,16). Por esse motivo, as considerações

sobre os gráficos gerados nessa etapa da pesquisa serão as mesmas feitas na etapa anterior.

Tabela 11 – Previsibilidade na Rede Neural (lacunas preenchidas com unidades)

CCPV	CPF32	CPF40	AgrF	AgrM	AgrG	Ptrc	Br0	Br1	Br2	Ag	Plast	SPlast	fc28d	Pre- visão	%Acer- to
262	1	1	591	1	1	1286	1	1	1	121.5	0.001	0.001	24.9	34.65	60.81
1	365	1	1	748	1	1	1136	1	1	173.5	0.001	2.5	37.6	18.48	49.16
1	1	281	318	513	1	1	1	1191	1	191.6	0.001	2.24	29.1	21.57	74.14
1	361	1	737	1	1	214	888	1	1	190.4	0.001	2.22	25.8	25.63	99.36
1	371	1	731	1	1	751	345	1	1	180.7	0.001	1.2	23.8	25.84	91.42
1	391	1	731	1	1	751	317	1	1	170.4	2.36	1.66	27.8	30.52	90.18
1	1	331	731	1	1	1135	1	1	1	180.1	1.65	1.98	37.4	32.66	87.33
1	1	311	748	1	1	1135	1	1	1	179.2	0.93	2.48	33.2	31.59	95.15
311	1	1	795	1	1	1	1	1196	1	191.5	2.4	0.001	41.3	35.87	86.87
321	1	1	748	1	1	1	1	1123	1	180.2	1.6	1.92	40.9	35.65	87.18
MÉDIA ACERTOS															82,16

Fonte: Autor

5. RESULTADOS E DISCUSSÕES

O estudo utiliza um banco de dados composto por 123 traços de concreto validados experimentalmente em laboratório. A complexidade inicial reside no fato de que nem todos os traços utilizam os mesmos insumos, gerando diversas "lacunas" na matriz de dados.

Na preparação do banco de dados para o início da pesquisa, etapas de pré-processamento, foram feitas as seguintes ações:

- a) Limpeza de Atributos: Colunas de insumos que não contribuíram para a confecção dos traços foram deletadas.

- b) Tratamento de Lacunas: Foram testadas duas abordagens para preencher os dados faltantes, uma com preenchimento de zeros e outra se usando a unidade (valores muito pequenos em relação aos insumos).

- c) Divisão dos Dados: Para ambas as metodologias, os dados foram separados em Matriz de Treinamento (113 traços) e Matriz de Teste (10 traços não treinados, para serem usados em previsões futuras).

5.1. Comparação de Desempenho Entre os Modelos

A Tabela 12 resume os principais resultados obtidos para os melhores modelos encontrados em cada categoria:

Tabela 12 – Desempenho entre os modelos

Método	Estratégia de Lacunas	Melhor Modelo de Algoritmo	RMSE (Treino)	Média de Acertos (Teste)
Regressão Linear	Zeros	Ensembles of Trees	7,3420	87,94
Regressão Linear	Unidades	Linear SVM	7,2035	88,18
Rede Neural (RNA)	Zeros	MPL (Levenbert-Marquardt)	N/A	81,77
Rede Neural (RNA)	Unidades	MPL (Levenbert-Marquardt)	N/A	82,16

Fonte: Autor

*Nota: Para a RNA o aplicativo foca nos valores de correlação R, o que justifica a não avaliação (N/A) dos valores de RMSE. Sendo assim, no treinamento com zeros, os 113 traços tiveram R=0,81793 conforme consta na Figura 10.

5.2. Discussão Crítica

5.2.1. Os pontos fortes e limitações da Pesquisa consistem em:

a) Regressão Linear (*Ensembles/SVM*): mostrou-se mais robusta para este conjunto de dados específico. O modelo capturou bem a tendência geral (especialmente entre 20 e 40 MPa). Contudo, apresenta uma limitação de "suavização", tendendo a subestimar resistências muito altas e superestimar as muito baixas, como foi abordado na explicação do gráfico da Figura 3.

b) Redes Neurais: Embora tenham alta capacidade de mapear relações não lineares, o modelo enfrentou dificuldades significativas de generalização, apresentando menor desempenho em comparação à Regressão Linear.

c) As estratégias de pré-processamento adotadas, como o preenchimento das lacunas com zeros e com valores unitários (muito pequenos) e, finalmente, a exclusão de colunas de insumos que não contribuíram para nenhum traço, impactam diretamente a estabilidade e o viés dos modelos, especialmente das RNAs que são mais sensíveis à escala e à distribuição dos dados.

