



**CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS**  
**DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA**  
**COMPUTACIONAL**

**TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA A PREVISÃO DA**  
**RESISTÊNCIA À COMPRESSÃO DO CONCRETO E DA ADERÊNCIA AÇO-**  
**CONCRETO**

**PRISCILA FLÁVIA SOUZA DA SILVA**

Orientador: Prof. Dr. Gray Farias Moita

Coorientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Eliene Pires de Carvalho

**Belo Horizonte**

**Fevereiro de 2023**

**PRISCILA FLÁVIA SOUZA DA SILVA**

**TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA A PREVISÃO DA  
RESISTÊNCIA À COMPRESSÃO DO CONCRETO E DA ADERÊNCIA AÇO-  
CONCRETO**

Tese de doutorado apresentada ao Programa de Pós-graduação em Modelagem Matemática e Computacional do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito parcial para a obtenção do título de Doutor em Modelagem Matemática e Computacional.

Área de concentração: Modelagem Matemática e Computacional

Linha de pesquisa: Sistemas Inteligentes

Orientador: Prof. Dr. Gray Farias Moita

Coorientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Eliene Pires de Carvalho

Centro Federal de Educação Tecnológica de Minas Gerais

**Belo Horizonte**

**Fevereiro de 2023**

S586t Silva, Priscila Flávia Souza da  
Técnicas de aprendizado de máquina para a previsão da resistência à compressão do concreto e da aderência aço-concreto / Priscila Flávia Souza da Silva. – 2023.  
147 f.

Tese de doutorado apresentada ao Programa de Pós-Graduação em Modelagem Matemática e Computacional.

Orientador: Gray Farias Moita.

Coorientadora: Eliene Pires de Carvalho.

Tese (doutorado) – Centro Federal de Educação Tecnológica de Minas Gerais.

1. Concreto – Testes – Teses. 2. Resistência de materiais – Teses. 3. Força (Mecânica) – Teses. 4. Inteligência computacional – Teses. 5. Testes não-destrutivos – Teses. I. Moita, Gray Farias. II. Carvalho, Eliene Pires de. III. Centro Federal de Educação Tecnológica de Minas Gerais. IV. Título.

CDD 519.6



SERVIÇO PÚBLICO FEDERAL  
MINISTÉRIO DA EDUCAÇÃO  
CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS  
COORDENAÇÃO DO PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

**“TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA A PREVISÃO  
DA RESISTÊNCIA À COMPRESSÃO DO CONCRETO E DA  
ADERÊNCIA AÇO-CONCRETO”.**

Tese de Doutorado apresentada por **Priscila Flávia Souza da Silva**, em 24 de fevereiro de 2023, ao Programa de Pós-Graduação em Modelagem Matemática e Computacional do CEFET-MG, e aprovada pela banca examinadora constituída pelos professores:

**Prof. Dr. Gray Farias Moita (Orientador)**  
Centro Federal de Educação Tecnológica de Minas Gerais

**Prof<sup>a</sup>. Dr<sup>a</sup>. Eliene Pires de Carvalho (Coorientadora)**  
Centro Federal de Educação Tecnológica de Minas Gerais

**Prof. Dr. Moacir Kripka**  
Universidade de Passo Fundo

**Prof. Dr. Roque Luiz da Silva Pitangueira**  
Universidade Federal de Minas Gerais

**Prof. Dr. Alisson Marques da Silva**  
Centro Federal de Educação Tecnológica de Minas Gerais

**Prof. Dr. Gustavo Campos Menezes**  
Centro Federal de Educação Tecnológica de Minas Gerais

Visto e permitida a impressão,

**Prof. Dr. Thiago de Souza Rodrigues**  
Coordenador do Programa de Pós-Graduação Stricto Sensu em  
Modelagem Matemática e Computacional

## RESUMO

O concreto convencional é um dos materiais mais utilizados na construção civil e no mundo. Sua mistura é composta por cimento, água e diversos agregados. Seu comportamento é altamente não linear devido, principalmente, a suas características heterogêneas. A resistência à compressão é um dos parâmetros mais importantes para a determinação das características estruturais do concreto, sendo utilizada amplamente por calculistas para a realização de projetos estruturais. Já a aderência entre a barra de aço e a pasta de concreto, que são os principais componentes do concreto armado, pode ser vista como um dos principais fatores para que o concreto armado seja considerado uma solução estrutural viável para as mais diversas obras. Esses dois parâmetros são usualmente determinados por meio de ensaios laboratoriais dispendiosos, ocasionando grande gasto com recursos, materiais e tempo para a sua execução. Esse gasto é aumentado, principalmente, se considerado que a resistência à compressão do concreto, para atendimentos de processos normativos, é medida aos 7, 14 e 28 dias. Portanto, a previsão de resistência do concreto e da tensão de aderência continua sendo uma área ativa de pesquisa com um número considerável de estudos realizados. Por outro lado, a inteligência artificial e suas diversas aplicações são exemplos de novas tecnologias emergentes que têm se mostrado bem-sucedidas nas mais diversas aplicações científicas. Geralmente, os métodos computacionais superam suas contrapartes tradicionais, como os ensaios experimentais, na resolução de tarefas não lineares. Neste trabalho, é proposta a implementação de algoritmos de inteligência computacional para determinar a resistência do concreto armado à compressão e a força de arrancamento a partir de bases de dados experimentais. Cinco modelos são projetados, implementados e testados: árvores de decisão, florestas aleatórias, máquinas vetoriais de suporte, redes neurais artificiais e regressor gradiente *boosting*. Também são utilizados métodos de pré-processamento de dados e técnicas estatísticas para um melhor estudo das bases de dados utilizadas. O objetivo desse estudo é determinar a resistência à compressão do concreto e a força de arrancamento de barras de aço engastadas em corpos de prova de concreto sem destruir nenhuma amostra. Por fim, os resultados obtidos neste trabalho mostram eficiência na determinação da resistência à compressão e na força de arrancamento e são comparados com outros trabalhos, destrutivos e não destrutivos, que também obtiveram esses parâmetros.

PALAVRAS-CHAVE: Resistência à compressão do concreto; Força de arrancamento; Ensaio *pull-out*; Inteligência computacional; Métodos não-destrutivos.

## **ABSTRACT**

Conventional concrete is the most common material in civil construction around the world. Its mixture is fundamentally composed of cement, water, and different aggregates. Its behavior is highly nonlinear, mainly due to its heterogeneous characteristics. Compressive strength is one of the most critical parameters when designing concrete structural properties, and engineers widely use it. The adherence between the steel bar and the concrete paste, which are the main components of reinforced concrete, can be seen as one of the main factors for reinforced concrete to be considered a viable structural solution for the most diverse applications. These two parameters are usually determined through expensive laboratory tests, causing losses in resources, materials, and time. This loss is increased, especially if one considers that the compressive strength of concrete is measured on the 7<sup>th</sup>, 14<sup>th</sup>, and 28<sup>th</sup> days. Consequently, the prediction of concrete strength and the pull-out stress remains an active research area, with a considerable number of studies performed. On the other hand, artificial intelligence and its numerous applications are examples of new technologies that have been successfully applied in various scientific applications. Intelligent systems often outperform their traditional equivalents in solving nonlinear tasks. In this work, the implementation of machine learning techniques are proposed to determine the compressive strength of concrete and the pull-out force from several databases. Five models are devised, implemented, and tested: decision tree, random forest, support vector machine, artificial neural networks and regressor gradient boosting. Pre-process data, and statistical techniques are also used for a better understanding of the databases used. This study aims to determine the compressive strength of concrete and the pull-out force without destroying any samples. Finally, the results obtained in this work show high efficiency in determining the compressive strength and pull-out force and are compared with other approaches, both destructive and non-destructive.

**KEYWORDS:** Concrete compressive strength; Pull-out force, Pull-out tests; computational intelligence; Non-destructive methods.

## LISTA DE ILUSTRAÇÕES

Figura 2.1: Relação entre a resistência à compressão e a relação água/cimento do concreto.....	22
Figura 2.2: Influência da cura sobre a tensão a compressão do concreto.....	23
Figura 2.3: Ensaio de arrancamento <i>pull-out</i> .....	25
Figura 3.1: Exemplo de árvore. ....	32
Figura 3.2: Exemplo de árvore de decisão.....	33
Figura 3.3: Parâmetros importantes nas máquinas vetoriais de suporte.....	37
Figura 3.4: Dados não linearmente separáveis.....	38
Figura 3.5: Transformação de um problema não linearmente separável em um problema linearmente separável através do <i>kernel trick</i> . ....	39
Figura 3.6: (a) Neurônio biológico; (b) Neurônio artificial. ....	42
Figura 3.7: Representação esquemática de uma rede neural. ....	47
Figura 3.8: Iteração de aprendizes fracos (árvores) usando GBR para redução do erro.....	49
Figura 6.1: Resultados original <i>versus</i> previsto obtidos na implementação do árvores de decisão para a parcela de treinamento. ....	81
Figura 6.2: Resultados original <i>versus</i> previsto obtidos na implementação do árvores de decisão para a parcela de teste.....	82
Figura 6.3: Resultados de $R^2$ original <i>versus</i> previsto obtidos na implementação de árvores de decisão para as parcelas de treinamento e teste. ....	82
Figura 6.4: Resultados original <i>versus</i> previsto obtidos na implementação das florestas aleatórias para a parcela de treinamento.....	84
Figura 6.5: Resultados original <i>versus</i> previsto obtidos na implementação das florestas aleatórias a parcela de teste. ....	85
Figura 6.6: Resultados de $R^2$ original <i>versus</i> previsto obtidos na implementação das florestas aleatórias para as parcelas de treinamento e teste.....	85
Figura 6.7: Resultados original <i>versus</i> previsto obtidos na implementação do máquinas vetoriais de suporte para a parcela de treinamento. ....	87
Figura 6.8: Resultados original <i>versus</i> previsto obtidos na implementação do máquinas vetoriais de suporte para a parcela de teste. ....	87
Figura 6.9: Resultados de $R^2$ original <i>versus</i> previsto obtidos na implementação do máquinas vetoriais de suporte para as parcelas de treinamento e teste.....	88
Figura 6.10: Resultados original <i>versus</i> previsto obtidos na implementação de redes neurais artificiais para a parcela de treinamento. ....	89
Figura 6.11: Resultados original <i>versus</i> previsto obtidos na implementação de redes neurais artificiais para a parcela de teste.....	90
Figura 6.12: Resultados de $R^2$ original <i>versus</i> previsto para redes neurais artificiais para as parcelas de treinamento e teste.....	90

Figura 6.13: Resultados original <i>versus</i> previsto obtidos na implementação do regressor gradiente <i>boosting</i> para a parcela de treinamento. ....	92
Figura 6.14: Resultados original <i>versus</i> previsto obtidos na implementação do regressor gradiente <i>boosting</i> para a parcela de teste. ....	92
Figura 6.15: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação do regressor gradiente <i>boosting</i> para as parcelas de treinamento e teste. ....	93
Figura 7.1: Resultados original <i>versus</i> previsto obtidos na das árvores de decisão para a parcela de treinamento. ....	96
Figura 7.2: Resultados original <i>versus</i> previsto obtidos na implementação das árvores de decisão para a parcela de teste. ....	97
Figura 7.3: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação das árvores de decisão para as parcelas de treinamento e teste. ....	97
Figura 7.4: Resultados original <i>versus</i> previsto obtidos na implementação das florestas aleatórias para a parcela de treinamento. ....	99
Figura 7.5: Resultados original <i>versus</i> previsto obtidos na implementação das florestas aleatórias para a parcela de teste. ....	100
Figura 7.6: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação das florestas aleatórias para as parcelas de treinamento e teste. ....	100
Figura 7.7: Resultados original <i>versus</i> previsto obtidos na implementação das máquinas vetoriais de suporte para a parcela de treinamento. ....	102
Figura 7.8: Resultados original <i>versus</i> previsto obtidos na implementação das máquinas vetoriais de suporte para a parcela de teste. ....	102
Figura 7.9: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação das máquinas vetoriais de suporte para as parcelas de treinamento e teste. ....	103
Figura 7.10: Resultados original <i>versus</i> previsto obtidos na implementação das redes neurais artificiais para a parcela de treinamento. ....	104
Figura 7.11: Resultados original <i>versus</i> previsto obtidos na implementação das redes neurais artificiais para a parcela de teste. ....	105
Figura 7.12: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação das redes neurais artificiais para as parcelas de treinamento e teste. ....	105
Figura 7.13: Resultados original <i>versus</i> previsto obtidos na implementação do regressor gradiente <i>boosting</i> para a parcela de treinamento. ....	107
Figura 7.14: Resultados original <i>versus</i> previsto com a implementação de regressor gradiente <i>boosting</i> para a parcela de teste. ....	107
Figura 7.15: Resultados de R <sup>2</sup> original <i>versus</i> previsto com a implementação do regressor gradiente <i>boosting</i> para as parcelas de treinamento e teste. ....	108
Figura 7.16: Resultados de força de arrancamento <i>versus</i> resistência à compressão do concreto para os valores obtidos experimentalmente e o CEB (2010). ....	109

Figura 7.17: Resultados de força de arrancamento <i>versus</i> resistência à compressão do concreto para os valores obtidos no modelo de árvores de decisão (DTR) e o CEB (2010). .....	109
Figura 7.18: Resultados de força de arrancamento <i>versus</i> resistência à compressão do concreto para os valores obtidos no modelo de florestas aleatórias (RFR) e o CEB (2010).....	110
Figura 7.19: Resultados de força de arrancamento <i>versus</i> resistência à compressão do concreto para os valores obtidos no modelo de máquinas de suporte (SVM) e o CEB (2010). .....	110
Figura 7.20: Resultados de força de arrancamento <i>versus</i> resistência à compressão do concreto para os valores obtidos no modelo de redes neurais (ANN) e o CEB (2010). .....	111
Figura 7.21: Resultados de força de arrancamento <i>versus</i> resistência à compressão do concreto para os valores obtidos no modelo de regressor gradiente <i>boosting</i> (GBR) e CEB (2010).....	111
Figura 7.22: Resultados original <i>versus</i> previsto obtidos na implementação das árvores de decisão. ....	113
Figura 7.23: Resultados original <i>versus</i> previsto obtidos na implementação das florestas aleatórias. ....	114
Figura 7.24: Resultados original <i>versus</i> previsto obtidos na implementação das máquinas vetoriais de suporte.....	115
Figura 7.25: Resultados original <i>versus</i> previsto obtidos na implementação das redes neurais artificiais. ....	116
Figura 7.26: Resultados original <i>versus</i> previsto obtidos com a implementação de regressor gradiente <i>boosting</i> para a parcela de teste.....	117
Figura 7.27: Resultados original <i>versus</i> previsto obtidos na implementação das árvores de decisão para a parcela de treinamento. ....	119
Figura 7.28: Resultados original <i>versus</i> previsto obtidos na implementação das árvores de decisão para a parcela de teste. ....	119
Figura 7.29: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação das árvores de decisão para as parcelas de treinamento e teste.....	120
Figura 7.30: Resultados original <i>versus</i> previsto obtidos na implementação das florestas aleatórias para a parcela de treinamento. ....	122
Figura 7.31: Resultados original <i>versus</i> previsto obtidos na implementação das florestas aleatórias para a parcela de teste. ....	123
Figura 7.32: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação das florestas aleatórias para as parcelas de treinamento e teste.....	123
Figura 7.33: Resultados original <i>versus</i> previsto obtidos na implementação das máquinas vetoriais de suporte para a parcela de treinamento. ....	125
Figura 7.34: Resultados original <i>versus</i> previsto obtidos na implementação das máquinas vetoriais de suporte para a parcela de teste. ....	125
Figura 7.35: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação das máquinas vetoriais de suporte para as parcelas de treinamento e teste.....	126
Figura 7.36: Resultados original <i>versus</i> previsto obtidos na implementação das redes neurais artificiais para a parcela de treinamento. ....	127

Figura 7.37: Resultados original <i>versus</i> previsto obtidos na implementação das redes neurais artificiais para a parcela de teste.....	128
Figura 7.38: Resultados de R <sup>2</sup> original <i>versus</i> previsto obtidos na implementação das redes neurais artificiais para as parcelas de treinamento e teste.....	128
Figura 7.39: Resultados original <i>versus</i> previsto obtidos na implementação do regressor gradiente <i>boosting</i> para a parcela de treinamento. ....	130
Figura 7.40: Resultados original <i>versus</i> previsto com a implementação de regressor gradiente <i>boosting</i> para a parcela de teste.....	130
Figura 7.41: Resultados de R <sup>2</sup> original <i>versus</i> previsto com a implementação do regressor gradiente <i>boosting</i> para as parcelas de treinamento e teste.....	131

## LISTA DE TABELAS

Tabela 3.1: Vantagens e desvantagens das árvores de decisão e das florestas aleatórias. ....	35
Tabela 3.2: Vantagens e desvantagens das árvores de decisão e das florestas aleatórias. ....	36
Tabela 3.3: Vantagens e desvantagens das máquinas vetoriais de suporte.....	41
Tabela 3.4: Representação gráfica das funções de ativação. ....	45
Tabela 3.5: Vantagens e desvantagens das redes neurais artificiais.....	48
Tabela 3.6: Vantagens e desvantagens das regressor gradientes boosting.....	51
Tabela 5.1: Parâmetros dos atributos de entrada e saída da base de dados. ....	70
Tabela 5.2: Parâmetros dos atributos de entrada e saída da base de dados. ....	75
Tabela 5.3: <i>Range</i> dos parâmetros das bases de dados consultadas e que são utilizadas neste trabalho. ....	78
Tabela 6.1: Variação de parâmetros e parâmetros utilizados na implementação das árvores de decisão. ....	80
Tabela 6.2: Erros médios obtidos com a implementação das árvores de decisão.....	81
Tabela 6.3: Variação de parâmetros e parâmetros utilizados na implementação das florestas aleatórias. ....	83
Tabela 6.4: Erros médios obtidos com a implementação das florestas aleatórias. ....	83
Tabela 6.5: Variação de parâmetros e parâmetros utilizados na implementação das máquinas vetoriais de suporte.....	86
Tabela 6.6: Erros médios obtidos com a implementação das máquinas vetoriais de suporte. ....	86
Tabela 6.7: Parâmetros utilizados na implementação das redes neurais artificiais. ....	88
Tabela 6.8: Erros médios obtidos com a implementação das redes neurais artificiais.....	89
Tabela 6.9: Variação de parâmetros e parâmetros utilizados na implementação do regressor gradiente <i>boosting</i> . ....	91
Tabela 6.10: Erros médios obtidos com a implementação de regressor gradiente <i>boosting</i> . ....	91
Tabela 7.1: Variação de parâmetros e parâmetros utilizados na implementação das árvores de decisão. ....	95
Tabela 7.2: Erros médios obtidos com a implementação das árvores de decisão.....	95
Tabela 7.3: Variação de parâmetros e parâmetros utilizados na implementação das florestas aleatórias. ....	98
Tabela 7.4: Erros médios obtidos com a implementação das florestas aleatórias. ....	98
Tabela 7.5: Variação de parâmetros e parâmetros utilizados na implementação das máquinas vetoriais de suporte.....	101
Tabela 7.6: Erros médios obtidos com a implementação das máquinas vetoriais de suporte. ....	101
Tabela 7.7: Variação de parâmetros e parâmetros utilizados na implementação das redes neurais artificiais. .....	103
Tabela 7.8: Erros médios obtidos com a implementação das redes neurais artificiais.....	104
Tabela 7.9: Variação de parâmetros e parâmetros utilizados na implementação do regressor gradiente <i>boosting</i> . ....	106
Tabela 7.10: Erros médios obtidos com a implementação do regressor gradiente <i>boosting</i> . ....	106
Tabela 7.11: Valores de RMSE obtidos através dos métodos computacionais treinados com a base de Carvalho <i>et al.</i> (2017) e testados com a base ampliada, em kN. ....	112

Tabela 7.12: Variação de parâmetros e parâmetros utilizados na implementação das árvores de decisão. ...	118
Tabela 7.13: Erros médios obtidos com a implementação das árvores de decisão. ....	118
Tabela 7.14: Variação de parâmetros e parâmetros utilizados na implementação das florestas aleatórias. .	121
Tabela 7.15: Erros médios obtidos com a implementação das florestas aleatórias. ....	121
Tabela 7.16: Variação de parâmetros e parâmetros utilizados na implementação das máquinas vetoriais de suporte.....	124
Tabela 7.17: Erros médios obtidos com a implementação das máquinas vetoriais de suporte.....	124
Tabela 7.18: Variação de parâmetros e parâmetros utilizados na implementação das redes neurais artificiais. ....	126
Tabela 7.19: Erros médios obtidos com a implementação das redes neurais artificiais.....	127
Tabela 7.20: Variação de parâmetros e parâmetros utilizados na implementação do regressor gradiente <i>boosting</i> . ....	129
Tabela 7.21: Erros médios obtidos com a implementação do regressor gradiente <i>boosting</i> . ....	129
Tabela 8.1: Comparação de resultados obtidos para a resistência à compressão do concreto. ....	132
Tabela 8.2: Comparação dos parâmetros de performance obtidos nesse trabalho com resultados apresentados em outras literaturas.....	133
Tabela 8.3: Comparação dos resultados obtidos com a base de Carvalho <i>et al.</i> (2017). ....	134
Tabela 8.4: Valores de RMSE obtido através dos métodos computacionais treinados com a base de Carvalho <i>et al.</i> (2017) e testados na base de dados ampliada, em kN. ....	135
Tabela 8.5: Comparação de resultados obtidos na etapa 2. ....	136

## LISTA DE ABREVIATURAS

ABNT	Associação brasileira de normas técnicas.
A	Área transversal.
NBR	Norma brasileira.
AG	Algoritmos genéticos.
ANFIS	Sistema de inferência neuro-fuzzy adaptativo.
ANN	Artificial neural network, traduzido como rede neural artificial.
C	Parâmetro de penalidade do erro.
C-ANN	Rede neural artificial convencional.
DTR	<i>Decision tree</i> , traduzido como árvores de decisão.
EANNs	Redes neurais artificiais evolutivas.
ELM	Máquina de aprendizado extremo.
ELM-GWO	Máquina de aprendizado extremo com algoritmo metaheurístico.
F	Força.
$f_{ck}$	<i>Feature compression know</i> , traduzido como resistência característica do concreto à compressão.
GBR	<i>Gradient boosting regression</i> , traduzido como regressor gradiente <i>boosting</i> .
$l_d$	Comprimento de ancoragem.
LGP	<i>Linear genetic programming</i> .
LSSVM	<i>Least square support vector machine</i> .
MAE	Erro médio absoluto.
MAPE	<i>Mean absolute percentage error</i> , traduzido como erro percentual médio absoluto.

MARS	<i>Multivariate adaptive regression spline.</i>
MART	Árvore de regressão múltipla aditiva.
MLP	<i>MultiLayer perceptron.</i>
MOGWO	Método de otimização de lobos cinzas multiobjetivo.
MSE	Erro quadrático médio.
R	Coeficiente de correlação.
R <sup>2</sup>	Coeficiente de determinação.
R <sup>2</sup> ajustado	Coeficiente de correlação ajustado.
RAC	Agregado reciclado.
RBF	<i>Radial basis function</i> , traduzido como função de base radial.
RCA	Agregado grosso reciclado.
RDP	Desvio de porcentagem relativa.
RFR	<i>Random forest</i> , traduzido como florestas aleatórias.
RLM	Regressão linear múltipla.
RMSE	<i>Root mean square error</i> , traduzido como raiz do erro quadrático médio.
RSM	<i>Response surface methodology</i> , traduzido como metodologia de superfície de resposta.
RVM	<i>Relevance vector machine.</i>
SIFCON	Material cimentício composto reforçado contendo 20% de fibra de aço com diferentes minerais na mistura.
SO-ANN	Rede neural artificial de segunda ordem.
SVM	<i>Support vector machine</i> , traduzida como máquinas vetoriais de suporte.
SVM-Poly	Máquina vetorial de suporte com <i>kernel</i> de função polinomial.

SVM-RBF	Máquina vetorial de suporte com <i>kernel</i> de função de base radial.
TGP	<i>Tree-based genetic programming.</i>
$\sigma$	Tensão.
$\phi$	Diâmetro.
$\tau$	Tensão de arrancamento.
$\gamma$	Gamma ou coeficiente de <i>kernel</i> .

## SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>15</b>
1.1. OBJETIVOS E CONTRIBUIÇÕES .....	18
1.2. ESTRUTURA DO TRABALHO .....	19
<b>2. CARACTERÍSTICAS DO CONCRETO .....</b>	<b>21</b>
2.1. RESISTÊNCIA À COMPRESSÃO DO CONCRETO.....	21
2.2. TENSÃO DE ADERÊNCIA AÇO-CONCRETO.....	24
<b>3. MODELOS COMPUTACIONAIS .....</b>	<b>29</b>
3.1. PRÉ-PROCESSAMENTO DE DADOS.....	29
3.2. ÁRVORES DE DECISÃO E FLORESTAS ALEATÓRIAS.....	31
3.3. MÁQUINAS VETORIAIS DE SUPORTE .....	36
3.4. REDES NEURAIS ARTIFICIAIS .....	42
3.5. REGRESSOR GRADIENTE BOOSTING .....	48
3.6. MÉTODOS DE ANÁLISE DE RESULTADOS .....	51
<b>4. TRABALHOS CORRELATOS .....</b>	<b>53</b>
4.1. RESISTÊNCIA À COMPRESSÃO .....	53
4.2. RESISTÊNCIA AO ARRANCAMENTO .....	65
<b>5. METODOLOGIAS EMPREGADAS.....</b>	<b>68</b>
5.1. RESISTÊNCIA À COMPRESSÃO DO CONCRETO.....	68
5.1.1. LINGUAGEM DE PROGRAMAÇÃO E BIBLIOTECAS EMPREGADAS .....	68
5.1.2. BASES DE DADOS EMPREGADAS .....	68
5.1.3. PRÉ-PROCESSAMENTO .....	71
5.1.4. IMPLEMENTAÇÃO DOS MODELOS COMPUTACIONAIS .....	72
5.1.5. APRESENTAÇÃO DOS RESULTADOS.....	74
5.2. RESISTÊNCIA AO ARRANCAMENTO .....	74
5.2.1. BASES DE DADOS DE CARVALHO .....	74
5.2.2. APRESENTAÇÃO DOS RESULTADOS.....	75
5.2.3. EQUAÇÃO EMPÍRICA .....	75
5.2.4. BASE DE DADOS AMPLIADA .....	76
<b>6. APRESENTAÇÃO DOS RESULTADOS - RESISTÊNCIA À COMPRESSÃO DO CONCRETO .....</b>	<b>80</b>

6.1.	ÁRVORES DE DECISÃO .....	80
6.2.	FLORESTAS ALEATÓRIAS.....	83
6.3.	MÁQUINAS VETORIAIS DE SUPORTE .....	86
6.4.	REDES NEURAI ARTIFICIAIS .....	88
6.5.	REGRESSOR GRADIENTE BOOSTING .....	91
<b>7.</b>	<b>APRESENTAÇÃO DOS RESULTADOS - RESISTÊNCIA AO ARRANCAMENTO .....</b>	<b>94</b>
7.1.	BASE DE DADOS DE CARVALHO.....	95
7.1.1.	ÁRVORES DE DECISÃO .....	95
7.1.2.	FLORESTAS ALEATÓRIAS.....	98
7.1.3.	MÁQUINAS VETORIAIS DE SUPORTE .....	101
7.1.4.	REDES NEURAI ARTIFICIAIS .....	103
7.1.5.	REGRESSOR GRADIENTE BOOSTING .....	106
7.2.	EQUAÇÕES EMPÍRICAS .....	108
7.3.	BASE DE DADOS AMPLIADA .....	112
7.3.1.	ETAPA 1: .....	112
7.3.2.	ETAPA 2: .....	117
<b>8.</b>	<b>ANÁLISE DOS RESULTADOS .....</b>	<b>132</b>
8.1.	RESISTÊNCIA À COMPRESSÃO DO CONCRETO.....	132
8.2.	RESISTÊNCIA AO ARRANCAMENTO .....	134
8.2.1.	BASE DE DADOS DE CARVALHO.....	134
8.2.2.	EQUAÇÃO EMPÍRICA .....	135
8.2.3.	BASES DE DADOS AMPLIADA.....	135
<b>9.</b>	<b>CONCLUSÃO .....</b>	<b>137</b>
9.1.	TRABALHOS FUTUROS.....	139
<b>10.</b>	<b>BIBLIOGRAFIA.....</b>	<b>140</b>

## 1. INTRODUÇÃO

O concreto convencional é o material mais utilizado na construção civil, sendo composto por uma mistura de água, cimento e agregados. Sua resistência depende, principalmente, de fatores como consumo de cimento, fator água-cimento, grau de adensamento, tipo de agregado, dentre outros. Sua resistência à compressão é bastante considerável, contudo, sua resistência à tração é bem menor, variando entre 8% e 10% da resistência à compressão para concretos com resistência até 50 MPa. Sendo um composto formado pela combinação de vários materiais, o concreto é um material heterogêneo e seu comportamento é frágil quando submetido a ensaios de compressão e de tração, uma vez que apresenta pequenas deformações antes da ruptura (HIBBELER, 2010).

A resistência à compressão é um atributo fundamental no dimensionamento de estruturas, e sua determinação precisa é de grande relevância. Ademais, a resistência à compressão do concreto pode ser empregada para calcular o módulo de elasticidade do material quando este não pode ser obtido experimentalmente, conforme estabelecido pela NBR 6118 (ABNT, 2014).

Frequentemente, em estudos de mecânica dos sólidos, adotam-se simplificações, tratando materiais como o concreto como contínuos, elásticos, isotrópicos e homogêneos. No entanto, o concreto é, na realidade, heterogêneo e não se enquadra nessas premissas quando exposto a esforços e deformações. É crucial destacar que a propagação de trincas e discontinuidades, aliada à aplicação de cargas e deformações, faz com que o comportamento do concreto se desvie dessas hipóteses, perdendo sua isotropia e gerando diversas limitações no estudo deste material.

As estruturas de concreto armado são compostas por concreto e barras de aço, sendo as barras inseridas em regiões submetidas principalmente às tensões de tração para reforçar e aumentar a ductilidade do elemento estrutural. Um fator fundamental para o funcionamento adequado de um elemento de concreto armado é a aderência entre o aço e o concreto. Essa aderência é responsável por garantir o bom desempenho das estruturas de concreto armado, assegurando que o aço e o concreto trabalhem juntos como uma peça sólida.

Compreender o comportamento da aderência é crucial para avaliar a capacidade de carga das estruturas de concreto armado, e é uma condição básica para controlar a fissuração das estruturas, bem como definir as regras de projeto para o cálculo de ancoragem das barras de aço e das emendas traspassadas em elementos de concreto armado (BARBOSA, 2001).

Na aderência aço-concreto, a resistência de aderência é comumente idealizada pela tensão de cisalhamento na interface entre a barra de aço e o concreto, enquanto o deslizamento relativo representa o deslocamento entre a armadura e o concreto. Assim, é usual representar a tensão de arrancamento como a relação entre a tensão de aderência e o deslizamento relativo das barras de concreto.

Ao analisar a ligação aço-concreto, o fenômeno pode ser dividido em mecanismos cuja importância depende das características das barras de aço. No caso de barras nervuradas, a adesão química e o atrito entre o aço e o concreto são responsáveis pelo vínculo inicial, mas o entrelaçamento mecânico é a principal contribuição para a força do vínculo. Por outro lado, em barras lisas, a ligação depende principalmente de mecanismos de adesão e atrito devido à menor rugosidade superficial.

Em geral, a ruptura da ligação aço-concreto pode ocorrer por dois processos: arrancamento da barra ou fendilhamento da peça de concreto. Na falha por arrancamento, ocorre o esmagamento do concreto entre as nervuras, e a barra é puxada para fora do corpo de prova. Já no fendilhamento, a ruptura ocorre devido ao desenvolvimento de trincas ao longo do eixo longitudinal do corpo de prova. Fatores como o diâmetro da barra de aço, o cobrimento da armadura de concreto e a armadura transversal exercem influência direta no processo de falha. A falha de arrancamento geralmente ocorre quando o confinamento da barra é satisfatório; caso contrário, a ruptura por fendilhamento acontece (MIRANDA *et al.*, 2021).

Para determinar a tensão de aderência, consideram-se variáveis como diâmetro da barra, tipo da barra, disposição das nervuras, resistência característica das barras de aço, suas posições em relação à direção de concretagem e comprimento de ancoragem. Para o concreto, levam-se em conta a resistência à compressão e à tração, fator água/cimento, adições minerais, tipos de agregado, adensamento e idade de carregamento. Essa quantidade de variáveis associadas ao fenômeno de aderência aço-concreto pode influenciar de diversas maneiras a determinação da resistência de aderência da peça de concreto, tornando-a complexa.

Dessa forma, o estudo do comportamento das ligações em estruturas de concreto armado é desafiador devido ao grande número de parâmetros envolvidos. Compreender como esses parâmetros influenciam o comportamento dessas estruturas é fundamental, tornando-se crucial a determinação precisa das distribuições de tensões e deslocamentos nessas conexões.

A realização de ensaios precisos e confiáveis é essencial para determinar tanto a resistência à compressão quanto a resistência de arrancamento das barras de aço no concreto. Para estabelecer essas propriedades é necessário conduzir testes específicos. Tais informações são cruciais para o planejamento e construção de estruturas de concreto armado seguras e duráveis. No entanto, a obtenção dessas propriedades envolve a realização de ensaios destrutivos em diversos espécimes, o que pode apresentar desafios na sua aplicação prática.

Portanto, a determinação adequada dessas características pode ser onerosa, visto que pode envolver testes laboratoriais custosos que demandam tempo e recursos financeiros. Além disso, esses ensaios podem, muitas vezes, não ser viáveis, uma vez que implicam na destruição do espécime utilizado.

Nesse contexto, diversos estudos têm se concentrado na busca por determinar tais propriedades por meio de modelos teóricos. Essa abordagem tem o potencial de oferecer alternativas mais acessíveis e menos destrutivas para avaliar as características mecânicas do concreto em projetos de engenharia civil.

Os modelos de falha de *Rankine e Mohr-Coulomb* são frequentemente utilizados na determinação de rupturas em corpos de prova de concreto, graças à sua simplicidade de aplicação. No entanto, em situações específicas envolvendo concreto e cenários não lineares, esses modelos se mostram ineficientes para descrever com precisão as tensões de falha, gerando altas taxas de erros (VON MISES, 1928; CHEN, 2007).

Conforme Babanajad (2015), a resolução de problemas de engenharia pode ser abordada por meio de métodos teóricos, como os empíricos, analíticos e numéricos. Esses métodos são frequentemente simplificados com base em diversas suposições e aproximações. Portanto, quando aplicados a modelos teóricos, fatores não lineares podem afetar o desempenho da resistência e da aderência aço-concreto. Adicionalmente, ensaios experimentais mais precisos geralmente envolvem gastos significativos de tempo, planejamento e recursos financeiros, considerando que o período de cura comum para corpos de prova de concreto varia entre 7, 14 e 28 dias.

O progresso nas atividades de pesquisa tem gerado aplicações e tecnologias úteis em diversos campos. Avanços tecnológicos permitem resolver problemas de engenharia de maneiras alternativas às convencionais. A inteligência artificial e suas aplicações são exemplos de áreas exploradas com expectativas variadas e resultados realistas. Geralmente, sistemas de inteligência artificial têm demonstrado sua capacidade na resolução de problemas da vida real, especialmente em tarefas não lineares (HOANG *et al.*, 2019).

A engenharia estrutural tem sido um campo de intenso desenvolvimento, impulsionado pela implementação e teste de novos modelos computacionais para prever as propriedades de diversas misturas de concreto. No contexto de modelos comportamentais, o reconhecimento de padrões é extremamente útil, e os métodos de inteligência computacional podem ser aplicados. Em particular, modelos bio-inspirados podem agregar valor significativo no dimensionamento de estruturas para a engenharia civil (REUTER; SULTAN; REISCHL, 2018; TORKEY; ABURAWWASH, 2018).

Com o objetivo de contribuir para o estudo da determinação das características do concreto a partir de diferentes composições e componentes, este projeto busca empregar métodos computacionais para viabilizar abordagens alternativas na determinação de propriedades cruciais do concreto, principalmente no dimensionamento de estruturas de concreto armado. Assim, o foco deste projeto é a aplicação de inteligência computacional na análise e desenvolvimento de modelos de previsão para a resistência à compressão do concreto e na previsão da tensão de aderência aço-concreto,

utilizando métodos computacionais que enfatizem a precisão e eficiência, bem como sua capacidade de lidar com dados experimentais.

Além disso, pretende-se realizar uma revisão bibliográfica abrangente para investigar modelos computacionais voltados à previsão de características do concreto, conforme apresentado por diversos autores, enriquecendo o conhecimento na área e fundamentando a pesquisa proposta.

## 1.1. OBJETIVOS E CONTRIBUIÇÕES

O principal objetivo deste trabalho é validar o uso de métodos computacionais no auxílio à determinação de características importantes do concreto, como a resistência à compressão e a força de arrancamento entre a barra de aço e o concreto circundante, com base em diversas bases de dados, sem a necessidade de ensaios destrutivos.

Em outras palavras, e com foco no objetivo mencionado, busca-se desenvolver modelos de inteligência computacional para determinar parâmetros relevantes empregados no dimensionamento de estruturas de concreto, considerando diferentes traços do concreto e geometrias dos corpos de prova. O intuito é minimizar os fatores de erro e possibilitar a aplicação em casos simulados e reais.

Os objetivos específicos deste trabalho incluem:

- Apresentar estudos que empregam modelos computacionais na determinação da resistência à compressão do concreto, conforme proposto por outros autores;
- Apresentar estudos que utilizam modelos computacionais para determinar a tensão de arrancamento de barras de aço engastadas no concreto, conforme proposto por outros autores;
- Realizar a limpeza e preparação de uma base de dados bruta;
- Aplicar e validar técnicas de pré-processamento, como validação cruzada e ajuste de hiperparâmetros, utilizando ferramentas como *GridSearchCV*, entre outras;
- Empregar os seguintes modelos computacionais para determinar a resistência à compressão do concreto e a força de aderência aço/concreto:
  - Árvores de decisão;
  - Florestas aleatórias;
  - Máquinas vetoriais de suporte;
  - Redes neurais artificiais;

- Regressor gradiente *boosting*.
- Confrontar os resultados obtidos nesse estudo com os resultados encontrados na literatura, obtidos por outros autores;
- Confrontar os resultados obtidos nesse estudo com os resultados esperados para a força de arrancamento obtidos por meio de código normativo.

Nesse contexto, o presente trabalho tem como objetivo contribuir para um melhor entendimento da viabilidade dos métodos de inteligência computacional na determinação da resistência à compressão do concreto e da força de arrancamento de barras finas por meio do ensaio *pull-out*. A proposta é desenvolver modelos de inteligência computacional que permitam determinar esses parâmetros sem a necessidade de recorrer a ensaios destrutivos.

## 1.2. ESTRUTURA DO TRABALHO

A estrutura deste trabalho é estruturada da seguinte maneira:

- No Capítulo 1 são apresentados a introdução, os objetivos e contribuições deste trabalho.
- No Capítulo 2 são conceituadas as características do concreto que serão estudadas nesse trabalho: a resistência à compressão do concreto e a tensão de arrancamento aço/concreto.
- No Capítulo 3 é apresentada a conceituação das metodologias computacionais que são utilizadas nesse trabalho, detalhando-se a fundamentação teórica necessária. São definidos os modelos computacionais a serem utilizados, sendo eles: árvores de decisão, florestas aleatórias, máquinas vetoriais de suporte, redes neurais artificiais e regressor gradiente *boosting*.
- No Capítulo 4 são apresentados os trabalhos correlatos disponíveis na literatura. São trabalhos que utilizaram inteligência artificial para a resolução de problemas de engenharia, com ênfase para a determinação da tensão de aderência e a resistência à compressão do concreto.
- O Capítulo 5 apresenta as metodologias empregadas, tanto para o estudo da resistência à compressão do concreto, quanto para a determinação da força de arrancamento.
- No Capítulo 6 são apresentados os resultados obtidos no desenvolvimento desse estudo, para a determinação da resistência à compressão do concreto, a partir das bases de dados utilizadas, para cada modelo computacional utilizado.
- No Capítulo 7 são apresentados os resultados obtidos no desenvolvimento desse estudo, para a determinação da força de arrancamento aço/concreto, a partir das bases de dados utilizadas, para cada modelo computacional utilizado.

- No Capítulo 8 são discutidos os resultados encontrados para a resistência à compressão do concreto e para a resistência ao arrancamento.
- No Capítulo 9 são apresentadas a conclusão e as considerações finais.

## 2. CARACTERÍSTICAS DO CONCRETO

Neste capítulo, é abordado as características do concreto que serão discutidas neste trabalho. Primeiramente, é essencial descrever a resistência à compressão do concreto, destacando sua importância e explicando como os ensaios laboratoriais para sua determinação são realizados. Em seguida, é discutido a relevância da tensão de aderência entre aço e concreto, o ensaio adotado neste estudo para sua determinação e os fatores que influenciam no seu desempenho.

### 2.1. RESISTÊNCIA À COMPRESSÃO DO CONCRETO

Uma das principais propriedades mecânicas do concreto é a resistência característica à compressão. Essa propriedade é influenciada por diversos fatores, tais como: tipo e proporção de cimento; granulometria; diâmetro máximo, forma, textura, resistência e rigidez dos agregados; relação água/materiais cimentícios; tipo e proporção dos aditivos químicos e minerais (como metacaulim, sílica ativa, quartzo, entre outros); grau de compactação; condições de cura; e procedimento de ensaio, entre outros (CASTRO; LIBORIO; PANDOLFELLI, 2009).

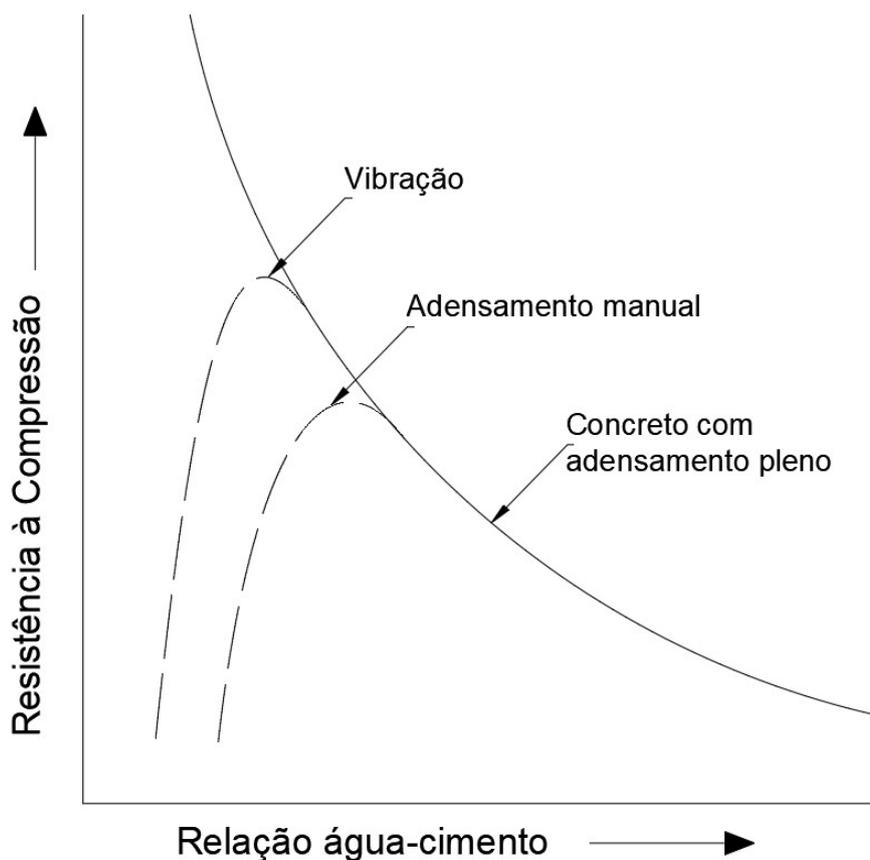
O processo de determinação da resistência à compressão do concreto começa com a moldagem e a cura dos corpos de prova, que serão submetidos ao esforço de compressão. Estes corpos de prova podem apresentar formatos cilíndricos ou prismáticos. Após a moldagem e o período de cura, são realizados os procedimentos do ensaio de compressão.

Inicialmente, o corpo de prova é posicionado em uma prensa hidráulica e submetido a um esforço ( $F$ ) de compressão. Isso resulta em deformações longitudinais e transversais no material. Quando o corpo de prova atinge a carga máxima, é considerado rompido, mesmo que não apresente sinais visíveis de fratura. Dessa forma, a resistência à compressão na ruptura ( $\sigma$ ) pode ser calculada dividindo-se o esforço máximo ( $F$ ) pela área transversal ( $A$ ) do corpo de prova (METHA; MONTEIRO, 2008).

No entanto, é importante destacar que diversos fatores influenciam a resistência à compressão do concreto, mesmo utilizando o mesmo cimento. Entre esses fatores, destacam-se a relação água/cimento e as características dos agregados, que são fundamentais para a resistência do material. Vale ressaltar também que diferentes resultados podem ser obtidos utilizando o mesmo cimento (marca, tipo, finura, composição química, lote) e os mesmos agregados (mesma jazida, mesma mineralogia, mesmo lote, mesma textura, mesma morfologia, mesma granulometria, módulo de finura e diâmetro máximo de agregado).

É possível afirmar que, quando adensado de maneira adequada, o concreto apresentará uma resistência à compressão inversamente proporcional à relação água/cimento, conforme ilustrado na Figura 2.1.

Figura 2.1: Relação entre a resistência à compressão e a relação água/cimento do concreto.



Fonte: Adaptado de Neville (2015)

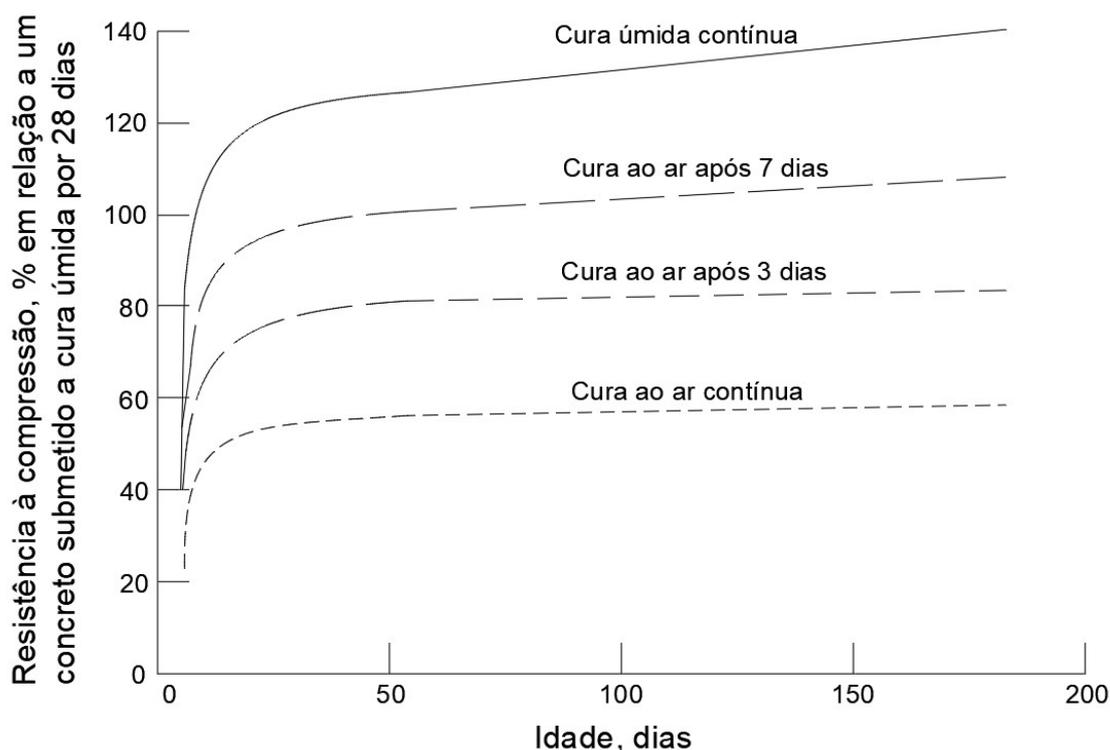
A partir da análise dessa figura, também se pode afirmar que a relação entre a resistência à compressão do concreto e o fator água/cimento é limitada, pois para um adensamento pleno, onde as relações água/cimento são baixas, essa curva deixa de ser válida. Apesar disso, o fator água/cimento é o elemento mais correlacionado com a resistência do concreto (NEVILLE, 2015).

Entre os principais agregados, estão os agregados miúdos e os agregados graúdos, popularmente conhecidos como areia e brita, respectivamente. Os agregados utilizados na fabricação do concreto devem apresentar características específicas, como estabilidade dos grãos minerais e durabilidade. É necessário, também, que esses agregados não interfiram na hidratação do cimento, ou seja, que sejam materiais inertes. Outros aspectos importantes nas características dos agregados incluem: a absorção de água; a porosidade; a distribuição granulométrica; a forma; o tipo de substâncias presentes e a resistência à compressão antes da realização da mistura. Os agregados têm o objetivo de transmitir as tensões ao concreto e reduzir o efeito das variações de retração. Um aumento na resistência à compressão do concreto pode ser obtido com uma granulometria bem definida dos agregados, fato explicado pela diminuição dos vazios no material (LI, 2011).

Bastos (2006) define a cura do concreto como um procedimento necessário para a hidratação do cimento, afetando diretamente a resistência do material. A cura é a etapa principal na execução de estruturas de concreto, responsável por manter a quantidade adequada de água para que ocorram as reações químicas durante o período de endurecimento, principalmente nos estágios iniciais. Trata-se de um procedimento essencial, independentemente do tipo de concreto. A cura pode ser descrita como uma combinação de umidade, tempo e temperatura do concreto (KUMMER, 2017).

Analisando a Figura 2.2 é possível constatar que a resistência à compressão do concreto aumenta significativamente até a idade de 28 dias. Após esse período, observa-se que, em cura úmida contínua, o processo de hidratação dos componentes do cimento continua a contribuir para o aumento da resistência, enquanto nos demais tipos de cura praticamente não há alteração.

Figura 2.2: Influência da cura sobre a tensão a compressão do concreto.



Fonte: Adaptado de Metha e Monteiro (2008)

A resistência à compressão do concreto é uma característica essencial para o dimensionamento das estruturas, especialmente no Brasil, onde o concreto é o principal material utilizado nas construções. No entanto, devido às características dos componentes necessários para a fabricação do concreto e ao processo de produção, a determinação da resistência à compressão e de outras

propriedades mecânicas do material torna-se uma tarefa custosa, exigindo ensaios destrutivos para sua obtenção.

## **2.2. TENSÃO DE ADERÊNCIA AÇO-CONCRETO**

Conforme mencionado anteriormente, o concreto simples, que não possui nenhuma armação, é um material que resiste apenas aos esforços de compressão, apresentando uma resistência à tração muito baixa. Portanto, para que o concreto seja empregado estruturalmente na construção civil, é necessária a participação do aço, que atuará resistindo aos esforços de tração resultantes da aplicação do carregamento na estrutura. Dessa forma, o concreto armado é formado pela ação conjunta entre a armadura de aço e a pasta de concreto. Em consequência, a aderência entre esses dois materiais é fundamental para a absorção dos esforços solicitantes, permitindo que ambos trabalhem juntos. Esse fenômeno é o principal fator responsável por tornar o concreto uma solução viável.

A aderência desempenha, assim, uma função crucial na determinação da capacidade de carga da estrutura de concreto armado. Nesse contexto, seu conhecimento é essencial para calcular as ancoragens das barras de aço no concreto, as emendas por traspasse das barras das armaduras, a determinação das deflexões e o controle das aberturas das fissuras das peças de concreto.

A ligação conjunta da armadura e do concreto pode ser descrita como uma composição de diversas parcelas decorrentes de diferentes fenômenos atuantes na junção aço-concreto. Essas parcelas são conhecidas como aderência por adesão química, aderência por atrito e aderência mecânica (FUSCO, 2000).

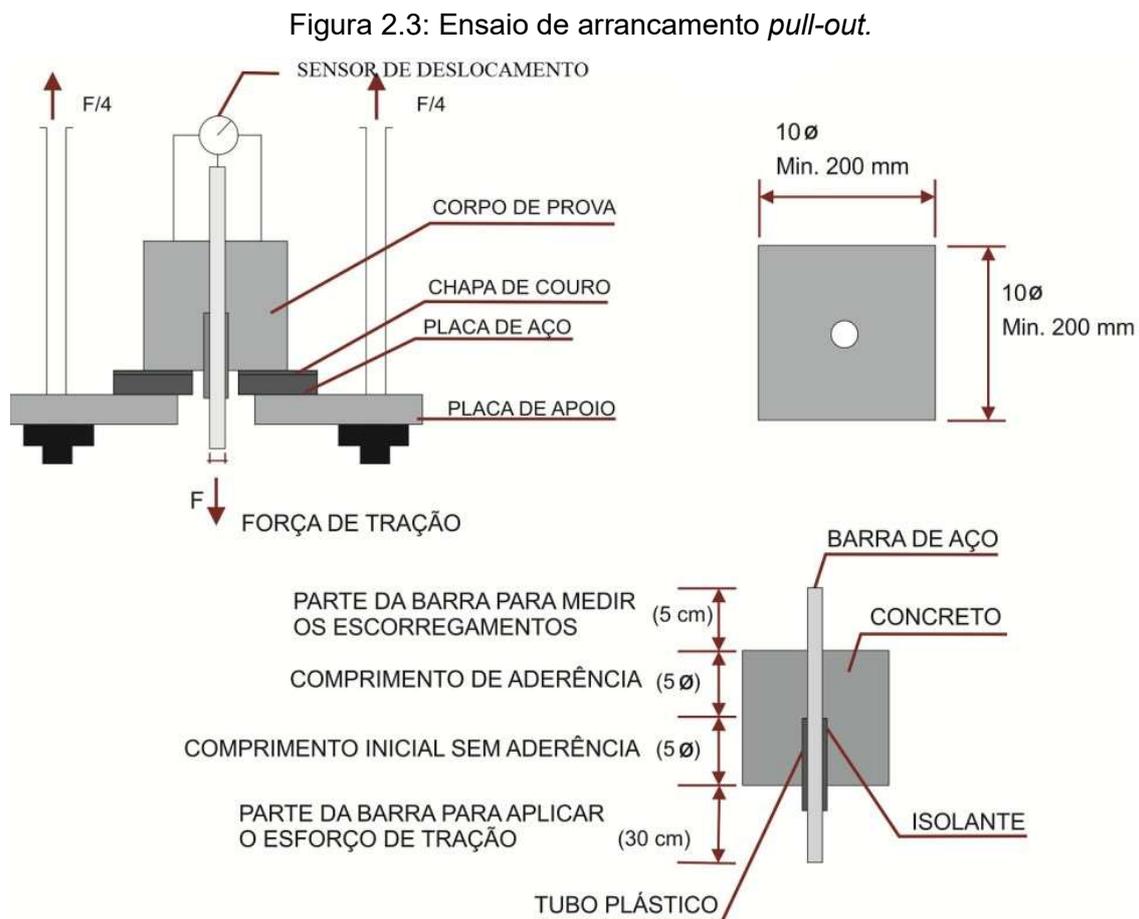
A aderência por adesão química resulta da ligação físico-química estabelecida na interface entre o aço e o concreto durante as reações de pega do cimento. A intensidade dessas forças de ligação depende da penetração da pasta de cimento na barra de aço e pode variar conforme as condições de laminação, estiramento e corrosão da barra. No entanto, essa aderência, quando considerada isoladamente, não é suficiente para suportar os esforços aos quais as estruturas estão expostas, sendo facilmente comprometida por pequenos deslocamentos.

A aderência por atrito, por sua vez, ocorre em virtude de pequenos deslocamentos após o rompimento da adesão química, resultantes de pressões transversais originadas pelas tensões de compressão. Essa ligação é considerável e depende da rugosidade da barra de aço, cuja conformação superficial desempenha um papel crucial no aumento desse atrito (FUSCO, 2000).

Por fim, tem-se que a aderência mecânica, que ocorre através do intertravamento mecânico entre as barras de aço e a pasta de concreto endurecida. Esse fenômeno é resultado das nervuras presentes nas barras de aço, que formam “consoles de concreto” solicitados ao cisalhamento e à

compressão, quando se tenta deslizar a barra na estrutura de concreto. Esse tipo de aderência é a ligação mais confiável e contribui significativamente para a solidificação desses dois materiais. O efeito dessa ligação é mais forte em barras nervuradas e entalhadas, no entanto, também pode estar presente em barras lisas devido às irregularidades superficiais ocorridas durante o processo de laminação.

Em relação aos ensaios laboratoriais, a literatura indica que um dos testes mais utilizados para avaliar a ligação entre concreto e aço são os testes de arrancamento, conhecidos como *pull-out*, descritos na RILEM/CEB RC6 (1983). Esse ensaio consiste em extrair uma barra de aço posicionada no centro de um espécime cúbico de concreto. A força de arrancamento é medida em uma extremidade, enquanto o deslocamento é registrado na outra extremidade, conforme ilustrado na Figura 2.3.



Fonte: Carvalho *et al.* (2017)

Conforme ilustrado na Figura 2.3, o ensaio utiliza um corpo de prova cúbico de concreto com dimensões de  $10\phi$  (dez vezes o diâmetro da barra de aço) ou, no mínimo, 20x20 cm. Uma barra de

aço é posicionada no centro do molde e submetida a esforços de tração até a ruptura. As extremidades da barra são projetadas para fora do corpo de prova, e a força de tração é medida em uma das extremidades, enquanto os deslizamentos são registrados na outra. A recomendação define um comprimento de ancoragem de  $5\phi$  (onde  $\phi$  é o diâmetro da barra), e o comprimento não ancorado é isolado com a utilização de um conduíte rígido de PVC (MIRANDA, 2018).

A tensão de aderência obtida no ensaio pode ser determinada usando a Equação (2.1).

$$\tau = \frac{F}{\pi \cdot \phi \cdot l_d} \quad (2.1)$$

Em que  $\tau$  é a tensão de arrancamento,  $F$  é a carga aplicada,  $\phi$  é o diâmetro da barra de aço e  $l_d$  é o comprimento de ancoragem. Embora a Equação (2.1) possa ser usada para estimar a tensão de arrancamento da barra, o valor da carga  $P$  é determinado pelo teste de arrancamento, que envolve métodos destrutivos e dispendiosos.

Como mencionado anteriormente, a falha na ligação das barras entalhadas e nervuradas geralmente envolve dois fenômenos. O primeiro é caracterizado pelo esmagamento local do concreto que envolve as nervuras das barras e/ou a ruptura do concreto devido a trincas radiais ao redor da barra de aço. O esmagamento local acontece quando o confinamento proporcionado pelo concreto ao redor da barra de aço ou pela armadura transversal é grande e/ou a altura da nervura é pequena. Por outro lado, a ruptura por fissuração ocorre quando o confinamento é insuficiente e/ou a altura das nervuras presentes nas barras de aço é considerável (MAKNI *et al.*, 2014).

Em ensaios do tipo *pull-out* de barras finas nervuradas de aço, a ruptura tende a ser por arrancamento, uma vez que o confinamento das barras de aço costuma ser mais significativo, aumentando a resistência do bloco de concreto e dificultando a ruptura por fissuração. Nessas barras, a área relativa das nervuras desempenha um papel importante na resistência da ligação. A resistência de aderência com o concreto circundante é controlada principalmente pelo esforço de confinamento do concreto. A falha, nesses casos, ocorre sempre devido ao cisalhamento do concreto localizado entre as nervuras consecutivas, o que depende da resistência do concreto (MAKNI *et al.*, 2014).

Os métodos ilustrados neste capítulo são considerados métodos experimentais, os quais envolvem a utilização de protótipos físicos em escala real para investigar o fenômeno em estudo. Esses métodos proporcionam resultados de alta qualidade, porém exigem um investimento significativo na fabricação dos corpos de prova e na infraestrutura necessária para simular o experimento. Outra

dificuldade encontrada nesses métodos é o tempo necessário para a realização do ensaio, onde pode ser preciso realizar várias simulações até se obter um modelo ideal que reproduza fielmente os ensaios padronizados, principalmente em ensaios destrutivos, que resultam na perda do corpo de prova.

O método analítico consiste na resolução de equações baseadas em fórmulas matemáticas que descrevem os fenômenos físicos. Entretanto, esses cálculos nem sempre podem ser aplicados a todos os problemas de engenharia, pois a resolução das equações que descrevem o fenômeno pode ser extremamente complexa, e nem sempre é possível definir equações que descrevam o fenômeno de maneira satisfatória. Para tornar as equações solucionáveis, adota-se a simplificação das características físicas envolvidas, idealizando o que é observado na prática. Como resultado, os valores obtidos por meio dessas equações podem apresentar desvios consideráveis em relação à realidade, o que pode gerar problemas no dimensionamento. No entanto, as soluções analíticas de alguns problemas podem servir como base para a compreensão do comportamento, o desenvolvimento de métodos numéricos e a verificação de códigos computacionais.

Os métodos numéricos buscam encontrar soluções numéricas aproximadas para problemas complexos por meio da aplicação de algoritmos, permitindo a elaboração e o cálculo de operações matemáticas usando sequências aritméticas simples. Atualmente, esse método está associado à tecnologia e ao uso de computadores. Devido à maior acessibilidade e capacidade de processamento dos computadores, seu uso tornou-se popular em situações em que as resoluções manuais podem ser impraticáveis. Essa abordagem requer um investimento menor que o método experimental e, muitas vezes, pode ser considerada mais viável que o método analítico devido sua capacidade de resolução de equações complexas.

No entanto, os métodos numéricos também apresentam limitações, pois o número de variáveis que podem ser consideradas é, frequentemente, limitado e as soluções numéricas não podem ser obtidas diretamente de acordo com as preferências dos usuários (CHAPRA; CANALE, 2016).

Diversos autores buscaram descrever o esforço de arrancamento através de equações. No entanto, os modelos utilizados para a formulação dessas equações consideraram como parâmetros de entrada tipos específicos de falhas, como a falha por arrancamento. Dessa forma, para a análise do arrancamento, é possível aplicar a Equação (2.2) (CEB, 2010) que descreve o esforço de arrancamento com base na resistência à compressão do concreto para qualquer tipo de falha, em MPa.

$$\tau = 2,5 \times \sqrt{f_{ck}} \quad (2.2)$$

Diversos modelos analíticos e numéricos na literatura buscam representar a resposta à tensão de arrancamento em uma ligação na interface aço-concreto. A maioria desses modelos baseia-se em resultados experimentais e considera diversos parâmetros, como resistência à compressão do concreto, cobertura de concreto, diâmetro da barra de aço e comprimento de ancoragem. Os testes geram equações para calcular a tensão média da ligação através de regressões lineares ou não lineares a partir dos resultados experimentais.

As técnicas analíticas para determinar a resistência à compressão do concreto e a tensão de ruptura da aderência do aço-concreto tem sido discutidas por vários autores. Com a disponibilidade de computadores digitais, os métodos numéricos tornaram-se mais atraentes do que as soluções analíticas, uma vez que podem lidar com situações mais complexas e realistas. Muitos problemas de engenharia de materiais são justamente o tipo de problema onde uma abordagem computacional parece ser mais adequada.

### 3. MODELOS COMPUTACIONAIS

Este capítulo apresenta os métodos computacionais utilizados neste trabalho, descrevendo a fundamentação teórica para a implementação dos algoritmos de inteligência computacional. São abordados os conceitos necessários dos seguintes métodos: árvores de decisão e florestas aleatórias, máquinas vetoriais de suporte, redes neurais artificiais e regressor gradiente *boosting*. Além disso, são apresentados os métodos de pré-processamento de dados e análise de resultados empregados.

#### 3.1. PRÉ-PROCESSAMENTO DE DADOS

O conjunto de dados utilizado pode precisar de pré-processamento antes de ser aplicado aos modelos de regressão. As técnicas de pré-processamento são eficazes e podem melhorar o desempenho dos modelos computacionais (WANG; WANG; ALEXANDER, 2015). Essa seção aborda as técnicas de pré-processamento que podem ser utilizadas visando aprimorar a resposta do modelo.

Uma das etapas de pré-processamento comum é o *feature scaling* ou escalonamento de recursos. Esse método tem como objetivo normalizar todas as características, ou seja, transformar os dados utilizados em uma escala comum. Isso evita que uma característica exerça uma influência desproporcional na variável-alvo devido ao seu valor numérico absoluto. Dessa forma, a normalização dos dados permite uma análise mais equilibrada. Nessa etapa, os recursos são dimensionados para a mesma escala, sendo transformados de modo que se encontrem dentro de uma faixa específica, geralmente entre 0 e 1 (FORMAN, 2008; ZHANG; ZHOU, 2004).

Para alguns modelos, a escala é essencial antes de construir o modelo de aprendizado de máquina, pois, em várias situações, a distância entre os pontos analisados pode resultar em um ponto dominando outro e, assim, exercendo maior influência no valor da variável-alvo. Para evitar essa anomalia, todos os recursos devem ser transformados em uma escala específica antes de serem usados na construção do modelo computacional.

Para obter bons resultados no aprendizado de máquinas, é comum dividir a base de dados em conjuntos de treinamento e teste. Dessa forma, o algoritmo é treinado com uma parcela dos dados e, em seguida, validado no conjunto de teste. Isso garante que o resultado obtido não seja enviesado e apenas aprenda com dados similares aos utilizados para o treinamento. Esse processo é chamado de *resampling* ou reamostragem e consiste na reorganização do conjunto de dados, dividindo-o em grupos de treinamento e teste (GOOD, 2006).

O *hold-out validation* é a maneira mais simples de separar os dados. Nessa abordagem, define-se um percentual para cada conjunto de dados, que podem ser divididos em treinamento e teste ou

treinamento, validação e teste. A divisão treinamento e teste, sem o conjunto de validação, é comumente usada quando o conjunto de dados é pequeno e não há dados suficientes para dividir em três conjuntos (treinamento, validação e teste). Esse método é simples de implementar, mas pode ser sensível à forma como os dados são divididos em dois conjuntos. Se a divisão não for aleatória, os resultados podem ser tendenciosos.

Quando se dispõe de um volume maior de dados, é possível utilizar uma camada de validação. Isso permite verificar se as amostras criadas têm significância estatística para representar a população. Nessa divisão, há três conjuntos de dados. O primeiro, o conjunto de treinamento, é usado para treinar o modelo e geralmente possui o maior volume de dados. O segundo, o conjunto de teste, é mantido separado e introduzido posteriormente para avaliar o desempenho do modelo treinado com novos dados. O conjunto de teste é utilizado para testar a implementação do modelo computacional, evitando que o modelo seja testado apenas com dados de treinamento, o que dificultaria a generalização dos resultados. Por fim, o conjunto de validação é composto por dados separados e utilizados para determinar a qualidade do treinamento do modelo. Esses dados são empregados para medir o desempenho do modelo e calcular os parâmetros de erro.

Uma outra abordagem para separar os dados é a validação cruzada ou *cross-validation*. Há diversos tipos de validação cruzada, mas a mais comum e conhecida é o *k-fold*. Neste método, cria-se um número  $k$  de amostras, onde cada amostra é deixada de fora enquanto o modelo é treinado com as demais. O processo é repetido até que se possa determinar a qualidade de cada divisão. O valor de  $k$  deve ser escolhido de modo que os grupos de dados para treino e teste sejam suficientemente grandes para representar estatisticamente o conjunto de dados original. Na literatura, recomenda-se um valor de  $k$  entre 5 e 10 (EFRON; TIBSHIRANI, 1997; GOLUB; HEATH; WAHBA, 1979; SHAO, 1993).

Por fim, o *GridSearchCV* é um processo de ajuste por hiperparametrização, ou seja, um método que utiliza um algoritmo para encontrar um conjunto de valores que maximizem critérios de desempenho, definindo os valores ideais para um determinado modelo. Isso significa que o desempenho do modelo é baseado nos valores de um hiperparâmetro especificado. O *GridSearchCV* realiza uma busca exaustiva sobre os parâmetros de cada modelo, usando um produto cartesiano dos parâmetros especificados, mantendo todos os outros constantes, visando a minimização do erro do modelo. Esse método é computacionalmente caro, mas produz bons resultados (BUITINCK *et al.*, 2013; PEDREGOSA *et al.*, 2011).

### 3.2. ÁRVORES DE DECISÃO E FLORESTAS ALEATÓRIAS

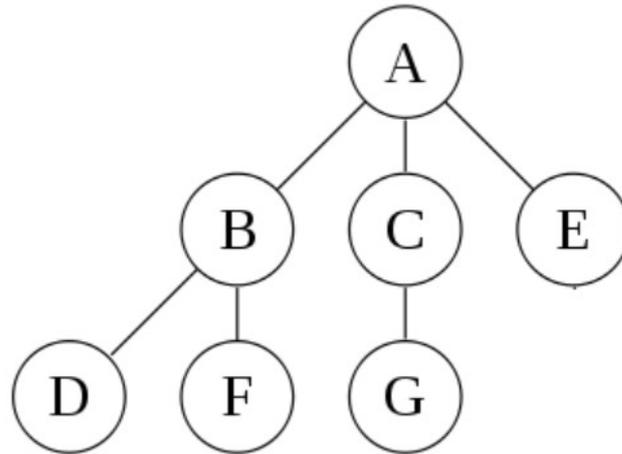
A árvore de decisão (DTR) é um algoritmo de aprendizagem supervisionada amplamente utilizado para problemas de classificação. Esse algoritmo é aplicável tanto para variáveis categóricas quanto contínuas de entrada e saída. Na árvore de decisão, a população é dividida em dois ou mais conjuntos homogêneos (subpopulações) com base nos divisores/diferenciadores mais significativos das variáveis de entrada. Assim, a árvore de decisão identifica a variável mais representativa e os valores que geram os conjuntos de população mais homogêneos.

As florestas aleatórias (RFR) são uma técnica poderosa de aprendizagem em conjunto, comumente usada em tarefas de classificação e regressão. Simplificadamente, nas florestas aleatórias, são utilizadas múltiplas árvores de decisão em vez de uma única árvore. Para classificar um novo objeto com base em atributos, cada árvore fornece uma classificação. As florestas selecionam a classificação com maior pontuação de todas as árvores e, em casos de regressão, consideram a média das saídas por diferentes árvores (BREIMAN, 2001).

As árvores de decisão são frequentemente destacadas por serem diferentes dos típicos “classificadores de prateleira” devido à sua simplicidade de uso e à ausência de necessidade de estratégias avançadas de pré-processamento. As florestas aleatórias, por outro lado, consistem em construir um conjunto de árvores com variação controlada, criando várias árvores de decisão e combinando-as para obter melhores previsões com maior precisão e acurácia (GISLASON; BENEDIKTSSON; SVEINSSON, 2006).

Para melhor compreender as árvores de decisão, é necessário definir alguns conceitos, como apresentado na Figura 3.1:

Figura 3.1: Exemplo de árvore.



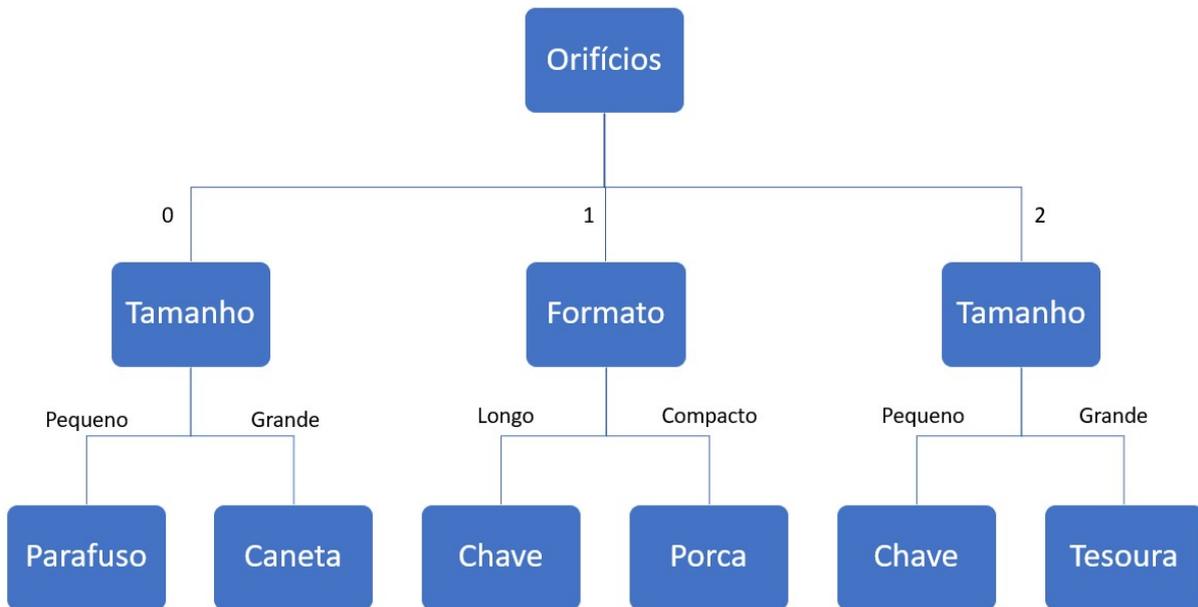
Onde:

- As bolas A, B, C e assim por diante representam os nós da árvore;
- As linhas que conectam os nós são chamadas de arestas;
- A é o nó raiz, a partir do qual a árvore começa;
- Um conjunto de nós e arestas interconectados forma uma sub-árvore;
- A é considerado o ancestral de B, C e E, que, por sua vez, são chamados de descendentes de A;
- Os nós B e C são conhecidos como nós internos, enquanto os nós D, F e G são chamados de nós terminais ou folhas.

Uma árvore de decisão começa sua análise a partir de um único nó, que se ramifica em diferentes resultados possíveis. Estes resultados conduzem a novos nós, que por sua vez se dividem em outras possibilidades. A estrutura de uma árvore de decisão é composta por nós internos com atributos, folhas com classes e ramos rotulados com atributos categóricos ou numéricos.

A Figura 3.2 ilustra um exemplo de árvore de decisão utilizada para classificar objetos em cinco categorias: porca, parafuso, chave, caneta e tesoura. O algoritmo extrai atributos das imagens, como tamanho (pequeno ou grande), formato (longo, compacto, outro) e número de orifícios (0, 1, 2, 3, muitos).

Figura 3.2: Exemplo de árvore de decisão.



Para compreender árvores de decisão e florestas aleatórias, é importante abordar conceitos como hiperparâmetros e *bagging*. Hiperparâmetros são variáveis definidas antes do treinamento do algoritmo, enquanto os parâmetros são ajustados durante o processo de aprendizado. *Bagging* é uma técnica utilizada para reduzir a variância das previsões ao combinar o resultado de vários classificadores treinados em diferentes subconjuntos do mesmo conjunto de dados.

Um classificador de florestas aleatórias possui hiperparâmetros de árvores de decisão e classificadores de *bagging*. A classe de florestas aleatórias é mais conveniente e otimizada para árvores de decisão do que a construção de um classificador de *bagging* separado. Os parâmetros do modelo de florestas aleatórias são usados para aumentar a capacidade preditiva ou tornar o modelo mais eficiente.

Os parâmetros no modelo de florestas aleatórias são utilizados para aumentar o poder preditivo do modelo ou para tornar o modelo mais rápido. A seguir são listados os parâmetros utilizados e os seus significados:

- Número de estimadores: indica o número de árvores construídas pelo algoritmo antes de tomar uma votação ou fazer uma média de previsões. Em geral, um maior número de árvores melhora a performance e estabiliza as previsões, mas também torna a computação mais lenta.
- Profundidade máxima dos estimadores de regressão: a profundidade máxima da árvore.

- Número máximo de características: indica o número máximo de características a serem utilizadas pelo modelo na construção de uma dada árvore.
- Quantidade máxima de nós: número máximo de nós por árvore.
- Número mínimo de amostras para um nó de folha: número mínimo de amostras necessárias para estar em um nó de folha. Um ponto dividido em qualquer profundidade só será considerado se deixar pelo menos o número mínimo de amostras de treinamento para dividir um nó inteiro em cada um dos ramos esquerdo e direito. Isso pode ter o efeito de suavizar o modelo, especialmente em regressão.
- Número mínimo de amostras para dividir um nó interno: número mínimo de amostras necessárias para dividir um nó interno.

Ao utilizar o *GridSearchCV*, é possível calcular automaticamente o valor de cada característica após o treinamento e normalizar os resultados para que a soma de todas as importâncias seja igual a 1. Isso permite identificar quais características podem ser descartadas, já que não contribuem significativamente para o processo de predição.