5.2.2. Sensibilidade e Riscos de *Overfitting*

Na pesquisa ficou evidenciado um problema clássico de *overfitting* nas RNAs, destacando-se:

a) A rede aprendeu quase perfeitamente os dados de treino ($R=0,95143$), mas falhou na validação ($R=0,29747$). (Figura 9)

b) Isso indica que, com apenas 113 amostras e uma arquitetura da rede com 10 neurônios na camada oculta, isso pode ser complexo demais para a quantidade de dados pequena, levando a rede a memorizar ruídos em vez de aprender padrões generalizáveis.

5.2.3. Fatores que influenciaram os modelos (sensibilidade à fatores chave)

A Tabela 13 sintetiza o comportamento observado ao longo dos experimentos: os dois modelos respondem de forma diferente às limitações do banco de dados, especialmente tamanho amostral e presença de lacunas. Isso explica diretamente os resultados obtidos na pesquisa.

Tabela 13 – Fatores influentes sobre os modelos

Fator	Regressão Linear	RNA
Tamanho do banco de dados	Baixa	Alta
Lacunas de dados	Moderada	Alta
<i>Overfitting</i>	Baixo	Elevado
Interpretabilidade	Alta	Baixa

Fonte: Autor

5.2.4. Interpretabilidade e Implementação Prática

A Regressão Linear, neste cenário, oferece uma implementação mais confiável para o laboratório, servindo como uma ferramenta de checagem imediata. A sensibilidade ao preenchimento de lacunas (zeros vs. unidades) foi pequena, com uma leve vantagem para o uso de valores unitários.

6. CONCLUSÃO E RECOMENDAÇÕES

6.1. Síntese dos Resultados

O método de Regressão Linear (especialmente o Linear SVM) apresenta o melhor desempenho nas condições documentadas, atingindo uma média de acerto

de 88,18% em dados novos. No entanto, cabem três observações:

a) Fazer uso da Regressão Linear (*Ensembles/SVM*) quando o conjunto de dados for limitado (pequena escala) e a estabilidade da previsão for prioritária. O que, segundo a pesquisa, habilita sua aplicação prática em laboratórios, podendo ser usada como ferramenta de checagem e controle de qualidade.

b) Usar Redes Neurais apenas se houver um volume de dados significativamente maior (>500 a 1000 traços) para mitigar o *overfitting* e permitir que a rede aprenda as complexidades sem apenas memorizar os exemplos de treino. A sua aplicabilidade se faz presente quando há forte

“não linearidade” de dados comprovada. Para se ter um melhor rendimento da Redes Neurais, o banco de dados tem que estar completo e bem balanceado.

c) Foi observado que na tabela de traços os insumos não apresentam a mesma proporcionalidade de medida, por exemplo, enquanto tem-se peso do cimento de 314 Kg/m^3 , o de brita nº1 é de 1140 Kg/m^3 e o de plastificante é $0,9 \text{ Kg/m}^3$. Essa desproporcionalidade entre os dados de entrada provoca distorções na previsibilidade. O ideal é normalizar todos os valores de insumos do banco de dados, tendo como referência o maior e o menor peso da tabela.

6.2. Avaliação dos Objetivos Alcançados

Com relação às metas específicas propostas na pesquisa, pode-se afirmar:

a) Está sendo proposta uma nova formação para o banco de traços que o laboratório deverá implementar, o que facilitará o manuseio desses dados em treinamentos futuros de redes neurais.

b) Foram analisados os modelos de Regressão e Redes Neurais, concluindo-se que, dependendo da composição e do tamanho do banco de dados, um dos modelos apresentará melhores resultados. Na análise dos resultados, ao ser calculado a previsibilidade de 10 traços, a Regressão Linear apresentou um percentual de acerto de 87,94% tendo somente um traço abaixo dessa média, com margem de erro igual a 23,26%. Apesar das Redes Neurais terem um percentual de acerto de 81,77% constatou-se que cinco traços ficaram abaixo desse valor, sendo a pior margem de erro igual a 30,86%.

c) Há a possibilidade de utilizar os resultados da pesquisa para prever a resistência do concreto em outras datas, como 7, 14 e 63 dias.

d) Existe a chance de desenvolver um dispositivo digital para verificar a resposta de resistência do concreto de um traço. Um desses dispositivos é o Simulink do Matlab.

Portanto, o objetivo geral de avaliação e eficácia dos modelos foram alcançados, conforme pode ser comprovado pelos resultados apresentados.

6.3. Implementações Práticas

A adoção dessas ferramentas impacta diretamente a eficiência econômica e técnica das obras, como: (1) redução do gargalo temporal; (2) economia de materiais; (3) segurança estrutural, pois modelos computacionais conferem maior robustez ao processo, garantindo que a resistência característica (f_{ck}) especificada seja atendida com maior confiança; e (4) mitigação de riscos, permitindo a correção do traço calculado antes da montagem dos corpos de prova, evitando retrabalhos onerosos.