A Tabela 3.1 apresenta as vantagens e desvantagens do uso de árvores de decisão. Já a Tabela 3.2 apresenta as vantagens e desvantagem da utilização das florestas aleatórias como métodos de inteligência computacional.

Tabela 3.1: Vantagens e desvantagens das árvores de decisão e das florestas aleatórias.

<b>Árvores de decisão</b>	
<b>Vantagens</b>	<b>Desvantagens</b>
<ul style="list-style-type: none"> <li>• Fácil interpretação e visualização: As árvores de decisão são simples de entender e interpretar, uma vez que seguem uma estrutura semelhante à tomada de decisão humana.</li> <li>• Requer pouco pré-processamento de dados: Árvores de decisão geralmente não requerem normalização de dados ou tratamento de valores ausentes.</li> <li>• Lida com variáveis categóricas e numéricas: As árvores de decisão podem lidar com variáveis categóricas e numéricas, tornando-as versáteis.</li> <li>• Seleção automática de recursos: Durante a construção da árvore, o algoritmo seleciona automaticamente os recursos mais importantes, o que pode ser útil para reduzir a dimensionalidade.</li> </ul>	<ul style="list-style-type: none"> <li>• Propensas a <i>overfitting</i>: As árvores de decisão podem facilmente se ajustar demais aos dados de treinamento, o que pode prejudicar o desempenho em dados não vistos.</li> <li>• Sensíveis a variações nos dados: Pequenas variações nos dados de treinamento podem resultar em árvores de decisão muito diferentes.</li> <li>• Instabilidade: Árvores de decisão podem ser instáveis e podem gerar resultados diferentes com pequenas alterações nos dados.</li> <li>• Pode gerar árvores enviesadas: Se algumas classes dominam o conjunto de dados, a árvore de decisão pode ser enviesada em favor dessas classes.</li> </ul>

Tabela 3.2: Vantagens e desvantagens das árvores de decisão e das florestas aleatórias.

<b>Florestas Aleatórias</b>	
<b>Vantagens</b>	<b>Desvantagens</b>
<ul style="list-style-type: none"> <li>• Redução do <i>overfitting</i>: Ao combinar várias árvores de decisão, as florestas aleatórias reduzem o risco de <i>overfitting</i>.</li> <li>• Melhor desempenho: Florestas aleatórias geralmente apresentam melhor desempenho de classificação ou regressão em comparação com árvores de decisão únicas.</li> <li>• Lida com variáveis categóricas e numéricas: Assim como as árvores de decisão, as florestas aleatórias podem lidar com variáveis categóricas e numéricas.</li> <li>• Robustez a ruído e outliers: Florestas aleatórias são menos sensíveis a ruído e outliers nos dados devido à combinação de várias árvores.</li> </ul>	<ul style="list-style-type: none"> <li>• Maior complexidade computacional: Florestas aleatórias podem ser mais lentas para treinar e fazer previsões em comparação com árvores de decisão individuais devido à combinação de várias árvores.</li> <li>• Menos interpretação e explicabilidade: Enquanto as árvores de decisão individuais são facilmente interpretáveis, a combinação de várias árvores em uma floresta aleatória torna a interpretação e explicabilidade mais complexa.</li> <li>• Requer mais recursos computacionais: Florestas aleatórias requerem mais memória e poder de processamento do que árvores de decisão únicas devido à combinação de várias árvores.</li> </ul>

Dessa forma, as árvores de decisão e as florestas aleatórias destacam-se como excelentes algoritmos para serem aplicados nos estágios iniciais do desenvolvimento de um modelo. Esses algoritmos oferecem uma abordagem robusta e intuitiva, permitindo a análise e interpretação dos dados de forma eficaz. Além disso, eles são capazes de lidar com conjuntos de dados complexos e variáveis de diferentes tipos, tornando-os versáteis em várias aplicações.

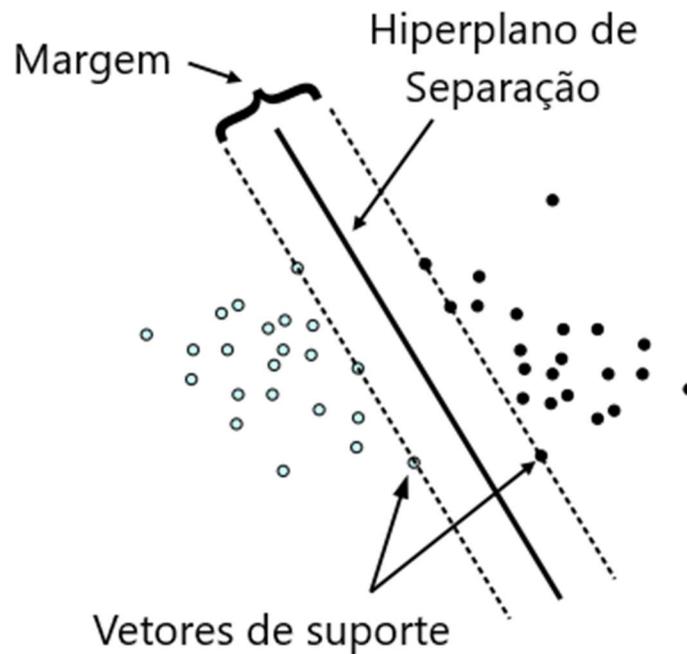
### **3.3. MÁQUINAS VETORIAIS DE SUPORTE**

Máquinas vetoriais de suporte (SVM) são algoritmos de aprendizagem populares conhecidos por funcionar bem em problemas de classificação e regressão. Além de realizar regressão linear e classificação, os SVM também têm bom desempenho em dados não lineares (LIN; WANG, 2002; SCHOLKOPF; SMOLA, 2001).

Esta técnica constrói um hiperplano, que é um plano de decisão que separa e classifica um conjunto de dados em diferentes classes da melhor maneira possível, ou seja, as máquinas vetoriais de

suporte constroem um hiperplano com o intuito de separar dados de forma que valores semelhantes estejam do mesmo lado do plano separador. Para entender melhor, é necessário definir alguns parâmetros importantes para o desenvolvimento das máquinas vetoriais de suporte, conforme apresentado na Figura 3.3:

Figura 3.3: Parâmetros importantes nas máquinas vetoriais de suporte.



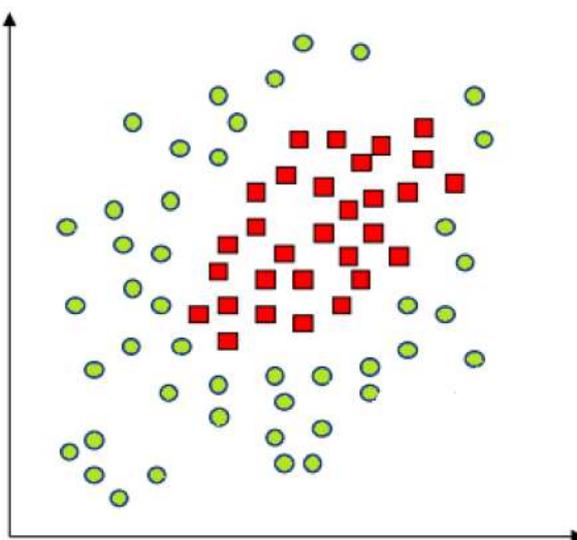
- Hiperplano: um plano de decisão que separa e classifica um conjunto de dados;
- Vetores de suporte: os pontos de dados mais próximos do hiperplano;
- Margem: a distância entre o hiperplano e o ponto de dados mais próximo de qualquer conjunto.

Para problemas de classificação de dados linearmente separáveis semelhantes àqueles mostrados na Figura 3.3, ou seja, para problemas de classificação de padrões que podem ser resolvidos a partir de uma superfície de decisão linear, existem muitos hiperplanos diferentes que podem separar os dados com precisão. Nesse caso, o problema estaria em encontrar um hiperplano que poderia maximizar a separação entre as duas classes (SUYKENS; VANDEWALLE, 1999).

A margem do separador é a distância entre os vetores de suporte em ambos os lados do hiperplano. Em outras palavras, não há pontos dentro da margem. Os vetores de suporte nos SVM são os pontos mais próximos das margens. As margens suaves permitem que alguns pontos estejam

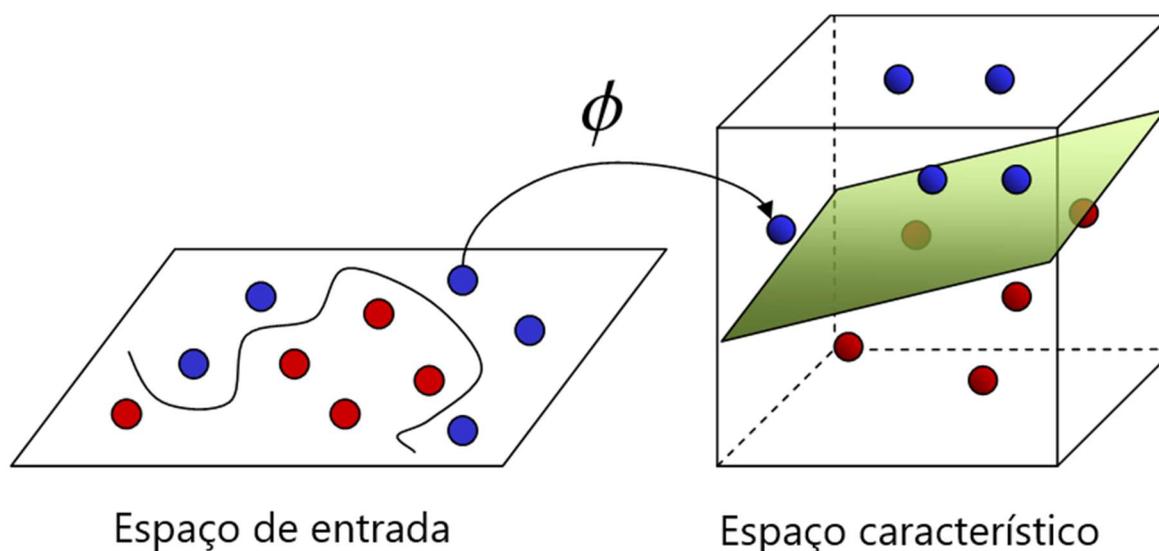
dentro da margem ou até mesmo do lado errado do hiperplano, enquanto as margens rígidas não o permitem. O SVM pode utilizar margens rígidas ou suaves, dependendo da natureza dos dados. De maneira simplificada, as máquinas vetoriais de suporte buscam encontrar uma linha ou hiperplano que separe duas classes de pontos de dados. Embora os classificadores lineares SVM sejam eficientes e funcionem bem em muitos casos, diversos conjuntos de dados não são linearmente separáveis. Nesses casos, quando as duas classes a serem separadas têm formatos curvos, não haverá linha, plano ou hiperplano que as separe completamente, como ilustrado na Figura 3.4.

Figura 3.4: Dados não linearmente separáveis.



Nesses casos, é necessário adaptar o algoritmo de forma independente. A abordagem mais comum é usar uma técnica geral chamada *kernel trick*, que permite generalizar algoritmos lineares para que possam ser aplicados a formas curvas de distribuição de dados. A Figura 3.5 ilustra o uso do *kernel trick*, mostrando um espaço bidimensional achatado e um espaço tridimensional com um hiperplano em verde. Em resumo, a função de *kernel* transforma dados linearmente inseparáveis em dados separáveis, adicionando mais dimensões a esses dados (BENNETT; DEMIRIZ, 1999).

Figura 3.5: Transformação de um problema não linearmente separável em um problema linearmente separável através do *kernel trick*.



Fonte: Rebelo (2008)

No aprendizado de máquinas, as funções de *kernel* servem para projetar vetores de características de entrada em um espaço de características de alta dimensão, permitindo a classificação de problemas em espaços não linearmente separáveis. Um *kernel* é um método que viabiliza a aplicação de classificadores lineares a problemas não lineares, mapeando dados não lineares em um espaço de dimensão superior sem a necessidade de visitar ou entender esse espaço (OSUNA; FREUND; GIROSIT, 1997).

Nesse contexto, existem basicamente três tipos principais de *kernels* comumente utilizados em máquinas vetoriais de suporte:

- Linear: pode ser usada quando os dados são linearmente separáveis, ou seja, podem ser separados por uma linha reta. Mesmo que o conjunto de dados não seja linear, essa *kernel* mapeia o espaço original (não linear) para um novo espaço de maior dimensão, chamado espaço de características, que é linearmente separável. Essa *kernel* é aplicada principalmente em conjuntos de dados com um grande número de características.
- Polinomial: este *kernel* utiliza uma função polinomial para mapear os dados do espaço original para um espaço de maior dimensão. Ele faz isso ao calcular o produto escalar dos dados no espaço original com uma função polinomial no novo espaço. Este *kernel* não apenas considera as características dadas pelas amostras de entrada para determinar suas semelhanças, mas também analisa as combinações dessas características de interação. Ao

mapear os dados em um espaço de maior dimensão, o *kernel* polinomial pode encontrar um hiperplano que separa as classes.

- Função de Base Radial (RBF): é um *kernel* estacionário, também conhecido como *kernel* gaussiana. A função de base radial é usada principalmente para trabalhar com dados não lineares e geralmente apresenta os melhores resultados para conjuntos de dados mais complexos em regressões SVM. É parametrizado por um parâmetro de escala de comprimento, que pode ser um escalar ou um vetor com o mesmo número de dimensões que as entradas dos dados. Este *kernel* é definido por:

$$k(x_i, x_j) = \exp\left(\frac{d(x_i, x_j)^2}{2l^2}\right) \quad (3.1)$$

Onde:  $l$  é a escala do comprimento do *kernel* e  $d(\dots)$  é a distância euclidiana dos pontos.

O SVM foi originalmente desenvolvido para resolver problemas de classificação. No entanto, problemas de regressão podem ser abordados pelo método de classificação binária. A Regressão Vetorial de Suporte (SVR) é uma técnica de regressão não paramétrica baseada exclusivamente nas funções do *kernel*. O objetivo do SVR é encontrar uma função  $f(x)$  que se desvie de  $y_n$  por um valor não maior que  $\varepsilon$  para cada ponto de treinamento em um conjunto de dados e que, ao mesmo tempo, permaneça o mais plana possível (DRUCKER *et al.*, 1997; GUNN, 1998; SCHOLKOPF; SMOLA, 2001).

Ao utilizar o *GridSearchCV*, mencionado anteriormente na Seção 3.1, para uma parametrização ótima, pode-se aplicar funções lineares, polinomiais e de função de base radial. Isso permite avaliar o desempenho desses *kernels* na base de dados apresentada e testar diferentes parâmetros de entrada.

Para as máquinas vetoriais de suporte, o parâmetro de entrada utilizado é conhecido como  $C$ , que é o parâmetro de penalidade do termo de erro. Este parâmetro controla o equilíbrio entre o limite de decisão suave e a classificação correta dos pontos de treinamento. Para *kernels* polinomiais e de função base radial, também pode ser utilizado um parâmetro  $\gamma$  (*gamma*), que é chamado de coeficiente do *kernel*. Este parâmetro ajusta a função utilizada ao conjunto de dados; quanto maior seu valor, maior a tentativa da função de se ajustar aos dados de treinamento, o que pode causar erro de generalização e problemas de ajuste excessivo.

É recomendável observar a pontuação da validação cruzada para obter uma combinação eficaz desses parâmetros e evitar o ajuste excessivo. Em outros casos, por meio do *GridSearchCV*, pode-se avaliar o melhor desempenho com base nos resultados de  $R^2$ . Assim, é possível obter o melhor desempenho do modelo implementado usando diferentes *kernels*, valores  $C$  e parâmetros  $\gamma$ .

A Tabela 3.3 apresenta as vantagens e desvantagens do uso de máquinas vetoriais de suporte como método de inteligência computacional.

Tabela 3.3: Vantagens e desvantagens das máquinas vetoriais de suporte.

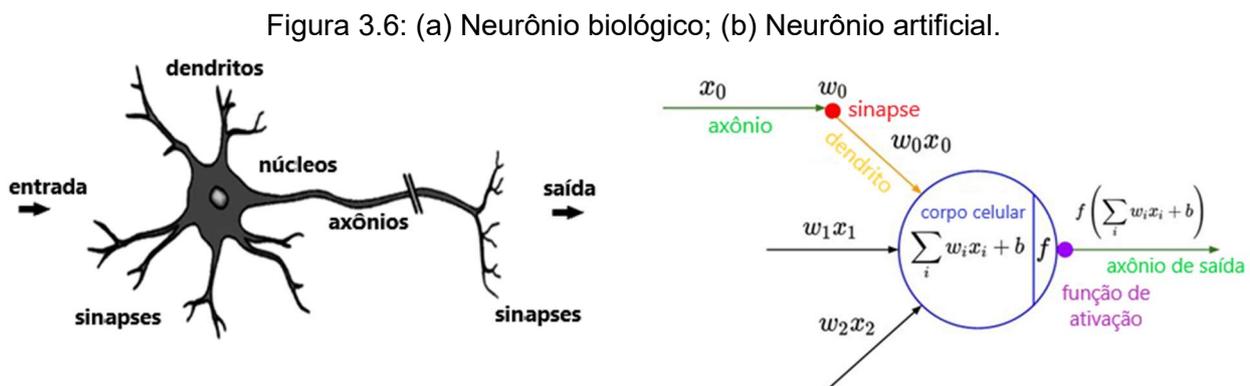
Vantagens	Desvantagens
<ul style="list-style-type: none"> <li>• São eficazes em problemas de classificação com várias dimensões: as SVM são eficazes em problemas de classificação em que o número de variáveis é grande. Isso ocorre porque as SVM usam um espaço dimensional elevado para separar diferentes classes, permitindo uma melhor separação de dados.</li> <li>• Podem lidar com dados não linearmente separáveis: SVM podem usar funções de <i>kernel</i> para mapear dados de um espaço dimensional inferior para um espaço dimensional superior, onde podem ser separados por uma fronteira de decisão linear.</li> <li>• São altamente precisos: SVM tendem a ter melhor precisão em comparação com outros algoritmos de aprendizado de máquina, especialmente em problemas de classificação com muitas características.</li> <li>• São eficientes em problemas com grande número de amostras: SVM podem lidar com grandes conjuntos de dados e são conhecidos por serem eficientes em problemas com grandes quantidades de amostras.</li> </ul>	<ul style="list-style-type: none"> <li>• São sensíveis ao ajuste de parâmetros: SVM têm vários parâmetros que precisam ser ajustados para obter melhores resultados. O processo de ajuste de parâmetros pode ser demorado e pode exigir uma grande quantidade de experimentação.</li> <li>• Podem ser computacionalmente caros: SVM podem ser computacionalmente intensos e exigir muito tempo para treinar. Além disso, o processo de seleção do <i>kernel</i> correto pode ser demorado e exigir muitos recursos.</li> <li>• SVM podem ser sensíveis a outliers: SVM são sensíveis a <i>outliers</i>, que são pontos de dados que estão longe da maioria dos outros pontos de dados. <i>Outliers</i> podem afetar significativamente a posição da fronteira de decisão, tornando a classificação menos precisa.</li> <li>• SVM podem ser difíceis de interpretar: SVM não fornecem interpretações fáceis dos resultados, o que pode tornar difícil entender como o algoritmo chegou a uma determinada decisão de classificação.</li> </ul>

### 3.4. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (ANN) são exemplos típicos de métodos interdisciplinares modernos que ajudam a resolver vários problemas de engenharia que não poderiam ser resolvidos pelos métodos tradicionais. A rede neural é capaz de coletar, memorizar, analisar e processar uma grande quantidade de dados obtidos por meio de experimentos (HOPFIELD, 1988; SARLE, 1994). Essa técnica é uma ilustração de modelagem sofisticada que pode ser usada para resolver uma ampla variedade de problemas complexos.

A rede neural treinada atua como uma ferramenta analítica para prognósticos qualificados dos resultados, para quaisquer dados de entrada que não foram incluídos no processo de aprendizagem da rede. Sua operação é relativamente simples em comparação com outros métodos de inteligência computacional.

Uma rede neural artificial é uma emulação do sistema neural biológico. A Figura 3.6 apresenta uma simplificação dos modelos do neurônio biológico e do neurônio utilizado nas redes neurais.



Os dados de treinamento de entrada/saída são fundamentais para essa rede, pois transmitem informações necessárias para descobrir o ponto de operação ideal. Simulando o neurônio humano, um peso é atribuído a cada seta apresentada na Figura 3.6b, que representam a seta de informação, para dar mais ou menos força ao sinal transmitido. O neurônio de entrada tem apenas uma entrada e sua saída será a entrada recebida multiplicada pelo peso atribuído ao neurônio. O neurônio na camada de saída recebe a saída de ambos os neurônios de entrada, multiplicada por seu respectivo peso.

As redes neurais artificiais são um dos modelos computacionais mais eficazes utilizados em tarefas supervisionadas de regressão e classificação de aprendizagem. As ANN trabalham principalmente com a ajuda de três camadas: a camada de entrada, as camadas ocultas e a camada de saída,

sendo que o desempenho das redes neurais depende, em grande parte, do desempenho das camadas ocultas.

Normalmente, a rede neural recebe um padrão de neurônios na camada inicial. Cada neurônio na camada de entrada deve representar alguma variável independente que influencia o resultado da rede neural. Portanto, o número de nós na camada de entrada é igual ao número de entradas em si (GULLI; PAL, 2017).

A camada de entrada pode possuir um neurônio especial, chamado de *bias*, que serve para aumentar os graus de liberdade, permitindo uma melhor adaptação da rede neural ao conhecimento fornecido. Esse neurônio permite mudar a função de ativação adicionando uma constante. Portanto, essa camada pode ser considerada analogamente ao papel de uma constante em uma função linear, pela qual a linha é efetivamente transposta pelo valor da constante.

O número de neurônios na camada de saída está diretamente relacionado com a tarefa que a rede neural executa. Em geral, o número de neurônios que um classificador deve ter nesta camada é igual ao número de saídas necessárias para cumprir a tarefa proposta.

O número de camadas intermediárias pode variar, assim como o número de neurônios necessários. Problemas que requerem duas ou mais camadas intermediárias podem ser chamados de não usuais. Basicamente, uma rede neural com duas camadas intermediárias é capaz de representar funções de qualquer formato. Portanto, não existem razões teóricas para se utilizar mais que duas camadas intermediárias. Entretanto, independentemente da abordagem, quanto mais camadas de neurônios, melhor é o desempenho da rede neural, pois a capacidade de aprendizado aumenta, melhorando a precisão com que ela delimita as regiões de decisão.

Apesar de não interagirem com o ambiente externo, as camadas intermediárias exercem grande influência no funcionamento da rede. A falta de nós nessas camadas pode causar sub-ajuste (*underfitting*), que ocorre quando poucos neurônios não conseguem detectar adequadamente os sinais em um conjunto complicado de dados. Por outro lado, o excesso de nós pode causar sobreajuste (*overfitting*), que ocorre quando há muitos neurônios a serem treinados por um número limitado de informações contidas em um conjunto de dados. O excesso de neurônios pode fazer com que o treinamento não termine adequadamente em tempo hábil, exigindo grande esforço computacional.

Existem diversas inicializações de pesos que podem ser utilizadas em uma rede neural. Algumas dessas inicializações são (KAVEH; KALATEH-AHANI; FAHIMI-FARZAM, 2013):

- a. Zeros: gera tensores inicializados iguais a 0.
- b. Um: gera tensores inicializados em 1.
- c. Constante: gera tensores de valor constante.

- d. *Random normal*: gera tensores com valores de uma distribuição normal.
- e. *Random uniform*: gera tensores com uma distribuição uniforme.
- f. *Glorot uniform*: também chamado Xavier uniforme, sendo gerado na inicialização pequenos números próximos de 0 (PEDAMONTI, 2018).

Matematicamente, em uma rede neural artificial, os neurônios se parecem com a Equação (3.2), seguidos pela função de ativação, que determina se o neurônio deve ser ativado ou não, conforme apresentado na Equação (3.3):

$$z = w^T X + b \quad (3.2)$$

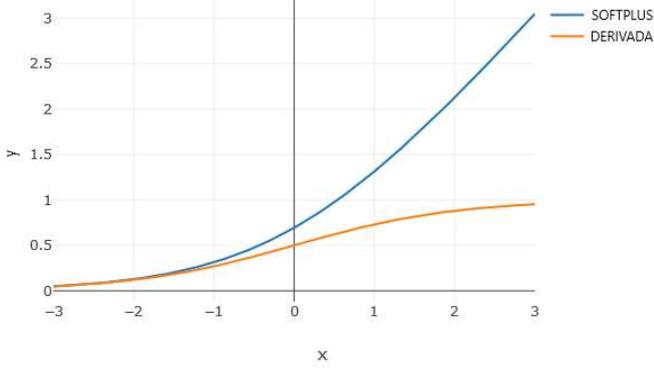
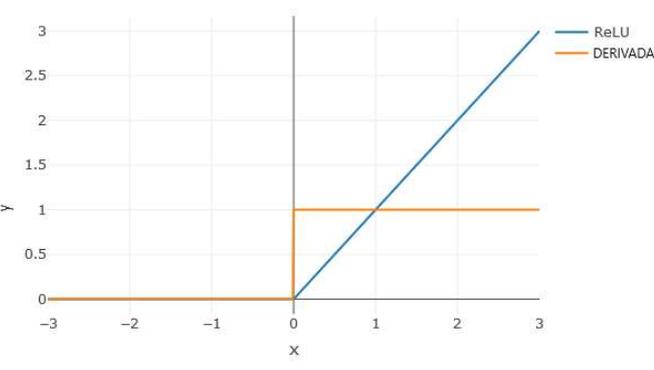
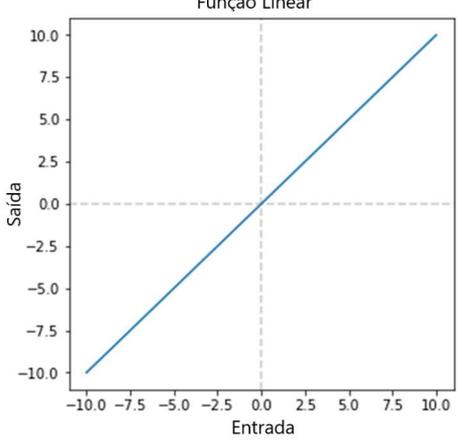
$$\hat{y} = a(z) = a(w^T X + b) \quad (3.3)$$

Inicialmente, tem-se a propagação para a frente (*forward propagation*), que define a saída da rede para uma determinada entrada. Nessa fase, um vetor de entrada é aplicado aos neurônios da rede, e seu efeito se propaga através das camadas até que o resultado seja gerado na camada de saída. Essa saída é comparada à saída desejada, e um erro é calculado para cada nó de saída. Em seguida, temos a propagação para trás (*backward propagation*), onde a saída desejada e a saída fornecida pela rede são utilizadas para atualizar os pesos da rede. Os erros calculados são transmitidos em uma direção contrária, da camada de saída para os nós das camadas intermediárias (GEORGIU; KOUTSOUGERAS, 1992; HECHT-NIELSEN, 1992).

Os pesos sinápticos são ajustados, baseados nos erros calculados anteriormente. Isso é feito para que a resposta real da rede seja mais perto da resposta desejada. Este processo deve ser feito até que se atinja um erro médio desejado. No *backward propagation* (*backpropagation*) são utilizadas as derivadas das funções de ativação. Isso resulta em dois grandes problemas com o treinamento das redes neurais. O primeiro é a diminuição dos gradientes, que é um fenômeno causado por gradientes muito pequenos durante a *backpropagation*. Quanto mais profunda a rede, menor a chance desses gradientes chegarem às primeiras camadas para atualizar seus pesos durante o treinamento. O segundo é a explosão dos gradientes que pode determinar gradientes de pesos muito grandes e, portanto, causam *NaN erros* (erros não numéricos). A compreensão das funções de ativação e a escolha de uma arquitetura de rede apropriada podem ajudar a minimizar esses dois problemas. Outras abordagens que podem ser utilizadas são: normalização adequada, regularização de peso, recorte de gradiente e, claro, mudança na arquitetura do modelo.

A Tabela 3.4 apresenta uma lista de funções de ativação utilizadas, focando na compreensão visual da função e na sua derivada para a utilização na *backpropagation*.

Tabela 3.4: Representação gráfica das funções de ativação.

Função	Representação gráfica das função de ativação	Função de ativação e função derivada	
Softplus		$f(x) = \ln(1 + e^x)$	(3.4)
		$\frac{d}{dx} f(x) = \frac{1}{1 + e^x}$	(3.5)
ReLU		$f(x) \begin{cases} x \rightarrow \text{se } x \geq 0 \\ 0 \rightarrow \text{se } x \leq 0 \end{cases}$	(3.6)
		$\frac{d}{dx} f(x) = \begin{cases} 1 \rightarrow \text{se } x \geq 0 \\ 0 \rightarrow \text{se } x \leq 0 \end{cases}$	(3.7)
Linear		$f(x) = x$	(3.8)

Estudos anteriores sugerem que, em modelos de regressão, a função linear é usualmente utilizada na camada de saída, enquanto a função retificada linear (ReLU) apresenta melhores resultados nas outras camadas (CLEVERT; UNTERTHINER; HOCHREITER, 2016; KLAMBAUER *et al.*, 2017).

A taxa de aprendizagem é um hiperparâmetro crucial na configuração de uma rede neural. Essa taxa controla o quanto o modelo muda em resposta ao erro estimado a cada atualização dos pesos. Escolher a taxa de aprendizagem é desafiador, pois um valor muito pequeno pode resultar em um longo processo de treinamento, enquanto um valor muito grande pode resultar na aprendizagem de um conjunto pouco ideal de pesos ou um processo de treinamento instável. Portanto, é fundamental investigar os efeitos da taxa de aprendizagem no desempenho do modelo e construir intuição sobre a dinâmica da taxa de aprendizagem no comportamento do modelo (KOVÁCS, 2002).

Redes neurais de aprendizagem são treinadas usando o algoritmo de otimização de descida de gradiente estocástico. A descida do gradiente estocástico é um algoritmo de otimização que estima o erro do gradiente para o estado atual do modelo, utilizando o conjunto de dados de treinamento. Para isso, atualiza-se os pesos do modelo, sendo utilizado o *backpropagation* como algoritmo de propagação de erros. Com isso, durante o treinamento, à medida que os pesos são atualizados, é utilizada uma taxa de aprendizagem. Especificamente, a taxa de aprendizagem é um hiperparâmetro configurável usado no treinamento de redes neurais que tem um pequeno valor positivo, muitas vezes na faixa entre 0,0 e 1,0 (BISHOP, 1995).

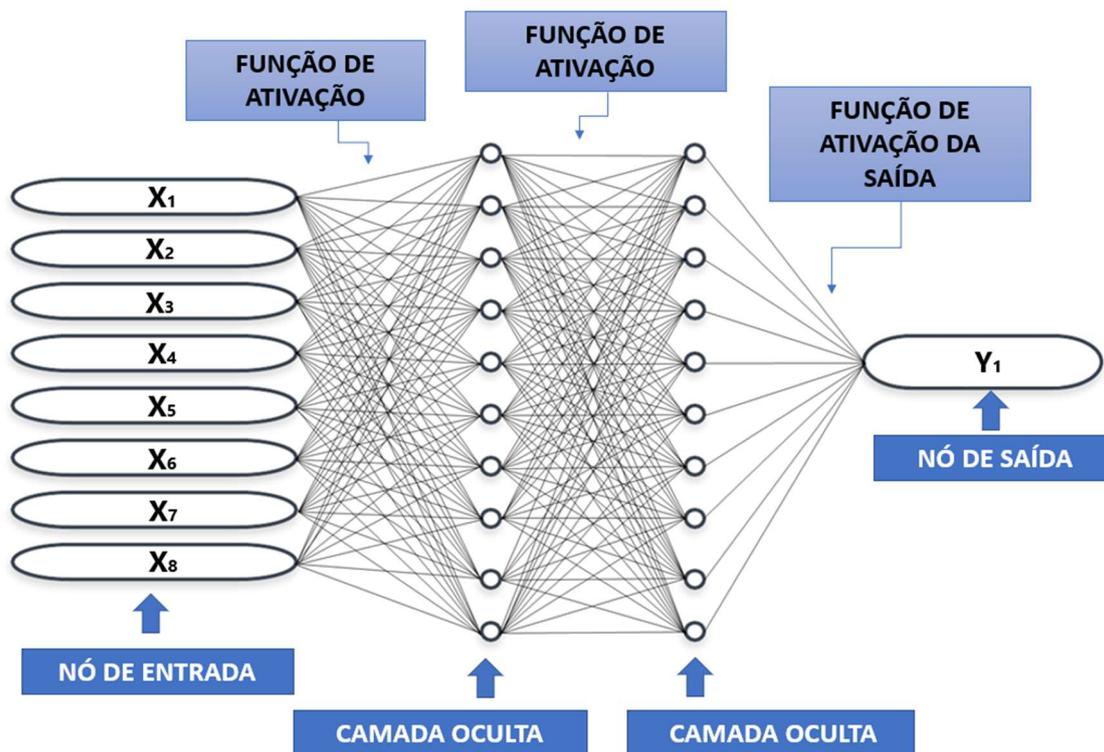
A taxa de aprendizagem controla a velocidade de adaptação do modelo ao problema. Menores taxas de aprendizagem exigem mais épocas de treinamento devido às pequenas alterações nos pesos a cada atualização. Taxas de aprendizagem maiores resultam em mudanças mais rápidas e requerem menos épocas de treinamento.

Os principais algoritmos de otimização de descida de gradiente estocástico são:

- *Stochastic Gradient Descent* (SGD): implementa o otimizador de descida de gradiente estocástico com uma taxa de aprendizagem.
- *Adaptive Learning Rate Gradient Descent*: algoritmos de gradiente estocástico que suportam taxas de aprendizagem adaptativas. Dois métodos de taxa de aprendizagem adaptativa notáveis são o otimizador Adam e o otimizador Nadam (DAHL; SAINATH; HINTON, 2013; DOZAT, 2016).

A Figura 3.7 representa uma rede neural de regressão com duas camadas intermediárias. A imagem apresenta a localização das funções de ativação na arquitetura de rede e a posição dos nós da primeira camada, camada intermediária e camada de saída.

Figura 3.7: Representação esquemática de uma rede neural.



A Tabela 3.5 apresenta as vantagens e desvantagens na utilização das redes neurais artificiais como método de inteligência computacional.

Tabela 3.5: Vantagens e desvantagens das redes neurais artificiais.

Vantagens	Desvantagens
<ul style="list-style-type: none"> <li>• Capacidade de lidar com grandes volumes de dados: as RNA são capazes de lidar com grandes volumes de dados e, assim, podem ser utilizadas em problemas complexos que envolvem grandes quantidades de dados.</li> <li>• Aprendizado contínuo: as RNA podem aprender continuamente a partir de novos dados e, assim, melhorar a sua precisão ao longo do tempo.</li> <li>• Flexibilidade: as RNA são flexíveis e podem ser usadas em vários tipos de problemas, como classificação, regressão, reconhecimento de fala e imagem, entre outros.</li> <li>• Robustez: as RNA podem lidar com dados incompletos, ruidosos e inconsistentes, o que as torna robustas em relação a outros algoritmos de aprendizado de máquina.</li> </ul>	<ul style="list-style-type: none"> <li>• Capacidade de lidar com grandes volumes de dados: as RNA são capazes de lidar com grandes volumes de dados e, assim, podem ser utilizadas em problemas complexos que envolvem grandes quantidades de dados.</li> <li>• Aprendizado contínuo: as RNA podem aprender continuamente a partir de novos dados e, assim, melhorar a sua precisão ao longo do tempo.</li> <li>• Flexibilidade: as RNA são flexíveis e podem ser usadas em vários tipos de problemas, como classificação, regressão, reconhecimento de fala e imagem, entre outros.</li> <li>• Robustez: as RNA podem lidar com dados incompletos, ruidosos e inconsistentes, o que as torna robustas em relação a outros algoritmos de aprendizado de máquina.</li> </ul>

Dessa forma, as redes neurais possuem grande potencial, tendo em vista a considerável melhora tecnológica desenvolvida nos últimos anos.

### 3.5. REGRESSOR GRADIENTE *BOOSTING*

A máquina de aprendizagem gradiente regressor *boosting* (GBR), originalmente proposta por Friedman (1999), é uma técnica de aprendizagem de máquinas utilizada com frequência para resolver problemas de regressão e de classificação. O modelo produz uma previsão utilizando modelos mais fracos, geralmente árvores de decisão, para construir modelos fortes. O funcionamento do algoritmo consiste na construção de um modelo em etapas, como em outros

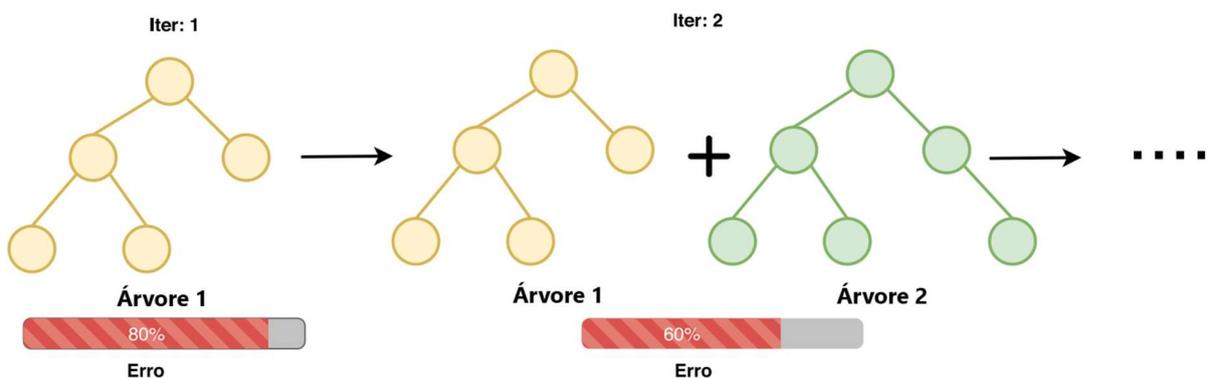
métodos de *boosting*, generalizando e permitindo a otimização de uma função de perda diferenciável arbitrária.

A ideia de gradiente *boosting* surgiu da observação de Breiman (1997) de que o *boosting* pode ser interpretado como um algoritmo de otimização em uma função de custo adequada. Pesquisas subsequentes introduziram a visão de algoritmos de *boosting* como algoritmos iterativos de descida de gradiente funcional, ou seja, algoritmos que otimizam uma função de custo em um espaço de funções, escolhendo iterativamente uma função (hipótese fraca) na direção oposta do gradiente. Essa perspectiva dos algoritmos de *boosting* em termos de gradientes funcionais levou ao desenvolvimento de algoritmos de *boosting* em várias áreas de aprendizado de máquina e estatística, além de regressão e classificação.

O GBR pode ser descrito como um modelo de aprendizado de máquina que utiliza uma sequência de aprendizes fracos para criar um aprendiz forte e arbitrariamente preciso. Um aprendiz fraco é definido como aquele cujo desempenho é, no mínimo, melhor do que um palpite aleatório. No modelo, novos aprendizes fracos são adicionados com o objetivo de minimizar o erro geral, também conhecido como perda do modelo (NGUYEN, H. *et al.*, 2021).

Os GBR utilizam árvores de regressão como aprendizes fracos, e algoritmos de aprendizagem baseados em gradientes são usados para treinar GBR, visando minimizar a perda ao adicionar aprendizes fracos. Especificamente, na primeira iteração, o algoritmo aprende com o primeiro aprendiz fraco (a primeira árvore) a reduzir o erro geral de treinamento. Na segunda iteração, o algoritmo aprende com a segunda árvore a reduzir o erro cometido pela primeira árvore, conforme ilustrado na Figura 3.8 (FRIEDMAN, J. H., 2001).

Figura 3.8: Iteração de aprendizes fracos (árvores) usando GBR para redução do erro.



Fonte: Adaptado de Nguyen, H. *et al.* (2021)

O algoritmo repete esse procedimento até construir um modelo de qualidade aceitável, ou seja, quando a perda do modelo ou erro geral atinge um nível desejado. No GBR, o sucesso da aprendizagem baseada em gradientes depende dos valores iniciais dos hiperparâmetros, incluindo o número de aprendizes fracos (árvores de regressão), quantidade máxima de árvores, perda/objetivo, função de perda e taxa de aprendizagem.

Comparando os modelos de regressor gradiente *boosting* (GBR) com as florestas aleatórias, observamos diferenças na ordem e no método de construção das árvores e na combinação dos resultados. Florestas aleatórias treinam cada árvore de maneira independente, utilizando amostras de dados aleatórios. Essa aleatoriedade torna o modelo mais robusto do que uma única árvore de decisão. O GBR, por outro lado, constrói uma árvore de cada vez, e cada árvore corrige os erros cometidos pela árvore anterior. Embora os GBR geralmente apresentem melhores resultados, seu treinamento pode ser mais demorado, pois as árvores são construídas sequencialmente.

Apesar de parecer que os GBR são superiores às florestas aleatórias, esse método é mais propenso ao sobreajuste. No entanto, existem estratégias para superar esse problema, como construir árvores cada vez mais generalizadas, utilizando uma combinação de parâmetros, como taxa de aprendizagem e profundidade da árvore. Esses parâmetros visam determinar o impacto de cada árvore no modelo final, sendo que valores menores implicam em uma menor contribuição de cada árvore.

Os parâmetros utilizados para implementação são os mesmos das florestas aleatórias, incluindo a taxa de aprendizagem, que determina a importância de cada árvore na formação do modelo final e na minimização do resíduo gerado. De forma semelhante aos outros modelos, os GBR também utilizam o *GridSearchCV* para calcular as melhores características no treinamento.

A Tabela 3.6 apresenta as vantagens e desvantagens na utilização das regressor gradiente *boosting* como método de inteligência computacional.

Tabela 3.6: Vantagens e desvantagens das regressor gradientes boosting.

Vantagens	Desvantagens
<ul style="list-style-type: none"> <li>• Alta precisão: o GBR geralmente produz previsões muito precisas, especialmente em problemas complexos e com grandes quantidades de dados.</li> <li>• Pode lidar com dados faltantes: o GBR é capaz de lidar com dados incompletos e faltantes, o que é uma grande vantagem em problemas do mundo real.</li> <li>• Pode lidar com dados não lineares: o GBR pode lidar com problemas não lineares, pois é capaz de construir árvores de decisão com base em recursos não lineares.</li> <li>• Redução de viés: o GBR pode reduzir o viés de modelos individuais, resultando em uma previsão geral mais precisa.</li> </ul>	<ul style="list-style-type: none"> <li>• Sensível a <i>overfitting</i>: o GBR é sensível a <i>overfitting</i>, o que pode levar a um modelo que se ajusta demais aos dados de treinamento e perde precisão em novos dados.</li> <li>• Demanda de recursos computacionais: o GBR pode ser um processo computacionalmente custoso, especialmente em grandes conjuntos de dados e modelos complexos.</li> <li>• Interpretação limitada: o GBR é menos interpretável do que outros modelos.</li> <li>• Ajuste de hiperparâmetros: o GBR requer ajustes cuidadosos dos hiperparâmetros para obter um modelo preciso, o que pode ser demorado e requer experiência técnica.</li> </ul>

### 3.6. MÉTODOS DE ANÁLISE DE RESULTADOS

Calcular as taxas de erro entre os valores reais e os valores previstos é importante em um estudo de regressão para determinar o sucesso do método utilizado. Neste contexto, nos modelos computacionais, são calculados o coeficiente de correlação (coeficiente de *Pearson*) e o coeficiente de determinação, conforme apresentado nas equações (3.9) e (3.10):

$$R = \frac{\sum (x - \bar{x}) \cdot (y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \cdot (y - \bar{y})^2}} \quad (3.9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y)^2}{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2} \quad (3.10)$$

Onde:

$\hat{y}_i$  é o valor de y desejado (experimental);

$y_i$  é o valor de y previsto pelo modelo computacional;

$\bar{y}$  é a média do valor desejado de y;

N é o número de amostras.

Outras métricas de erro também podem ser empregadas, como o erro absoluto médio (MAE), o erro quadrático médio e a raiz do erro quadrático médio (RMSE). Como o valor médio do erro absoluto é de fácil interpretação, ele é comumente utilizado em problemas de regressão. A raiz do erro quadrático médio indica a dispersão dos dados em torno da linha que melhor se ajusta a eles.

Dessa forma, nesse estudo, são utilizados os parâmetros apresentados nas equações (3.11) e (3.12) para a avaliação do erro obtido nos modelos, respectivamente:

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (3.11)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (3.12)$$

## 4. TRABALHOS CORRELATOS

Neste capítulo, são apresentados trabalhos em que a inteligência computacional é aplicada na resolução de problemas de engenharia, com foco especial naqueles em que os métodos computacionais inteligentes são empregados para determinar as propriedades mecânicas do concreto. A Seção 4.1 apresenta trabalhos que buscam determinar a resistência à compressão do concreto a partir de diversas bases de dados, enquanto a Seção 4.2 aborda trabalhos que visam determinar a resistência ao arrancamento de barras de aço, tanto em ensaios *pull-out* quanto em outros tipos de ensaios.

### 4.1. RESISTÊNCIA À COMPRESSÃO

Vários pesquisadores utilizaram técnicas de inteligência computacional na previsão da resistência à compressão do concreto, alcançando resultados promissores. A seguir, são apresentados estudos que empregam redes neurais artificiais (ANN), máquinas vetoriais de suporte (SVM), árvores de decisão (DTR) e florestas aleatórias (RFR). Alguns desses estudos abordam concretos convencionais, enquanto outros investigam a aplicação de diversos tipos de concretos produzidos a partir de novos componentes. Neste último caso, a implementação desses métodos é particularmente interessante para prever características inovadoras desses concretos, uma vez que não há resultados experimentais amplamente disponíveis.

Redes neurais artificiais (ANN) são utilizadas em diversos estudos, como em Hoła e Schabowicz (2005), onde foi proposto um método capaz de prever a resistência à compressão do concreto a partir de ensaios não destrutivos. Nesse estudo, a base de dados utilizada para treinar as redes foi obtida por meio de ensaios experimentais realizados com o método ultrassônico, o método esclerométrico e ensaios *pull-out*. O conjunto de dados para treinamento e teste das ANN foi criado com sete concretos, cujas resistências à compressão variaram de 24 a 105 MPa. Os parâmetros de entrada da rede neural testada incluíram velocidades longitudinais de ondas ultrassônicas, números de reflexão (tamanho do ressalto), dureza, força de arrancamento, idade do concreto e densidade aparente. Como parâmetro de saída, utilizou-se a resistência à compressão do concreto. O algoritmo de treinamento de *Levenberg-Marquardt* foi empregado e mostrou-se eficiente, conforme evidenciado pelos baixos valores de RMSE. O coeficiente de correlação obtido foi da ordem de 0,99 para os casos de treinamento e teste, enquanto os valores de desvio padrão do erro relativo foram baixos. Os resultados obtidos pela implementação e pelos ensaios destrutivos mostraram-se muito semelhantes.

Frequentemente, a implementação de redes neurais artificiais tem como objetivo parametrizar a previsão da resistência à compressão de novas misturas de concreto, evitando o uso de métodos

destrutivos. Um exemplo dessa abordagem é o estudo de Yeh (2006), que emprega redes neurais artificiais para determinar o efeito da substituição de cinzas volantes (em proporções de 0 a 50%) na resistência à compressão inicial e final do concreto. Nesse estudo, foram analisados espécimes com tempos de cura variando de 3 a 56 dias, baixa e alta resistência e relações água-cimento entre 0,30 e 0,70. A pesquisa concluiu que há uma forte correlação entre a resistência à compressão do concreto e sua composição. O valor de RMSE encontrado foi de 3,01 MPa, com um coeficiente de determinação de 0,94 para treinamento, e 4,32 MPa com um coeficiente de determinação de 0,92 para teste. Através deste estudo, verificou-se que as redes neurais podem ser usadas para testar os efeitos das variáveis e suas interações na resistência do concreto, mostrando que misturas com maior teor de cinzas volantes resultam em valores de resistência mais baixos, sendo essa redução mais acentuada em espécimes com menor tempo de cura. A metodologia aplicada confirmou a eficiência desse método computacional na simulação do comportamento da resistência à compressão do concreto.

As redes neurais artificiais também são utilizadas para comparar resultados obtidos com novos modelos computacionais, como no estudo de Nguyen *et al.* (2018). Nessa pesquisa, um modelo de rede neural profunda foi desenvolvido para prever a resistência à compressão do concreto. Um novo neurônio de alta ordem foi criado para melhorar o desempenho do modelo, e a função de custo de entropia cruzada e a função de ativação de unidade linear retificada foram empregadas para aprimorar seu desempenho. O modelo foi aplicado na previsão da resistência à compressão do concreto usando um conjunto específico de dados e os resultados foram comparados com outros métodos de aprendizado de máquina, incluindo a rede neural artificial convencional (C-ANN) e a rede neural artificial de segunda ordem (SO-ANN). Para validar ainda mais o modelo proposto, os autores apresentaram um novo conjunto de dados de laboratório e um conjunto de dados de concreto de alto desempenho. O modelo proposto obteve uma previsão melhor em comparação com outros métodos, melhorando seu desempenho ao treinar um modelo de rede neural profunda com múltiplas camadas ocultas, em contraste com C-ANN e SO-ANN. A análise de sensibilidade foi realizada para investigar os efeitos das variáveis de entrada na resistência à compressão, indicando que a resistência à compressão do concreto é afetada principalmente pela densidade, seguida pelas proporções de cimento e agregados de areia. Ao fornecer uma ferramenta de previsão confiável, o modelo proposto pode auxiliar pesquisadores e engenheiros na otimização de design de mistura de concreto.

Em um estudo comparativo realizado por Khademi *et al.* (2017), a avaliação da resistência à compressão do concreto moldado *in situ* foi investigada. O artigo analisa 173 exemplares de concreto com diferentes misturas e emprega três modelos computacionais distintos: regressão linear múltipla (RLM), rede neural artificial e sistema de inferência neuro-adaptativo (ANFIS). Os modelos foram treinados e testados no *matlab* com o objetivo de prever a resistência à compressão

do concreto aos 28 dias. Ao comparar os três modelos, os resultados indicam que as redes neurais artificiais (ANN) e o ANFIS fornecem avaliações confiáveis da resistência à compressão de diferentes misturas de concreto. Por outro lado, os modelos de regressão linear mostraram-se inviáveis nesta área devido à relação não linear entre os parâmetros das misturas de concreto.

Redes neurais são especialmente importantes na previsão de parâmetros do concreto quando se utiliza novos componentes. Alguns estudos são descritos a seguir:

No artigo de Belalia Douma *et al.* (2017), a viabilidade do uso de redes neurais artificiais para prever as propriedades do concreto autoadensável contendo cinzas volantes em substituição ao cimento foi investigada. O objetivo era construir um modelo utilizando bancos de dados experimentais da literatura e empregá-lo em uma rede de treinamento e teste. Os dados usados no modelo ANN foram organizados em seis parâmetros de entrada: porcentagem de substituição de cinzas volantes, razão água/cimento, agregados finos, agregados grossos e superplastificante. Quatro parâmetros de saída foram previstos: abatimento, teste de *l-box*, teste de *v-funnel* e resistência à compressão aos 28 dias. Para demonstrar a utilidade do modelo proposto e aprimorar seu desempenho, os autores compararam as previsões do modelo ANN com resultados experimentais de outros pesquisadores, encontrando uma boa correspondência. Esse estudo evidencia o potencial das redes neurais artificiais como ferramentas para prever as propriedades do concreto contendo cinzas volantes.