A principal aplicação prática é o uso desses modelos como uma ferramenta de checagem imediata e controle de qualidade, permitindo:

a) Previsibilidade Antecipada: O laboratório pode antever a resistência do traço antes mesmo da ruptura física dos corpos de prova, que tradicionalmente leva 28 dias.

b) Validação de Traços: Caso o resultado previsto pelo modelo seja muito divergente do traço calculado, o laboratório pode refazer os procedimentos preventivamente.

c) Gestão de Dados: O modelo permite transformar o banco de dados histórico do laboratório em inteligência técnica para novos projetos.

6.4. Perspectivas Futuras

As perspectivas futuras para a aplicação dos resultados dessa pesquisa podem ser registradas na rotina operacional do laboratório de análise de concreto, destacando: (1) O modelo pode atuar como um filtro imediato caso a resistência prevista para um novo traço divergir drasticamente do esperado, permitindo que o laboratório refaça os procedimentos de dosagem ou conferir a pesagem dos insumos antes mesmo da moldagem dos corpos de prova; (2) Com a consolidação de modelos mais robustos, o laboratório pode realizar "ajustes proativos" no traço final utilizando resultados parciais de 7 e 14 dias, economizando tempo e recursos experimentais; e (3) A transição do modelo estatístico tradicional para o aprendizado de máquina incentiva a manutenção de bancos de dados mais limpos e estruturados, transformando o histórico de ensaios do laboratório em um ativo de inteligência competitiva.

REFERÊNCIAS BIBLIOGRÁFICAS

- AIRLANGGA, G. "Comparação entre a Modelagem Preditiva da Resistência à Compressão do Concreto com Abordagens de Aprendizado de Máquina", UKaRsT, v. 8, n. 1, p. 28–41, 30 abr. 2024. DOI: 10.30737/ukarst.v8i1.5532.
- ADELI, H. "Redes Neurais em Engenharia Civil: 1989–2000", Engenharia Civil e de Infraestrutura Assistida por Computador, v. 16, n. 2, p. 126–142, 1 mar. 2001. DOI: 10.1111/0885-9507.00219. . Acesso em: 15 jan. 2026.
- ARSHAVSKY, Y. I. "Neurônios versus Redes: A Interação entre Neurônios Individuais e Redes Neurais nas Funções Cognitivas", O Neurocientista, v. 23, n. 4, p. 341–355, 22 set. 2016. DOI: 10.1177/1073858416670124
- BISWAS, T., FITZGERALD, J. E. "Estrutura geométrica para prever estrutura a partir da função em redes neurais.", Pesquisa em Revisão Física, v. 4, n. 2, 29 jun. 2022. DOI: 10.1103/physrevresearch.4.023255. . Acesso em: 15 jan. 2026.
- BU, L., DU, G., HOU, Q. "Previsão da Resistência à Compressão de Concreto Agregado Reciclado com Base em Rede Neural Artificial.", Materiais, v. 14, n. 14, p. 3921, 14 jul. 2021. DOI: 10.3390/ma14143921. . Acesso em: 15 jan. 2026.
- CHANG, C.-H., KAO, H.-Y., HUANG, S.-H. "Implementação de Hardware para Múltiplas Funções de Ativação". 1º de maio de 2019. Anais [...] [S.l.], Instituto de Engenheiros Eletroeletrônicos, 1º de maio de 2019. p. 1–2. DOI: 10.1109/icce-tw46550.2019.8991981. . Acesso em: 15 jan. 2026.
- COHEN, Y., ENGEL, T. A., LANGDON, C., e outros. "Avanços Recentes na Interface entre Neurociência e Redes Neurais Artificiais.", The Journal of Neuroscience: o periódico oficial da Society for Neuroscience, v. 42, n. 45, p. 8514–8523, 9 nov. 2022. DOI: 10.1523/jneurosci.1503-22.2022.
- GUNDOGDU, O., EGRIOGLU, E., ALADAG, C. H., e outros. "Modelo multiplicativo de neurônios em rede neural artificial baseada na função de ativação gaussiana", Computação Neural e Aplicações, v. 27, n. 4, p. 927–935, 29 abr. 2015. DOI: 10.1007/s00521-015-1908-x. . Acesso em: 15 jan. 2026.
- HUBERT, M., BRANDEN, K. V. "Métodos robustos para regressão de mínimos quadrados parciais", Revista de Quimiometria, v. 17, n. 10, p. 537–549, 1 out. 2003. DOI: 10.1002/cem.822. . Acesso em: 15 jan. 2026.
- KAMPEZIDOU, S. I., TIKAYAT RAY, A., BHAT, A. P., e outros. "Componentes Fundamentais e Princípios de Fluxos de Trabalho de Aprendizado de Máquina Supervisionados com Dados Numéricos e Categóricos", Eng, v. 5, n. 1, p. 384–416, 29 fev. 2024. DOI: 10.3390/eng5010021. . Acesso em: 15 jan. 2026.
- KARAYIANNIS, N. B., MI, G. W. "Crescimento de redes neurais de base radial: fusão de aprendizado supervisionado e não supervisionado com técnicas de crescimento de rede", Transações IEEE em Redes Neurais, v. 8, n. 6, p. 1492–1506, 1 nov. 1997. DOI: 10.1109/72.641471. . Acesso em: 15 jan. 2026.
- KHADEMI, F., AKBARI, M., JAMAL, S. M., e outros. "Regressão linear múltipla, rede neural artificial e previsão de lógica difusa de resistência à compressão de 28 dias do concreto", Fronteiras da Engenharia Estrutural e Civil, v. 11, n. 1, p. 90–99, 1 mar. 2017. DOI: 10.1007/s11709-016-0363-9.
- KINANEVA, D., HRISTOV, G., KYUCHUKOV, P., e outros. "Algoritmos de Aprendizado de Máquina para Análise de Regressão e Previsões de Dados Numéricos". 9, 11 jun. de 2021. Anais [...] [S.l.], Instituto de Engenheiros Eletroeletrônicos, 11 jun. 2021. p. 1–6. DOI: 10.1109/hora52670.2021.9461298. . Acesso em: 15 jan. 2026.
- KIRANYAZ, S., INCE, T., IOSIFIDIS, A., e outros. "Modelo generalizado de redes neurais biológicas: perceptrons operacionais progressivos". 1 de maio de 2017. Anais [...] [S.l.], Instituto de Engenheiros Eletroeletrônicos, 1º de maio de 2017. p. 2477–2485. DOI: 10.1109/ijcnn.2017.7966157. .
- KOHLI, S., GODWIN, G. T., UROLAGIN, S., "Previsão de Vendas Usando Regressão Linear e KNN". [S.l.], Springer Singapura, 2020. p. 321–329. DOI: 10.1007/978-981-15-5243-4_29.
- LETZGUS, S., WAGNER, P., LEDERER, J., e outros. "Rumo a uma Inteligência Artificial Explicável para Modelos de Regressão: Uma perspectiva metodológica", Revista de Processamento de Sinais IEEE, v. 39, n. 4, p. 40–58, 1 jul. 2022. DOI: 10.1109/msp.2022.3153277. . Acesso em: 15 jan. 2026.