A pesquisa de Alshihri *et al.* (2009) investigou o uso de redes neurais artificiais (ANN) para prever a resistência à compressão do concreto leve com idades de cura de 3, 7, 14 e 28 dias. Neste estudo, foram utilizados dois modelos: a rede *feedforward backpropagation* e o algoritmo de correlação em cascata, que ajusta sua própria arquitetura durante o treinamento. O teor de cimento utilizado foi de 450, 400 e 350 kg/m<sup>3</sup>, e os espécimes de concreto foram cubos de 150x150x150mm. Várias variáveis de entrada foram utilizadas para determinar a resistência à compressão do concreto agregado leve, como areia, relação água/cimento, agregado fino leve, agregado graúdo leve, sílica ativa na mistura e adicionada ao cimento, superplastificante, período de cura e resistência à compressão do concreto. Para as ANN, os coeficientes de correlação obtidos foram 0,97 e 0,98 para os dados de treinamento e teste, respectivamente. No método de correlação em cascata, os coeficientes de correlação foram de 0,97 e 0,92, respectivamente, para os dados de treinamento e teste. O estudo concluiu que a correlação em cascata apresentou resultados mais precisos e aprendizado mais rápido em comparação com o método ANN *feedforward backpropagation*.

Eskandari e Tayyebinia (2016) também empregaram redes neurais artificiais em uma pesquisa dividida em duas fases. A primeira fase incluiu o desenvolvimento de uma rede neural artificial para prever a resistência à compressão de materiais à base de ferro-cimento. Os parâmetros de entrada eram teor de cimento, fator água-cimento, pasta de água, água para cimento e proporções de areia.

Além dos resultados experimentais das ANN avaliados em 12 misturas, foram realizados ensaios para determinar a resistência à compressão do concreto e avaliar a resistência à compressão dos cubos de argamassa aos 28 dias. Isso foi feito usando diferentes compostos de argamassa, mistura com cimento/areia na relação 2:3 e variando a relação água/binder entre 0,30 e 0,60, utilizando areia graduada e dois tipos de resistência à compressão de cimento *portland* comum. Os resultados do treinamento e testes das ANN e a comparação dos resultados experimentais mostraram que as ANN têm forte potencial para prever a resistência à compressão das argamassas se o componente de ferro-cimento presente nas camadas de entrada da rede tiver as mesmas propriedades dos materiais utilizados.

Kaplan *et al.* (2019) apresentaram a utilização de misturas minerais e resíduos industriais como substitutos do cimento *portland*, reconhecidos por sua eficiência energética e redução das emissões de CO<sub>2</sub>. Os autores afirmam que o uso de materiais como cinzas volantes, escória de alto-forno ou pó de calcário na produção de concreto torna o processo sustentável. O estudo investigou diversas propriedades do concreto, como resistência à compressão, velocidade do pulso ultrassônico, módulo de elasticidade dinâmica, absorção de água e profundidade de penetração em diferentes condições de cura. Foram produzidas amostras de concreto com cimento *portland*, cimento de escória e cimento calcário, e relações água-cimento entre 0,63 e 0,70. As amostras de concreto foram curadas em três condições: úmidas, ao ar livre e em saco plástico selado. Utilizando ANN, o estudo estimou a resistência à compressão com alta precisão. Os valores de R<sup>2</sup> encontrados para treinamento, validação e testes de conjuntos de dados foram de 0,99, 0,99 e 0,98, respectivamente, indicando a alta precisão do modelo desenvolvido e uma boa correlação entre os valores de resistência à compressão previstos e os experimentais.

Chithra *et al.* (2016) compararam modelos de análise de regressão múltipla (RLM) e redes neurais artificiais (ANN) para prever a resistência à compressão do concreto de alto desempenho com nano-sílica e escória de cobre substituindo parcialmente o cimento e os agregados finos, respectivamente. Os dados utilizados foram obtidos a partir de experimentos de laboratório. A resistência à compressão do concreto foi determinada experimentalmente com diferentes porcentagens de nano-sílica e escória de cobre, em idades variadas de 1, 3, 7, 28, 56 e 90 dias, totalizando 264 experimentos. As observações foram agrupadas em três conjuntos com base nas misturas minerais incorporadas. Os constituintes da mistura serviram como parâmetros de entrada para prever a resistência à compressão. Os três conjuntos de dados foram modelados usando RLM e ANN, e os resultados foram avaliados e comparados. Os modelos ANN mostraram maior precisão e correlação em comparação com os modelos RLM.

Gupta (2013) aplicou redes neurais artificiais para determinar a resistência à compressão do concreto com substituição parcial de cimento por nano-sílica. O conjunto de dados dessa pesquisa

foi coletado de várias fontes, totalizando 32 conjuntos de dados. O desempenho do modelo foi avaliado pelo coeficiente de correlação (0,87), erro médio absoluto (6,01) e raiz do erro quadrático médio (8,18), que mediram a diferença entre os resultados previstos e os valores experimentais. Com base nesses resultados, o autor concluiu que é possível estimar a resistência à compressão do concreto sem a necessidade de ensaios experimentais, em um curto período de tempo e com taxas de erro aceitáveis.

O estudo realizado por Akpınar e Khashman (2017a) emprega modelos de redes neurais artificiais (ANN) para abordar e resolver problemas não lineares. O modelo ANN foi projetado, implementado e testado com o objetivo de classificar o grau de resistência à compressão de diferentes misturas de concreto, categorizadas como baixa, normal ou alta resistência. Os autores concluíram que a resistência à compressão do concreto depende de diversos fatores não lineares e, geralmente, é determinada usando métodos convencionais de engenharia civil, que envolvem a destruição de amostras de concreto. O objetivo do estudo era classificar a resistência à compressão do concreto sem a necessidade de destruir as amostras. Os resultados obtidos demonstraram alta eficiência na classificação correta da resistência à compressão.

Muthupriya *et al.* (2011) também utilizaram redes neurais artificiais para prever a resistência à compressão do concreto e sua durabilidade. O estudo utilizou uma base de dados contendo corpos de prova de concreto confeccionados com metacaulin, sílica ativa e cinza volante, nas idades de 3, 7, 28, 56 e 90 dias. Os conjuntos de treinamento e de teste da primeira rede neural (ANN-I) testada foram obtidos por meio de resultados experimentais de 140 espécimes produzidos com 7 proporções de mistura diferentes. O tipo da rede utilizada foi a *feedforward*, projetada com oito parâmetros de entrada, dentre eles: idade da amostra, quantidade de cimento, quantidade de metacaulin, cinza volante, água, areia, agregado e superplastificante. Em uma segunda rede (ANN-II), outro conjunto de espécimes foi utilizado. Esse conjunto apresentava sílica ativa em vez de metacaulin em sua mistura. No treinamento da primeira rede, os valores estatísticos de RMSE, R<sup>2</sup> e MAPE encontrados foram 2,14, 99,12% e 1,85%, respectivamente, e na etapa de teste, os valores foram 2,25, 99,01% e 0,43%, respectivamente. Já para o segundo modelo, os valores estatísticos de RMSE, R<sup>2</sup> e MAPE do treinamento encontrados foram 4,40, 99,65% e 3,71%, respectivamente, e na etapa de teste 4,74, 94,99% e 3,39%, respectivamente. O estudo conclui que as redes neurais artificiais multicamadas *feedforward* são capazes de prever as características mecânicas do concreto e a sua durabilidade.

O estudo de Reddy (2018) buscou adaptar redes neurais artificiais para a previsão das propriedades de resistência das SIFCON, um tipo especial de material composto reforçado contendo 20% de fibra de aço com diferentes minerais na mistura. As investigações contemplaram 84 misturas de SIFCON, sendo os espécimes testados após 28 dias de cura. Os dados experimentais obtidos foram

treinados usando redes neurais, consistindo em 4 parâmetros de entrada: percentuais de fibra de aço na mistura, relação de aspecto da fibra, tipo de mistura e percentual de mistura. Os parâmetros de saída correspondentes são a resistência à compressão, resistência à tração e resistência à flexão. Os valores previstos obtidos usando ANN mostram uma boa correlação com os dados experimentais. O desempenho da arquitetura com 4 nós na primeira camada, 14 nós na segunda e 3 nós na camada de saída foi o melhor resultado nas arquiteturas estudadas. O autor conclui que as ANN são uma ferramenta altamente poderosa e adequada para avaliar as características de resistência da SIFCON.

Behnood e Golafshani (2018) empregaram redes neurais artificiais (ANN) para estimar a resistência à compressão do concreto com adição de fumaça de sílica, substituindo parcialmente o cimento *portland*. Os pesquisadores destacaram que uma das principais limitações das ANN usadas na previsão de propriedades do concreto é sua elevada complexidade. Dessa forma, o estudo visou atingir dois objetivos: aprimorar a precisão e diminuir a complexidade dos modelos ANN. Para isso, foi aplicada uma otimização multiobjetivo conhecida como método de otimização de lobos cinzentos multiobjetivo (MOGWO) a fim de encontrar um modelo ANN simplificado com erros toleráveis. Como resultado desse processo de otimização, um conjunto de 31 modelos ANN otimizados foi obtido. O modelo final escolhido consistiu em uma ANN com apenas uma camada oculta de cinco neurônios, alcançando um coeficiente de correlação ( $R^2$ ) de 0,96 para todos os dados. Adicionalmente, os autores realizaram uma análise de sensibilidade para avaliar a habilidade do modelo ANN em prever a tendência da resistência à compressão do concreto com fumaça de sílica, considerando as variações nas variáveis que afetam a resistência à compressão.

De acordo com Sultana *et al.* (2020), diversas fibras podem ser utilizadas como material de reforço no concreto, sendo a fibra de juta uma opção interessante devido ao seu baixo custo e disponibilidade em países tropicais. O objetivo deste estudo foi desenvolver modelos empíricos não lineares para prever as propriedades mecânicas (resistência à tração e à compressão) do concreto reforçado com fibra de juta, utilizando diferentes abordagens, como RSM (*response surface methodology*), redes neurais e máquinas vetoriais de suporte. Foram realizados 13 conjuntos de experimentos, utilizando dois corpos de prova cúbicos de 150x150x150 mm e dois corpos de prova cilíndricos de 100 mm de diâmetro e 200 mm de comprimento para cada conjunto de experimentos. As amostras cúbicas foram utilizadas para determinar a resistência à compressão e as amostras cilíndricas para a resistência à tração, após 28 dias de cura. Os modelos RSM, ANN e SVM apresentaram valores de  $R^2$  para a resistência à compressão de 0,98, 0,98 e 0,99, respectivamente, enquanto para a resistência à tração, foram obtidos valores de 0,91, 0,98 e 0,99, respectivamente. Os resultados mostraram que o modelo SVM apresentou melhor desempenho em relação aos modelos ANN e RSM, com respeito às métricas de desempenho utilizadas para prever a resistência à compressão e à tração.

O artigo de Duan *et al.* (2013) demonstrou a aplicabilidade das redes neurais artificiais na previsão da resistência à compressão do concreto com agregado reciclado. Para isso, o modelo ANN foi construído, treinado e testado com 146 conjuntos de dados obtidos em 16 fontes literárias distintas. O modelo ANN utilizou 14 parâmetros de entrada, incluindo quantidade de água, cimento, areia, agregado grosso natural, agregado grosso reciclado, razão água-cimento, módulo de espessura de areia, absorção de água dos agregados, densidade saturada seca à superfície, tamanho máximo e teor de impureza do agregado grosseiro reciclado e razão de substituição do agregado grosseiro reciclado em volume. Utilizando o software *matlab*, o modelo ANN foi capaz de prever a resistência à compressão do concreto com agregado reciclado. Os resultados apresentados indicam que as redes neurais artificiais têm grande potencial para serem utilizadas como ferramentas na previsão da resistência à compressão do concreto com agregado reciclado, independentemente do tipo e fonte do agregado reciclado utilizado.

Deshpande *et al.* (2014) utilizaram redes neurais artificiais em um estudo para prever a resistência à compressão do concreto com agregado reciclado após vinte e oito dias. Além disso, duas outras técnicas foram propostas: árvores de regressão (DTR) e regressão não linear. Os dados utilizados foram obtidos de experimentos realizados pelos autores e da literatura publicada, totalizando 257 conjuntos de dados. As entradas consideradas no estudo foram proporções em metros cúbicos de cimento, agregado fino natural, agregados grosseiros naturais, agregados reciclados e água. As redes neurais artificiais obtiveram um coeficiente de correlação de 0,93, enquanto DTR e regressão não linear atingiram 0,83. Esses resultados indicam que as redes neurais artificiais tiveram melhor desempenho do que as outras técnicas avaliadas.

Naderpour *et al.* (2018) investigaram a utilização de diferentes resíduos sólidos da construção civil na produção de concreto com agregado reciclado (RAC). O objetivo do estudo foi desenvolver um modelo de rede neural artificial (ANN) para prever a resistência à compressão do RAC. Os dados de treinamento e teste foram obtidos a partir de 139 conjuntos de dados provenientes de 14 fontes literárias distintas. O modelo ANN desenvolvido utilizou seis parâmetros de entrada, incluindo relação água-cimento, absorção de água, agregado fino, agregado grosso natural, agregado grosso reciclado, relação total de materiais e água. O modelo ANN foi implementado no software *matlab* e utilizado para prever a resistência à compressão do RAC com base nos parâmetros de entrada mencionados. Os resultados mostraram que o modelo ANN é eficiente e pode ser utilizado como uma ferramenta para prever a resistência à compressão do RAC.

Deng *et al.* (2018) abordaram as dificuldades atuais na previsão da resistência à compressão do concreto com agregado reciclado, propondo um modelo de previsão baseado na teoria do aprendizado profundo usando redes neurais artificiais. Para isso, as características da relação água-cimento, taxa de substituição de agregado grosso reciclado, taxa de substituição agregado fino

reciclado e razão de substituição de cinzas volantes, assim como suas combinações, foram aprendidas por meio de redes neurais convolucionais. O modelo de previsão foi desenvolvido utilizando a função de ativação *softmax* e foi testado em 74 conjuntos de dados de blocos de concreto com diferentes proporções de mistura. Os resultados mostraram que o modelo ANN proposto apresentou várias vantagens, incluindo maior precisão, eficiência e capacidade de generalização em comparação com o modelo ANN tradicional. Esse modelo poderia ser considerado um novo método para calcular a resistência à compressão do concreto com agregado reciclado.

Hammoudi *et al.* (2019) realizaram um estudo para modelar e prever a resistência à compressão do concreto com agregado grosso reciclado em 7, 28 e 56 dias. A metodologia de superfície de resposta (RSM) e redes neurais artificiais (ANN) foram utilizadas em conjunto para modelar os três processos. A faixa de teores de cimento foi de 300 a 400 kg/m<sup>3</sup>, o percentual de agregado grosso reciclado (RCA) variou de 0 a 100% e o *slump* variou entre 5 a 12 ( $\pm 1$ ) cm. Os resultados mostraram que a resistência à compressão do concreto reciclado em 7, 28 e 56 dias é fortemente influenciada pelo teor de cimento, RCA e queda do *slump*. Observou-se que a resistência à compressão diminuiu com o aumento da RCA de 0 a 100% em média 22,62 para 18,56, 34,91 para 28,70 e 37,77 para 32,26 em 7, 28 e 56 dias, respectivamente. Os resultados foram apresentados em termos estatísticos, indicando que tanto a abordagem ANN quanto a RSM são ferramentas poderosas para prever a resistência à compressão. Além disso, os modelos ANN e RSM apresentaram uma correlação satisfatória com os dados experimentais. No entanto, os autores destacaram que o modelo ANN apresentou maior precisão em relação à RSM.

Shirgir *et al.* (2015) conduziram um estudo para prever a resistência à compressão e a permeabilidade do concreto permeável utilizando redes neurais. Os dados foram obtidos a partir de ensaios laboratoriais e a rede neural proposta buscou estabelecer uma relação funcional confiável entre as variáveis independentes de entrada que representam a variabilidade da permeabilidade e da resistência à compressão do concreto poroso. Os resultados do modelo de *backpropagation* demonstraram que o ajuste geral e a replicação dos dados foram satisfatórios, com valores de R<sup>2</sup> para o modelo final variando entre 0,88 e 0,92 para os valores previstos *versus* os valores experimentais. Os autores observaram que os valores de R<sup>2</sup> foram mais elevados para a permeabilidade em comparação com a resistência à compressão do concreto permeável. Além disso, os valores de desempenho foram melhores para o conjunto de dados de treinamento em comparação com o conjunto de teste. Esses resultados indicam que o modelo desenvolvido pode ser usado para prever a resistência à compressão e a permeabilidade do concreto permeável quando não há dados laboratoriais disponíveis.

Khademi *et al.* (2016) empregaram redes neurais para estudar a resistência à compressão do concreto com agregado reciclado. No estudo, foram utilizados três modelos computacionais distintos para prever a resistência à compressão do concreto agregado reciclado em 28 dias: redes neurais artificiais, sistemas adaptativos de inferência (ANFIS) e regressão linear múltipla (RLM). Foram empregados 14 parâmetros de entrada, incluindo parâmetros dimensionais e não-dimensionais. Os resultados indicaram que as redes neurais artificiais e os sistemas adaptativos de inferência apresentaram melhor desempenho para estimar a resistência à compressão do concreto com agregado reciclado em 28 dias. Em outras palavras, comparando a etapa de teste dos três modelos, o modelo RLM foi considerado mais adequado para prever a mistura de concreto a ser utilizada. Além disso, foi explorado o desempenho dos modelos orientados por dados com e sem os parâmetros não-dimensionais. Os autores observaram que os modelos orientados por dados apresentaram melhor precisão quando os parâmetros não-dimensionais foram incluídos como parâmetros de entrada adicionais.

Gandomi e Alavi (2011) propuseram o uso de técnicas de inteligência computacional na modelagem do comportamento do concreto, incluindo o uso de redes neurais artificiais em conjunto com algoritmos de programação genética. O estudo utilizou o conjunto de dados de Yeh (2006), que contém 1130 resultados de ensaios de resistência à compressão obtidos a partir de estudos anteriores. Foram empregados ramos da programação genética, como *tree-based genetic programming* (TGP) e *linear genetic programming* (LGP), bem como duas variantes de redes neurais artificiais, *multilayer perceptron* (MLP) e *radial basis function* (RBF). As simulações foram aplicadas em casos convencionais de obtenção das propriedades do concreto: resistência à compressão e módulo de elasticidade. Neste estudo, a resistência à compressão do concreto foi obtida utilizando as propriedades da mistura, enquanto o módulo de elasticidade foi obtido usando a resistência à compressão. Os resultados apresentaram um coeficiente de correlação maior que 0,80, o que indica uma forte correlação entre os dados. O erro médio absoluto (MAE) encontrado foi de cerca de 2. Os modelos propostos foram eficazes na previsão da resistência à compressão e do módulo de elasticidade. Para validar os modelos, foram utilizados dados experimentais além dos dados de treinamento. A LGP forneceu previsões mais precisas do que a TGP. No entanto, as redes neurais artificiais testadas apresentaram os melhores resultados.

Neeraja e Swaroop (2017) utilizaram redes neurais artificiais e algoritmos genéticos (AG) para prever a resistência à compressão do concreto. Os dados foram coletados por meio de experimentos em laboratório sob condições controladas, em períodos de cura de 28, 56 e 91 dias. Os modelos desenvolvidos foram testados com dados de concretos fabricados *in situ* encontrados na literatura. Os resultados foram comparados e concluiu-se que o modelo ANN, com a função de treinamento *Levenberg-Marquardt*, apresentou a melhor precisão na previsão da resistência à compressão do concreto em questão, quando comparado aos AG.

O estudo de Nikoo *et al.* (2015) propôs a utilização de redes neurais artificiais evolutivas (EANNs), uma combinação de redes neurais artificiais e algoritmos genéticos (AG), para determinar a resistência à compressão do concreto. O objetivo foi construir um modelo a partir de 173 padrões de dados experimentais de peças cilíndricas de concreto com características diferentes. Foram considerados como dados de entrada a relação água-cimento, tamanho máximo de areia, quantidade de cascalho, cimento, areia 3/4, areia 3/8 e coeficiente de parâmetros de areia. Utilizando o modelo ANN, a resistência à compressão do concreto foi calculada. Para otimizar a precisão, foram utilizados os AG para determinar o número de camadas, os nós de cada camada e os pesos aplicados em cada camada dos modelos ANN. Para avaliar a precisão, o modelo ANN otimizado foi comparado com o modelo de regressão linear múltipla (RLM). Os resultados da simulação mostraram que o modelo EANNs possui mais flexibilidade, capacidade e precisão na previsão da resistência à compressão do concreto. Os valores obtidos do coeficiente de correlação para a resistência à compressão nas etapas de treinamento, teste e validação foram iguais a 0,91, 0,93 e 0,90, respectivamente. A propriedade de generalização de EANNs também foi usada na previsão dos valores de resistência à compressão com base em dados coletados não utilizados. Em suma, o estudo demonstrou que a combinação de EANNs é uma ferramenta eficaz para prever a resistência à compressão do concreto e pode ser aplicada em diferentes condições experimentais.

Chopra *et al.* (2016) desenvolveram modelos de previsão da resistência à compressão do concreto utilizando redes neurais artificiais e algoritmos genéticos (AG). Os dados para análise e desenvolvimento dos modelos foram coletados em experimentos controlados, com períodos de cura de 28, 56 e 91 dias. Os modelos desenvolvidos foram testados em dados retirados da literatura e os resultados foram comparados. O modelo de redes neurais (ANN), utilizando a função de treinamento *Levenberg-Marquardt*, mostrou-se a ferramenta mais eficiente para previsão da resistência à compressão do concreto, apresentando um  $R^2$  médio de 0,98, enquanto o modelo AG obteve um  $R^2$  de 0,93.

As máquinas vetoriais de suporte (SVM) são frequentemente usadas em conjunto com redes neurais artificiais (ANN) para prever a resistência à compressão do concreto. Um estudo de Chou *et al.* (2011) comparou cinco métodos computacionais diferentes para otimizar a previsão da resistência à compressão do concreto de alto desempenho: redes neurais artificiais, máquinas vetoriais de suporte, regressão múltipla, árvore de regressão múltipla aditiva (MART) e árvore de regressão *bagging*. O objetivo do estudo foi comparar os métodos computacionais. A resistência à compressão do concreto de alto desempenho é influenciada por componentes como cimento, cinza volante, escória de alto forno, água, superplastificante, idade e agregado grosso e fino. O banco de dados utilizado para o estudo foi obtido em 17 bancos de testes de resistência à compressão do concreto. Os métodos foram avaliados com base em métricas como o coeficiente de determinação

( $R^2$ ). O estudo concluiu que o modelo MART e a rede neural apresentaram melhores resultados do que os outros métodos computacionais avaliados.

O estudo de Yu *et al.* (2018) apresentou um modelo preditivo utilizando as máquinas vetoriais de suporte e as redes neurais artificiais para prever a resistência à compressão do concreto de alto desempenho. O conjunto de dados foi coletado da literatura e incluiu parâmetros como teor de água, cimento, escória de alto forno, cinzas volantes, superplastificante, agregados graúdos e finos e idade de cura, enquanto a resistência à compressão do concreto foi o parâmetro de saída. As métricas de desempenho para o modelo proposto foram RMSE e  $R^2$  de 1,05 e 0,95, respectivamente. Comparativamente, a ANN obteve um RMSE de 1,45 e um  $R^2$  de 0,96. Esses resultados mostram que o método proposto pode ser considerado eficaz na predição de propriedades mecânicas de concretos de alto desempenho em aplicações de infraestrutura.

O estudo de Tanyildizi (2018) buscou prever a resistência à compressão e a resistência à flexão do concreto leve reforçado com fibra de carbono e sílica ativa exposto a alta temperatura, utilizando máquinas vetoriais de suporte e redes neurais. A sílica ativa foi usada para substituir parte do cimento, e as fibras de carbono foram utilizadas em diferentes proporções. Os corpos de prova foram aquecidos e submetidos a testes de resistência. O modelo incluiu as seguintes variáveis de entrada: quantidade de cimento, quantidade de sílica ativa, quantidade de fibras de carbono, quantidade de agregados e temperatura. As resistências à compressão e flexão do concreto leve foram usadas como variáveis de saída. Os modelos SVM previram as resistências à compressão e flexão com  $R^2$  de 0,97 e 0,92, respectivamente. O modelo de previsão ANN mostrou coeficientes de correlação de 0,99 e 0,97 entre os resultados medidos e previstos para as resistências à compressão e flexão, respectivamente. A comparação dos resultados dos modelos com os resultados experimentais indicou que os modelos de rede neural artificial obtiveram os melhores resultados.

O estudo de Shariati *et al.* (2020) apresenta a utilização de redes neurais artificiais em conjunto com máquinas vetoriais de suporte para a comparação de novas implementações de técnicas de inteligência computacional. O objetivo do estudo é prever a resistência à compressão do concreto, utilizando uma combinação de máquina de aprendizado extremo e um algoritmo metaheurístico (ELM-GWO). Além disso, outros métodos preditivos foram utilizados para a comparação de eficiência, tais como rede neural, sistema de inferência neuro-difuso adaptativo (ANFIS), máquina de aprendizado extremo (ELM), regressão de vetor de suporte com *kernel* de função de base radial (SVM-RBF) e outro SVM com *kernel* de função polinomial (SVM-poly). O conjunto de dados foi obtido na literatura, contendo 798 pontos de dados com o teor de cimento, água, cinza volante, escória de forno, agregado miúdo, agregado graúdo, superplastificante e idade como entradas dos modelos e a resistência à compressão do concreto como saída. Os valores do coeficiente de

correlação dos métodos foram de 0,97, 0,98, 0,98, 0,97, 0,96 e 0,99 para ANN, ANFIS, SVM-RBF, ELM e ELM-GWO, respectivamente. O RMSE dos métodos foram de 4,19, 3,68, 3,66, 4,11, 4,77 e 2,62 para ANN, ANFIS, SVM-RBF, ELM e ELM-GWO. O estudo conclui que o modelo ELM-GWO apresentou o melhor desempenho em relação aos outros métodos de predição.