- NIKOO, M., TORABIAN MOGHADAM, F., SADOWSKI, Ł. "Previsão da Resistência à Compressão do Concreto por Redes Neurais Artificiais Evolutivas", *Avanços em Ciência e Engenharia de Materiais*, v. 2015, p. 1–8, 1º de jan. 2015. DOI: 10.1155/2015/849126.
- RITTER, G. X., URCID, G. "Abordagem de álgebra de rede para computação de neurônio único", *Transações IEEE em Redes Neurais*, v. 14, n. 2, p. 282–295, 1º de mar. 2003. DOI: 10.1109/tnn.2003.809427.
- ROUSTAEI, N. "Aplicação e interpretação da análise de regressão linear.", *Hipótese médica, descoberta e inovação, revista de oftalmologia*, v. 13, n. 3, p. 151–159, 14 fora. 2024. DOI: 10.51329/mehdiophthal1506.
- SCHMIDGALL, S., ZIAEI, R., ACHTERBERG, J., e outros. "Aprendizagem inspirada pelo cérebro em redes neurais artificiais: uma revisão", *Aprendizado de Máquina APL*, v. 2, n. 2, 9 maio 2024. DOI: 10.1063/5.0186054. Acesso em: 15 jan. 2026.
- VERMA, N. K., RAO, M. C., KUMAR, S. "Efeito do regime de cura na resistência à compressão do concreto geopolímero", *Série de Conferências IOP: Ciências da Terra e Meio Ambiente*, v. 982, n. 1, p. 012031, 1 mar. 2022. DOI: 10.1088/1755-1315/982/1/012031.
- VERMA, B. "Treinamento rápido de perceptrons multicamadas", *Transações IEEE em Redes Neurais*, v. 8, n. 6, p. 1314–1320, 1 nov. 1997. DOI: 10.1109/72.641454. . Acesso em: 15 jan. 2026.
- ZHU, Z. "Otimização Sistemática de Problemas de Superajuste em Aprendizado de Máquina", *Destques em Ciência, Engenharia e Tecnologia*, v. 111, p. 353–359, 19 ago. 2024. DOI: 10.54097/3tkzrj84. . Acesso em: 15 jan. 2026.
- ZIOLKOWSKI, P., NIEDOSTATKIEWICZ, M. "Técnicas de Aprendizado de Máquina no Design de Misturas de Concreto", *Materiais*, v. 12, n. 8, p. 1256, 17 abr. 2019. DOI: 10.3390/ma12081256.