No estudo de Samui (2013), foram utilizados três algoritmos de aprendizado estatístico: máquinas vetoriais de suporte, *least square support vector machine* (lssvm) e *relevance vector machine* (rvm), para determinar a resistência à compressão do concreto. Como parâmetros de entrada desses métodos, foram considerados: cinzas volantes, fumaça de sílica, material cimentício total, agregado fino, agregado grosso, teor de água, agente redutor de água e idade das amostras. O parâmetro de saída dos métodos é a resistência à compressão do concreto. Os valores do coeficiente de correlação foram de 0,97 para os dados de treinamento e de 0,97 para a parcela de teste. Os modelos SVM propostos mostraram-se ferramentas práticas para a previsão da resistência à compressão do concreto.

Abd e Abd (2017) propõem duas técnicas para determinar a resistência à compressão do concreto leve: as máquinas vetoriais de suporte e a regressão não linear multivariável. O conjunto de dados foi obtido a partir de um conjunto de 150 cubos e distintos traços de concreto, que foram testados quanto à sua densidade e resistência à compressão aos 7 e 28 dias. As variáveis utilizadas nos modelos de previsão foram provenientes do conhecimento dos elementos de proporção da mistura e da resistência à compressão de 7 dias. O melhor valor do coeficiente de correlação foi de 0,99 com um MSE de 3,27 na etapa de teste, utilizando a função de base radial como *kernel*. Neste estudo, o modelo SVM mostrou ser uma ferramenta significativa na previsão da resistência à compressão do concreto leve.

No estudo de Yaseen *et al.* (2018), o modelo de aprendizado de máquina conhecido como aprendizado extremo (ELM) foi utilizado para prever a resistência à compressão do concreto leve. Esse método foi comparado com outros modelos, como os *multivariate adaptive regression spline* (MARS), *M5 tree models* e as máquinas vetoriais de suporte (SVM). O conjunto de dados foi compilado a partir de diversos estudos anteriores e foi usado para treinar e testar os modelos propostos. Os parâmetros de entrada para os modelos de previsão foram o teor de cimento, a densidade da escória de alto forno, a relação água-cimento e o volume de concreto. O melhor coeficiente de correlação alcançado entre a resistência à compressão medida e prevista foi de 0,94, 0,93, 0,78 e 0,90 para os modelos ELM, MARS, M5 tree e SVM, respectivamente. Os resultados indicaram que o modelo ELM proposto atingiu um nível adequado de precisão na previsão da resistência à compressão do concreto leve.

O estudo de Azimi-Pour *et al.* (2020) destaca o uso de máquinas vetoriais de suporte para modelar as propriedades do concreto autoadensável com adição de cinza volante. Foram testados modelos

de SVM linear e não linear, explorando o uso das funções de *kernel*, sendo estas: linear, polinomial, base radial (RBF) e *sigmoide*. O estudo propôs a previsão das propriedades e da resistência à compressão do concreto contendo cinza volante. Os testes de resistência à compressão foram realizados com cubos de 150x150x150 mm que foram curados em um tanque de água. A comparação dos resultados experimentais e previstos mostra que o novo modelo SVM tem boa concordância na previsão do concreto autoadensável com adição de cinza volante. Para o *slump*, o  $R^2$ , RMSE e MAPE de SVM treinados com *kernel* RBF são, respectivamente, 0,98, 21,47 e 1,90, enquanto para SVM treinados com *kernel* linear, esses parâmetros são, respectivamente, 0,97, 26,92 e 26,90. Os resultados obtidos para o concreto autoadensável com adição de cinza volante mostraram que modelos com SVM fornecem bons resultados considerando o uso de parâmetros de entrada e saída apropriados. Dentre os modelos testados, os resultados mais precisos para SVM foram obtidos com o uso da função de base radial como *kernel*.

#### 4.2. RESISTÊNCIA AO ARRANCAMENTO

Várias publicações empregaram distintas técnicas de inteligência computacional para analisar a aderência do aço com o concreto e estimar a resistência ao arrancamento. Nesta seção, serão apresentados estudos que utilizaram inteligência computacional para determinar a força de arrancamento a partir de ensaios experimentais.

Com relação ao estudo da aderência entre aço e concreto, utilizando redes neurais, o trabalho de Makni *et al.* (2014) demonstra a aplicabilidade das redes neurais artificiais na previsão do desempenho da ligação. Foi construído, treinado e testado um modelo de redes neurais utilizando dados de teste disponíveis de 117 amostras cilíndricas de concreto com barra de aço engastada do tipo *pull-out*. Os dados utilizados no modelo ANN consistem em quatro parâmetros de entrada: resistência à compressão do concreto, cobrimento, comprimento de aderência e área de nervuras das barras. O modelo ANN, implementado no software *matlab*, é capaz de prever a resistência de ancoragem da armadura no concreto. Os resultados demonstram que as redes neurais artificiais apresentam forte potencial como ferramenta viável para prever a resistência da ligação, com uma boa correlação de  $R^2 = 0,96$ . O estudo também compara os resultados obtidos pelo modelo ANN com fórmulas empíricas e resultados experimentais de vários pesquisadores, mostrando uma precisão aceitável do modelo proposto.

Assim como na resistência à compressão do concreto, modelos híbridos que combinam diversos métodos computacionais também têm sido utilizados para a previsão da resistência ao arrancamento. O estudo de Rinchon *et al.* (2017) apresenta um modelo que utiliza redes neurais artificiais e algoritmo genético (AG) para prever e otimizar a resistência de arrancamento entre as barras de aço e o concreto, considerando diversas variáveis que influenciam essa propriedade. O

ensaio de arrancamento *pull-out* foi utilizado e as variáveis de entrada incluem a resistência à compressão do concreto aos 28 dias, cobrimento de concreto, diâmetro da barra de aço, comprimento de ancoragem, altura da costela e espaçamento entre as costelas. A resistência final de ligação prevista pelo modelo de redes neurais (ANN) demonstrou uma precisão razoável e uma boa correlação com os valores experimentais. Por outro lado, a AG utilizada na busca da combinação ideal das variáveis de entrada resultou em um alto desempenho da resistência da aderência da ligação aço-concreto.

No estudo de Golafshani *et al.* (2012), redes neurais artificiais e modelos de sistemas adaptativos de inferência (ANFIS) foram utilizados para prever a resistência de arrancamento das barras de aço no concreto. O objetivo principal deste estudo foi desenvolver um modelo ANN e ANFIS usando dados experimentais de 179 ensaios de arrancamento em vigas para treinar, validar e testar os modelos. Os modelos utilizados possuem seis entradas: comprimento de ancoragem, área relativa das nervuras, cobrimento de concreto, relação entre a área das barras longitudinais e a seção transversal efetiva na região de trespasse, relação entre a área da seção transversal dos estribos e seu espaçamento na região de trespasse e resistência à compressão do concreto do corpo de prova. A resistência de união das barras de aço no concreto foi o dado de saída para ambos os modelos. O erro percentual médio absoluto foi inferior a 6,60% para ANN e 6,65% para os modelos ANFIS, e o  $R^2$  encontrado foi de 99,50% e 99,45% para ANN e ANFIS, respectivamente, para os conjuntos de teste. Os resultados mostraram que os modelos propostos têm boa capacidade de previsão e generalização, com erros aceitáveis. Concluiu-se também que a ANN proposta é um pouco mais precisa do que o modelo ANFIS.

Nos estudos de força de aderência da ligação aço-concreto empregando métodos computacionais, também são utilizados compósitos com a finalidade de melhorar a resistência do concreto. Um exemplo é o estudo de Sancak (2009), no qual foram produzidas amostras de concreto utilizando agregados de pedra-pomes e fumos de sílica. O cimento foi substituído por fumos de sílica, como aditivo mineral, em 5% e 10% do seu peso. Primeiramente, as propriedades do concreto das amostras produzidas foram avaliadas. Em seguida, testes de resistência à compressão foram realizados nos dias 28 e 90. Além disso, foram realizados 48 testes de arrancamento do tipo *pull-out* em amostras cúbicas de 150 mm<sup>3</sup> no 90º dia, a fim de detectar a resistência de ligação de aderência aço-concreto. Os dados obtidos no final dos testes foram utilizados como entrada para o método de redes neurais artificiais para prever os valores de resistência de ligação. Os valores de resistência de ligação previstos por meio do método ANN foram encontrados próximos aos valores de resistência de ligação obtidos nos testes experimentais. Em conclusão, é benéfico prever a força de ligação do concreto normal e leve por meio do método ANN, usando um alto número de parâmetros como entrada. Assim, foi possível detectar a resistência de ligação reforço aço-concreto de forma mais rápida e confiável, utilizando um menor número de testes em laboratório.

No trabalho de Dahou *et al.* (2009), as redes neurais artificiais foram utilizadas para modelar a ligação entre as barras de aço nervuradas e o concreto, a fim de prever a força de arrancamento através de testes *pull-out*. Para isso, dois modelos foram propostos: o primeiro modelo utiliza a variação do traço do concreto e do diâmetro das barras de aço como parâmetro de entrada, enquanto o segundo utiliza a variação da resistência à compressão do concreto, variando-se o traço do concreto do corpo de prova. Os modelos ANN foram implementados utilizando uma base de dados experimental de 112 resultados de teste de tração realizados com barras nervuradas de 10 mm ou 12 mm de diâmetro e três misturas de concreto com diferentes proporções. Uma rede do tipo *multilayer-perceptron* foi treinada de acordo com um algoritmo de *backpropagation*. O primeiro modelo possui seis entradas (ANN-6): diâmetro da barra nervurada, razão água/cimento, razão brita/areia, razão brita moída/triturada, tipo de cimento e idade do concreto. O segundo modelo tem duas entradas (ANN-2): diâmetro da barra e resistência compressiva do concreto. Os resultados mostram que os modelos implementados têm uma boa capacidade de previsão e generalização com baixos erros. O modelo ANN-6 é mais preciso em relação à capacidade de generalização do que o modelo ANN-2. O estudo conclui que a variação no traço do concreto como parâmetro de entrada, em vez da resistência à compressão, apresenta resultados mais significativos para a determinação da força máxima de arrancamento.

Apesar dos bons resultados obtidos, todos os estudos descritos acima utilizaram bases de dados com ensaios de arrancamento em barras de aço com diâmetros superiores a 10mm para treinamento. Portanto, há uma carência de estudos de métodos computacionais que utilizem bases de dados experimentais com barras de aço finas, ou seja, aquelas com diâmetros inferiores a 10mm.

## 5. METODOLOGIAS EMPREGADAS

### 5.1. RESISTÊNCIA À COMPRESSÃO DO CONCRETO

Nesta seção, é abordado a metodologia empregadas no desenvolvimento de um modelo de inteligência computacional destinado à determinação da resistência à compressão do concreto. Primeiramente, é discutido as linguagens de programação aplicadas neste estudo, bem como as bibliotecas utilizadas para processamento de dados. Posteriormente, é descrito as bases de dados empregadas no treinamento dos algoritmos, cujo objetivo é determinar a resistência à compressão do concreto. Por último, é apresentado os métodos de pré-processamento adotados.

#### 5.1.1. LINGUAGEM DE PROGRAMAÇÃO E BIBLIOTECAS EMPREGADAS

A linguagem de programação empregada neste trabalho é o *Python*, escolhida devido à sua facilidade de uso, ampla comunidade na internet e nos meios acadêmicos. *Python* é uma linguagem de alto nível, orientada a objetos, funcional, com tipagem dinâmica e forte, originalmente lançada por Guido van Rossum em 1991. Atualmente, seu desenvolvimento é comunitário, aberto e gerido pela organização sem fins lucrativos *Python Software Foundation*. As principais bibliotecas utilizadas no âmbito do *Python* neste trabalho são *Scikit-learn* e *Keras* (HETLAND, 2008).

A *Scikit-learn* é uma biblioteca de aprendizado de máquina *open-source* para *Python*, incluindo diversos algoritmos de classificação, regressão e agrupamento, como máquinas vetoriais de suporte, florestas aleatórias e *k-means*. Foi projetada para interagir com as bibliotecas mais populares do *Python*, *NumPy* e *SciPy* (PEDREGOSA *et al.*, 2011).

O *Keras* é uma biblioteca *open-source* de redes neurais escrita em *Python*, compatível com *TensorFlow* e outras bibliotecas. Foi desenvolvido para permitir experimentação rápida com redes neurais profundas, focando em ser amigável, modular e extensível. Criado como parte do projeto de pesquisa ONEIROS (*Open-ended Neuro-Electronic Intelligent Robot Operating System*), seu principal autor e mantenedor é François Chollet. O *Keras* foi projetado como uma interface, em vez de uma estrutura autônoma de aprendizado de máquina, oferecendo abstrações de alto nível e mais intuitivas, facilitando o desenvolvimento de modelos de aprendizado profundo. Neste trabalho, a biblioteca *TensorFlow* foi utilizada para implementação das redes neurais (GULLI; PAL, 2017)

#### 5.1.2. BASES DE DADOS EMPREGADAS

Visando determinar a resistência à compressão do concreto, tornou-se necessário estabelecer uma base de dados confiável e reconhecida na literatura existente. Após uma busca, a base de dados principal escolhida foi a disponibilizada no artigo de Yeh (2006), cujo trabalho visava explorar a

adaptabilidade de máquinas computacionais para prever diversas resistências à compressão do concreto. Yeh empregou um conjunto de lotes experimentais produzidos em laboratório, visando demonstrar resultados experimentais satisfatórios e sua subsequente aplicação em modelos de redes neurais mais precisos que os modelos baseados em regressão linear.

A base de dados conta com 1030 amostras de testes experimentais que apresentam resultados de resistência à compressão do concreto a partir de diferentes composições. No estudo experimental, foram utilizados oito parâmetros de entrada e um parâmetro de saída.

Os parâmetros de entrada incluem os seguintes componentes:

- Cimento.
- Escória de alto-forno.
- Cinzas volantes.
- Água.
- Superplastificante.
- Agregado graúdo.
- Agregado miúdo.
- Idade.

O único parâmetro de saída obtido experimentalmente é a resistência à compressão do concreto.

O processo convencional para testar a resistência à compressão do concreto envolve a moldagem de diversos corpos de prova. É importante ressaltar que a resistência à compressão do concreto geralmente é obtida ao longo de um período que varia entre 7 e 28 dias. No Brasil, a NBR 5739 – Ensaio de compressão de corpos de prova (ABNT, 2007) estabelece o procedimento para os ensaios desses corpos de prova, que pode ser demorado e dispendioso.

Como mencionado anteriormente, o concreto apresenta diferenças comportamentais, resultado de sua heterogeneidade, quando submetido a ensaios para determinar sua resistência à compressão. O tempo e o tipo de cura do concreto também são processos importantes de manutenção da umidade para assegurar a hidratação contínua do concreto.

Um dos principais objetivos deste trabalho é prever, por meio de métodos computacionais, a variável dependente (resistência à compressão do concreto) a partir das variáveis independentes (componentes de entrada). Assim, com base no conjunto de dados, são aplicadas técnicas de regressão para prever o valor da variável dependente, a resistência à compressão do concreto.

A base de dados utilizada apresenta os valores máximos e mínimos dos componentes de entrada e saída, conforme mostrado na Tabela 5.1.

Tabela 5.1: Parâmetros dos atributos de entrada e saída da base de dados.

Atributos do modelo	Valores	
	Máximo	Mínimo
<b>Cimento (kg/m<sup>3</sup>)</b>	540,0	102,0
<b>Escória de alto forno (kg/m<sup>3</sup>)</b>	359,4	0,0
<b>Cinzas volantes (kg/m<sup>3</sup>)</b>	200,1	0,0
<b>Água (kg/m<sup>3</sup>)</b>	247,0	121,8
<b>Superplastificante (kg/m<sup>3</sup>)</b>	32,2	0,0
<b>Agregado graúdo (kg/m<sup>3</sup>)</b>	1145,0	801,0
<b>Agregado fino (kg/m<sup>3</sup>)</b>	992,6	594,0
<b>Idade (dias)</b>	365,0	1,0
<b>Resistência à compressão do concreto (MPa)</b>	82,6	2,3

É notável que a base de dados fornecida por Yeh é bastante conhecida e consolidada , apresentando uma boa distribuição para as variáveis de entrada e para a variável de saída. A literatura também conta com diversos trabalhos que utilizam a mesma base de dados, possibilitando futuras comparações entre os valores obtidos neste estudo.

Para determinar a resistência à compressão do concreto usando métodos de inteligência computacional, além da seleção de uma base de dados consolidada, foi preciso implementar diversos modelos computacionais baseados nos modelos descritos no Capítulo 4. Assim, os algoritmos existentes foram implementados e testados, e inicialmente várias redes neurais foram avaliadas para obter um resultado preliminar da resistência à compressão do concreto.

Com o objetivo de melhorar os resultados obtidos, foram exploradas implementações de outros modelos computacionais baseados em árvores de decisão, florestas aleatórias e máquinas vetoriais de suporte e regressor gradiente *boosting*.

Também foi necessário aplicar diferentes métodos de pré-processamento dos dados, visando melhorar os resultados obtidos nos modelos apresentados.

### 5.1.3. PRÉ-PROCESSAMENTO

Em algumas situações, o conjunto de dados a ser utilizado precisa ser pré-processado antes da aplicação nos diversos modelos de regressão. Esta subseção aborda o pré-processamento como uma ferramenta empregada para aprimorar a resposta dos modelos utilizados. Aqui são apresentados os procedimentos para uma melhor normalização dos dados de entrada.

Uma das etapas de pré-processamento utilizada neste trabalho é chamada de *feature scaling*, ou escalonamento de recursos, apresentada no capítulo 3.1. Conforme mencionado anteriormente, essa escala é necessária antes de construir o modelo de aprendizado de máquina, pois, em muitos casos, a distância entre os pontos analisados pode levar a um ponto dominante sobre o outro, exercendo maior influência no valor da variável-alvo.

Alguns pacotes de programação possuem critérios de escala embutidos que dimensionam automaticamente os recursos, simplificando a aplicação do método. Este é o caso do *Scikit-learn* utilizado neste trabalho. Nas bases de dados empregadas neste estudo, a aplicação da técnica *feature scaling* foi necessária para uma melhor padronização dos dados utilizados.

Para obter bons resultados no aprendizado de máquinas, é comum dividir a base de dados em treinamento, validação e teste. Dessa forma, o algoritmo é treinado com um determinado volume de dados e validado no conjunto de teste, evitando o sobreajuste e garantindo que o modelo aprenda com dados similares aos utilizados para o treinamento. Neste trabalho, o *hold-out validation* é utilizado inicialmente, ajudando a definir qual algoritmo melhor se adapta ao conjunto de dados. Conforme a pesquisa evolui, formas mais refinadas de separação dos dados são consideradas para o aprendizado dos métodos computacionais.

Nesse contexto, a validação cruzada (*cross-validation*), conhecida como *k-fold* e descrita no capítulo 3.1, é utilizada. Neste método, *k* amostras (pastas) são criadas, sendo que cada amostra é deixada de lado enquanto o modelo treina com as demais. O processo é repetido até que seja possível determinar a qualidade de cada divisão. Neste trabalho, os testes na implementação que apresentaram melhor resultado utilizam 5 pastas, portanto, esse foi o número de pastas empregado.

O *GridSearchCV*, processo de ajuste que utiliza a hiperparametrização para definir os valores ideais para um determinado modelo, foi implementado com o auxílio do *cross-validation* na determinação dos valores ótimos dos parâmetros de cada método computacional. O *GridSearchCV* realiza uma busca exaustiva sobre os parâmetros de cada modelo, explorando o produto cartesiano dos parâmetros especificados, minimizando o erro do modelo.

Embora vários métodos de pré-processamento tenham sido testados ao longo do desenvolvimento deste trabalho, o *cross-validation* e o *GridSearchCV* foram mantidos para a implementação dos algoritmos finais.

#### 5.1.4. IMPLEMENTAÇÃO DOS MODELOS COMPUTACIONAIS

A seguir, é apresentado um resumo da metodologia utilizada para cada um dos métodos computacionais empregados neste trabalho:

##### • ÁRVORES DE DECISÃO E FLORESTAS ALEATÓRIAS

1. Os dados são divididos em conjuntos de treinamento e teste, com 85% e 15% respectivamente.
2. A árvore de decisão começa sua análise com um nó único, que se divide em possíveis resultados.
3. Esses resultados levam a novos nós adicionais, que se dividem em outras possibilidades.
4. A estrutura da árvore de decisão e das florestas aleatórias consiste em nós internos, folhas e ramos, conforme descrito na Seção 3.2.
5. O modelo é ajustado aos dados de treinamento.
6. O *GridSearchCV* é utilizado com diversos parâmetros possíveis para árvores de decisão e florestas aleatórias.
7. O *GridSearchCV* otimiza a hiperparametrização para os parâmetros do modelo.
8. O  $R^2$  é calculado para cada hiperparâmetro utilizado.
9. Os melhores parâmetros são aplicados ao modelo.

##### • MÁQUINAS VETORIAIS DE SUPORTE

1. Os dados são divididos em conjuntos de treinamento e teste, com 85% e 15% respectivamente.
2. Os melhores parâmetros para o *kernel* são definidos.
3. O *GridSearchCV* avalia funções lineares, polinomiais e de base radial no conjunto de dados, testando diferentes parâmetros de penalidade para o erro (C), conforme descrito na Seção 3.3.
4. Para funções polinomiais e de base radial, um parâmetro  $\gamma$ , chamado de coeficiente de *kernel*, também é avaliado.
5. O *GridSearchCV* otimiza a hiperparametrização para os parâmetros do modelo.
6. O  $R^2$  é calculado para cada hiperparâmetro utilizado.
7. Os melhores parâmetros são aplicados ao modelo.

## • REDES NEURAIS ARTIFICIAIS

1. Os dados são divididos em conjuntos de treinamento e teste, com 85% e 15% respectivamente.
2. Inicialização: pesos são escolhidos aleatoriamente com valores próximos a zero.
3. Entrada: primeira observação do conjunto de dados na camada de entrada, com cada característica correspondendo a um nó de entrada.
4. Propagação para frente: da esquerda para a direita, os neurônios são ativados e os pesos limitam o impacto da ativação de cada neurônio.
5. A propagação continua até obter o resultado previsto  $\hat{y}$ , que é comparado ao valor real  $y$  e o erro é estimado.
6. A propagação para trás (*backpropagation*) é utilizada para atualizar os pesos com base em sua influência sobre o erro.
7. A atualização de pesos é determinada pela taxa de aprendizagem.
8. As operações de 1 a 7 são repetidas após os lotes de operações.
9. Após todo o conjunto de treinamento ser alimentado na rede neural, completando uma época, o parâmetro da época decide o número de épocas para a operação.

## • REGRESSOR GRADIENTE *BOOSTING*

1. Inicialmente, os dados são divididos em conjuntos de treinamento e teste, com aproximadamente 85% e 15% respectivamente.
2. O regressor gradiente *boosting* combina “modelos de aprendizado” fracos em um único modelo de aprendizagem forte, de maneira iterativa. Um primeiro modelo de florestas aleatórias é criado com uma aproximação simples, gerando um resíduo, que é a distância entre o valor previsto e o valor real.
3. Um novo modelo é criado e ajustado com base no resíduo do modelo anterior, e um novo resíduo é calculado com este segundo modelo.
4. As iterações são repetidas, buscando minimizar os resíduos gerados pelos modelos fracos até que a distância entre o valor previsto e o valor real seja a menor possível.
5. O modelo final é determinado pela soma dos ajustes de todos os modelos fracos.
6. O *GridSearchCV* otimiza a hiperparametrização para os parâmetros do modelo.
7. O  $R^2$  é calculado para cada hiperparâmetro utilizado.
8. Os melhores parâmetros são aplicados ao modelo.

### 5.1.5. APRESENTAÇÃO DOS RESULTADOS

Após a implementação dos modelos computacionais descritos, o desempenho dos algoritmos é apresentado e os resultados obtidos para a resistência à compressão do concreto são comparados aos valores experimentais no Capítulo 6. O desempenho alcançado também é comparado com outros trabalhos que utilizaram a mesma base de dados.

## 5.2. RESISTÊNCIA AO ARRANCAMENTO

Neste capítulo, são apresentadas as metodologias utilizadas para desenvolver um modelo de inteligência computacional para determinar a força de arrancamento usando ensaios *pull-out*. A mesma linguagem de programação e metodologia foram aplicadas, conforme descrito na Seção 5.1, portanto, não é necessário descrever novamente toda a metodologia.

Entretanto, a diferença na implementação da base de dados voltada à determinação da resistência ao arrancamento é a divisão treinamento/teste. Enquanto na base de dados focada na determinação da resistência à compressão do concreto foram utilizados 85% dos dados para treinamento e 15% para teste, na base de dados voltada à determinação da aderência foram utilizados 90% dos dados para treinamento e 10% dos dados para teste. Isso foi necessário porque as bases utilizadas no arrancamento são menores que a base de dados utilizada na resistência à compressão do concreto.

### 5.2.1. BASES DE DADOS DE CARVALHO

Considerando a determinação da resistência ao arrancamento por meio de ensaios *pull-out*, foi necessário definir outra base de dados. Assim, a principal base de dados foi obtida no artigo de Carvalho *et al.* (2017), que disponibiliza 89 amostras de testes experimentais com quatro parâmetros de entrada e um parâmetro de saída.

Os parâmetros de entrada incluem:

- Resistência à compressão do concreto;
- Diâmetro da barra de aço;
- Comprimento de ancoragem;
- Conformação superficial das barras.

O único parâmetro de saída obtido experimentalmente é a força de arrancamento em kN.

Além do pré-processamento utilizado na base de dados anterior, voltada à determinação da resistência à compressão do concreto, nesta base de dados foi realizada uma limpeza através do cálculo do desvio padrão de cada amostra, separadas por diâmetro e resistência do concreto. Essa

análise removeu valores considerados *outliers* para amostras com coeficiente de variação da força de arrancamento superior a 20%. Com isso, a base de dados apresentou maior homogeneidade, contribuindo para resultados mais promissores na implementação dos métodos computacionais.

A base de dados utilizada apresenta os valores máximos e mínimos dos componentes de entrada e saída, conforme mostrado na Tabela 5.2.

Tabela 5.2: Parâmetros dos atributos de entrada e saída da base de dados.

Atributos do modelo	Valores	
	Mínimo	Máximo
Resistência à compressão do concreto (MPa)	23,0	47,0
Diâmetro (mm)	6,0	10,0
Comprimento de ancoragem (mm)	30,0	100,0
Conformação superficial das barras	Entalhada (Tipo 1)	Nervuradas (Tipo 2)
Força máxima de arrancamento (kN)	2,5	36,5

### 5.2.2. APRESENTAÇÃO DOS RESULTADOS

Semelhante ao que foi feito para a resistência à compressão do concreto, o desempenho dos algoritmos na determinação da resistência ao arrancamento é apresentado no Capítulo 7 e o valor da resistência ao arrancamento encontrado é comparado aos valores experimentais.

### 5.2.3. EQUAÇÃO EMPÍRICA

Conforme mencionado anteriormente, a literatura apresenta diversos modelos analíticos e numéricos que tentam representar a resposta à tensão de arrancamento de uma ligação na interface aço-concreto. A maioria desses modelos é baseada em resultados experimentais e analisa vários parâmetros, como: resistência à compressão do concreto, cobrimento de concreto, diâmetro da barra de aço, comprimento de ancoragem, entre outros. Esses testes forneceram equações para calcular a tensão média da ligação por meio de regressões lineares ou não lineares a partir de resultados experimentais.

Portanto, os valores obtidos para a tensão de arrancamento nos ensaios experimentais e nos modelos computacionais podem ser comparados com os valores empíricos obtidos por meio da equação analítica. É possível utilizar a Equação (2.2) (CEB, 2010).

#### 5.2.4. BASE DE DADOS AMPLIADA

Considerando que o estudo da implementação de métodos computacionais para obter a força de aderência de barras de aço de pequenos diâmetros no concreto é relativamente novo, foi necessário reunir ensaios experimentais de diversos trabalhos. Os estudos utilizados neste trabalho são apresentados nos parágrafos a seguir.

Vale Silva (2010) investigou a proposta de Lorrain e Barbosa (2008), controlando parâmetros em laboratório e comparando dois tipos de ensaios de aderência aço-concreto: o ensaio *pull-out* e o *pull-out* modificado. Foram utilizadas duas classes de resistência de concreto, barras de aço de diâmetros 8,0 mm, 10,0 mm e 12,5 mm e idades de ruptura dos dois ensaios aos 3, 7 e 28 dias.

No estudo de Sabau (2020), os ensaios de aderência visaram prever a tensão de arrancamento no concreto autoadensável. Os parâmetros considerados incluíram resistência compressiva do concreto, propriedades geométricas da barra de reforço e reforço de confinamento. Os dados consistiram em 500 simulações para várias classes de concreto (C12, C16, C20, C25, C30, C35, C40, C45 e C50) e diâmetros de barras de reforço (10, 12, 16, 20 e 25 mm). Foi realizada uma análise exploratória de dados e estatísticas descritivas foram utilizadas para analisar todos os dados e alguns subconjuntos de interesse.

França (2004) apresenta os resultados dos ensaios de arrancamento realizados com concreto convencional e concreto contendo 10% de resíduo de borracha em substituição à areia, em volume, nas idades de 28 e 90 dias. As barras de aço utilizadas foram do tipo nervuradas e com diâmetros variando entre 10,0, 12,5 e 16,0 mm. A introdução dos resíduos de borracha no concreto permitiu avaliar o comportamento desse tipo de concreto e a viabilidade de sua utilização estrutural como material de construção, em substituição ao concreto convencional.

O estudo de Fernandes (2000) descreve o comportamento da aderência do concreto armado sob ações monotônicas e repetidas por meio de uma revisão bibliográfica e ensaios de arrancamento padronizados. A influência de alguns parâmetros foi analisada, como diâmetro da armadura, tipo e amplitude de carregamento. Também foi realizada a análise numérica da aderência monotônica empregando elementos finitos. A resistência monotônica da ligação ficou compreendida entre condições boas e ruins de aderência.

Almeida Filho (2006) conduziu um estudo que analisou o comportamento de ligação entre barras de aço e concreto autoadensável em comparação com concreto vibrado, utilizando testes de

arrancamento e vigas. Os principais parâmetros analisados incluíram resistência à compressão do concreto, diâmetro da barra de aço e tipo de concreto. Uma comparação entre códigos normativos e equações empíricas também foi realizada. Segundo os resultados, os espécimes de concreto autoadensável e concreto convencional exibiram comportamento semelhante.

Nogueira (2018) apresentou uma dissertação focada no estudo das condições de aderência aço-concreto com barras de aço finas e grossas, investigando a resistência de aderência e a determinação do coeficiente de conformação superficial experimental. Foram utilizados concretos da classe C40 e aços da categoria CA-50 nervurados (diâmetros 6,3, 10,0, 20,0, 25,0 e 32,0 mm), CA-60 nervurados (diâmetros 3,4, 4,2, 6,0 e 9,5 mm) e CA-60 lisos (diâmetros 3,4 e 4,2 mm). Como o ensaio de barras confinadas não é eficiente para barras menores que 10 mm, devido às distorções proporcionalmente maiores considerando a relação diâmetro/força de arrancamento, os ensaios de arrancamento do tipo “*pull-out*” foram executados para determinar as tensões de aderência aço-concreto e o coeficiente de conformação superficial experimental.

O estudo realizado por Barbosa (2001) buscou avaliar o comportamento da aderência aço-concreto para barras de fabricação nacional de seção circular com sete diâmetros distintos (6,3, 8,0, 10,0, 12,5, 16,0, 20,0 e 25,0 mm) e barras de seção quadrada com três tamanhos de lado (6,3, 8,0 e 10,0 mm); foram empregados concretos de cinco classes de resistência à compressão (20, 40, 60, 80 e 100 MPa). Assim, foram realizados dois tipos de ensaio de aderência: ensaio de tirantes (tração simétrica) e ensaio de arrancamento (*pull-out*) para cada dimensão de barra e classe de resistência do concreto. Os resultados experimentais foram comparados com especificações de normas e formulações teóricas propostas por diversos autores para a relação tensão de aderência *versus* deslizamento.

Em resumo, as bases de dados utilizadas neste estudo, com o objetivo de validar os métodos computacionais empregados, apresentam os seguintes valores máximos e mínimos dos componentes de entrada e saída, conforme mostrado na Tabela 5.3.

Tabela 5.3: *Range* dos parâmetros das bases de dados consultadas e que são utilizadas neste trabalho.

<b>Autor</b>	<b>Nº de ensaios</b>	<b>Fc (MPa)</b>	<b>Diâmetros (mm)</b>	<b>Comprimento de ancoragem (mm)</b>	<b>Força de arrancamento (kN)</b>
<b>Carvalho <i>et al.</i> (2017)</b>	89	23,0 – 47,0	6,0 – 10,0	30,0 – 100,0	2,51 – 36,45
<b>Vale Silva (2010)</b>	10	16,7 – 40,5	8,0 – 10,0	48,0 – 100,0	16,4 – 37,1
<b>Sabau (2020)</b>	12	20,0 – 43,0	10,0	30,0 – 50,0	6,8 – 15,6
<b>França (2004)</b>	30	32,9 – 35,2	10,0	50,0	3,8 – 7,9
<b>Fernandes (2000)</b>	4	29,7 – 30,5	10,0	50,0	18,4 – 22,5
<b>Almeida Filho (2006)</b>	5	32,0	10,0	50,0	16,5 – 19,6
<b>Nogueira (2018)</b>	24	39,7 – 42,3	6,0 – 10,0	60,0 – 100,0	4,7 – 51,7
<b>Barbosa (2001)</b>	15	20,0 – 100,0	6,3 – 10,0	31,5 – 50,0	1,4 – 15,0

Ao tratar-se de diâmetros finos, todas as bases incluídas neste trabalho apresentam o mesmo tipo de ruptura, ou seja, por arrancamento, semelhante ao observado nos ensaios conduzidos por Carvalho *et al.* (2017). É importante mencionar que algumas das bases utilizadas neste estudo, como Nogueira (2018), França (2004), Fernandes (2000) e Almeida Filho (2006), apresentam resultados experimentais para cada um dos corpos de prova, ou seja, existem valores de entrada iguais, uma vez que os espécimes se repetem, fornecendo, no entanto, valores de arrancamento diferentes. As demais bases apresentam valores médios para esses ensaios, ou seja, as entradas são únicas e não se repetem, e o valor do resultado experimental utilizado é a média dos valores obtidos para o arrancamento naquele ensaio.

Com a base de dados ampliada, foram realizados dois testes, conforme descrito a seguir: No primeiro teste, que teve como objetivo avaliar os algoritmos treinados com a base de Carvalho *et al.* (2017), os parâmetros de entrada dos dados experimentais da base ampliada foram utilizados no algoritmo treinado com a base de dados de Carvalho *et al.* (2017). Dessa forma, o algoritmo fornece valores para a força de arrancamento que serão então comparados com aqueles obtidos por meio dos ensaios experimentais.

No segundo teste, a base ampliada foi utilizada integralmente para treinar novos algoritmos de inteligência computacional, de maneira similar ao que foi feito nos estudos anteriores realizados neste trabalho, com a base de Yeh, I.-C. (2006) e Carvalho *et al.* (2017).

Novamente, são apresentados os resultados de desempenho dos algoritmos e a comparação com os valores obtidos experimentalmente.

## 6. APRESENTAÇÃO DOS RESULTADOS - RESISTÊNCIA À COMPRESSÃO DO CONCRETO

Neste capítulo, são apresentados os resultados obtidos por meio dos modelos computacionais utilizados para determinar a resistência à compressão do concreto, conforme descrito anteriormente.

Para determinar a resistência à compressão do concreto, os parâmetros de desempenho escolhidos para avaliar as implementações dos modelos são a raiz do erro quadrático médio (RMSE) e o coeficiente de determinação ( $R^2$ ). A seguir, também é apresentada a variedade dos parâmetros utilizados em cada um dos modelos computacionais e os parâmetros escolhidos por meio da calibração proporcionada pelo *GridSearchCV*.

### 6.1. ÁRVORES DE DECISÃO

Para o modelo de árvores de decisão, a variação de parâmetros implementada e os parâmetros que apresentaram os melhores resultados estão descritos na Tabela 6.1.

Tabela 6.1: Variação de parâmetros e parâmetros utilizados na implementação das árvores de decisão.

Parâmetro	Varição	Configuração utilizada
Função utilizada para medir a qualidade da divisão	mse-mae	mse
Profundidade máxima dos estimadores de regressão	None-3	100
Nº máximo de características	None-3	None
Nº mínimo de amostras para um nó de folha	1-5	2
Nº mínimo de amostras para dividir um nó interno	2-30	10

Os parâmetros apresentados na Tabela 6.1 estão descritos na Seção 3.2 e, conforme mencionado anteriormente, os valores desses parâmetros foram definidos por meio de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de desempenho obtidos por meio da implementação das árvores de decisão estão apresentados na Tabela 6.2.

Tabela 6.2: Erros médios obtidos com a implementação das árvores de decisão.

Treinamento RMSE (MPa)	Teste RMSE (MPa)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
4,094	6,673	0,938	0,863

Na Figura 6.1 e na Figura 6.2 são apresentados os resultados para os valores originais e previstos para teste e treinamento, respectivamente, obtidos na implementação das árvores de decisão.

Figura 6.1: Resultados original *versus* previsto obtidos na implementação do árvores de decisão para a parcela de treinamento.

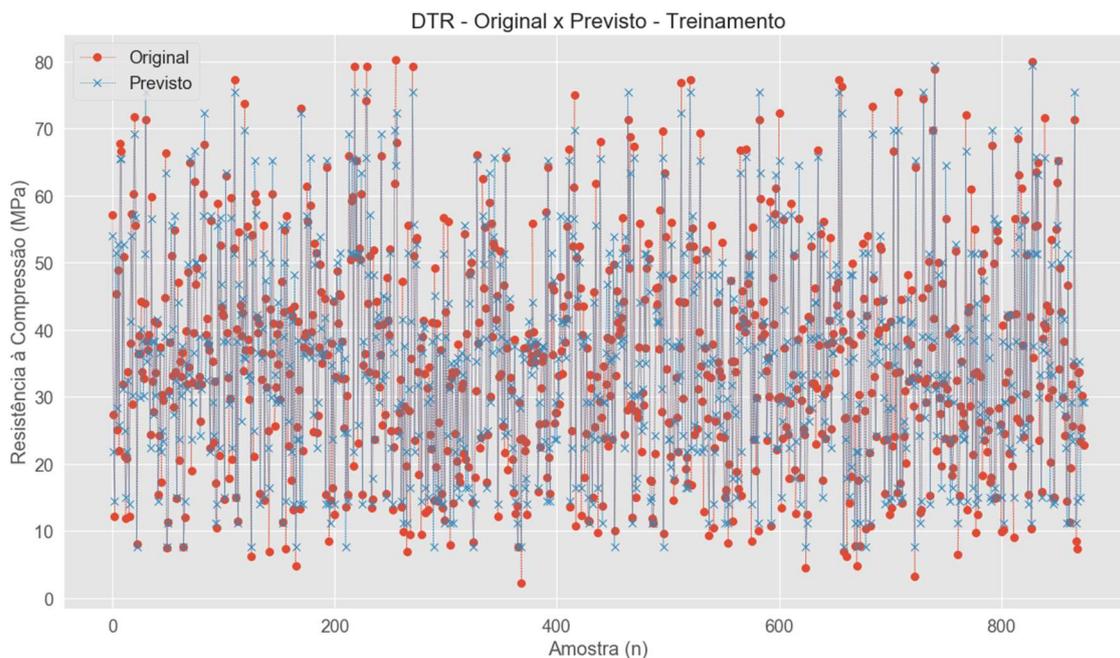
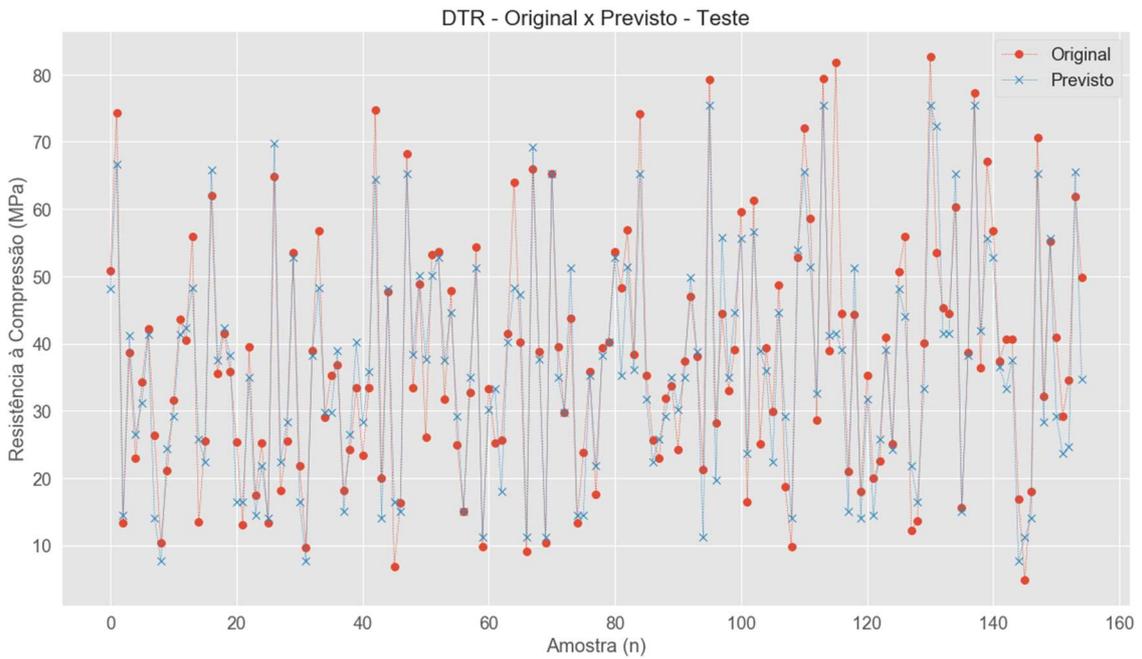
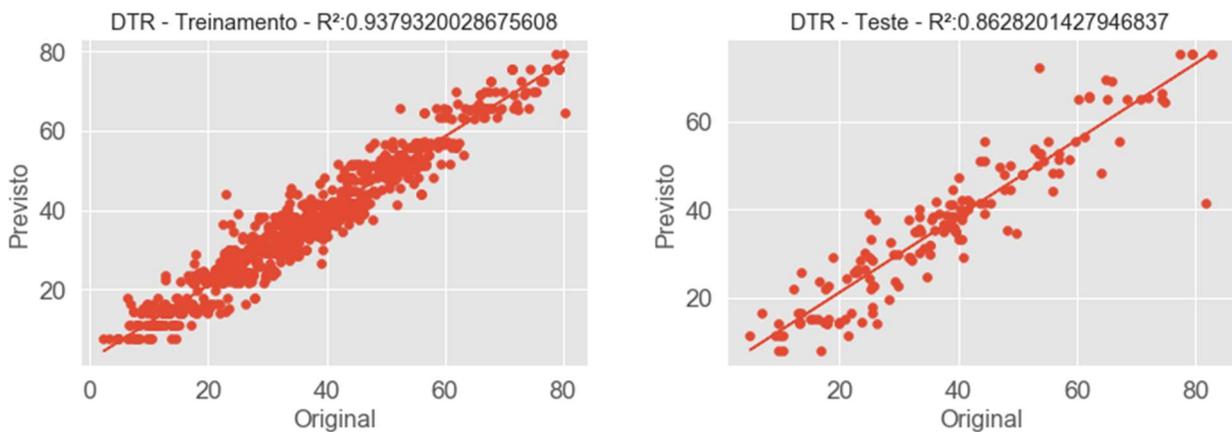


Figura 6.2: Resultados original *versus* previsto obtidos na implementação do árvores de decisão para a parcela de teste.



Na Figura 6.3 são apresentados os valores de  $R^2$  original *versus* previsto obtidos na implementação das árvores de decisão.

Figura 6.3: Resultados de  $R^2$  original *versus* previsto obtidos na implementação de árvores de decisão para as parcelas de treinamento e teste.



## 6.2. FLORESTAS ALEATÓRIAS

Para o modelo de florestas aleatórias, a variação de parâmetros implementada e os parâmetros que apresentaram os melhores resultados estão descritos na Tabela 6.3.

Tabela 6.3: Variação de parâmetros e parâmetros utilizados na implementação das florestas aleatórias.

<b>Parâmetro</b>	<b>Varição</b>	<b>Configuração utilizada</b>
<b>Função utilizada para medir a qualidade da divisão</b>	mse-mae	mse
<b>Profundidade máxima dos estimadores de regressão</b>	3-10	7
<b>Quantidade máxima de nós</b>	80-120	90
<b>Nº mínimo de amostras para dividir um nó interno</b>	6-10	7
<b>Nº máximo de características</b>	auto-sqrt-log2	auto
<b>Nº mínimo de amostras para um nó de folha</b>	1-5	2

Os parâmetros apresentados na Tabela 6.3 estão descritos na Seção 3.2 e, conforme mencionado anteriormente, os valores desses parâmetros foram definidos através de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de desempenho obtidos através da implementação das florestas aleatórias estão apresentados na Tabela 6.4.

Tabela 6.4: Erros médios obtidos com a implementação das florestas aleatórias.

<b>Treinamento RMSE (MPa)</b>	<b>Teste RMSE (MPa)</b>	<b>Treinamento R<sup>2</sup></b>	<b>Teste R<sup>2</sup></b>
3,061	5,910	0,952	0,892

Na Figura 6.4 e na Figura 6.5 são apresentados os resultados dos valores originais e previstos para teste e treinamento, respectivamente, obtidos na implementação das florestas aleatórias.

Figura 6.4: Resultados original *versus* previsto obtidos na implementação das florestas aleatórias para a parcela de treinamento.

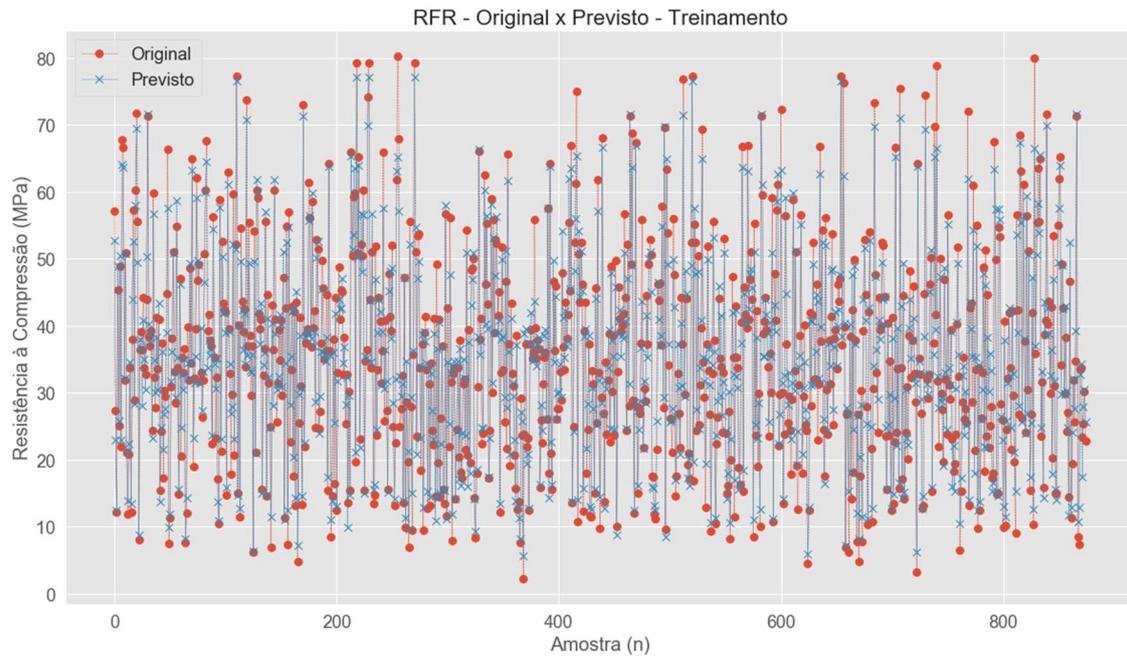
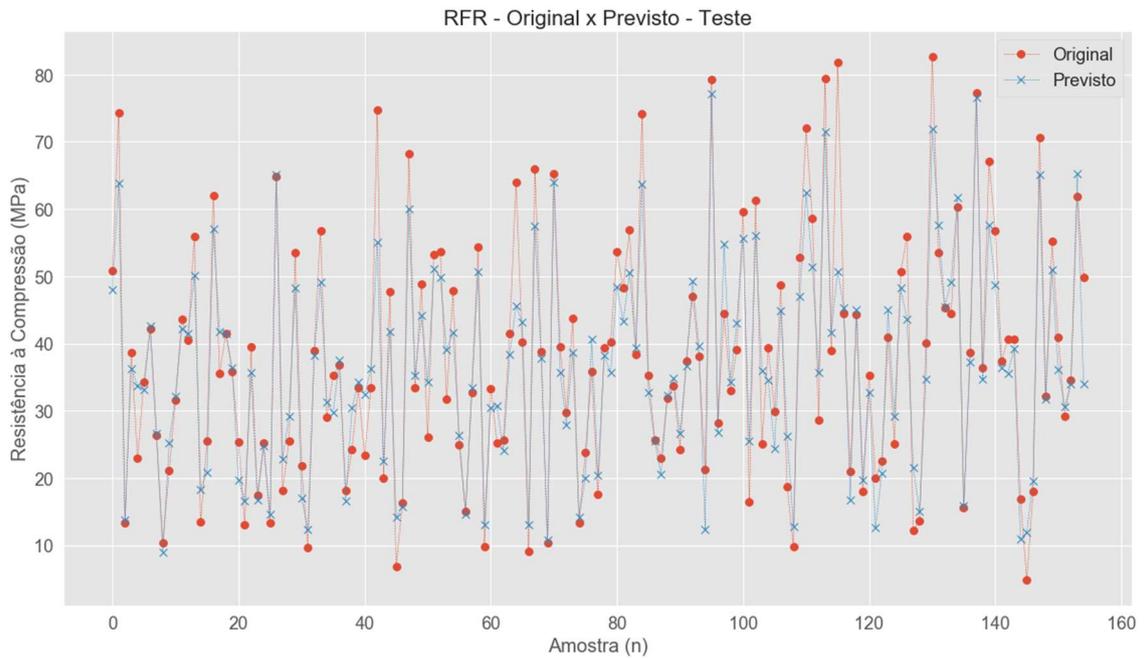
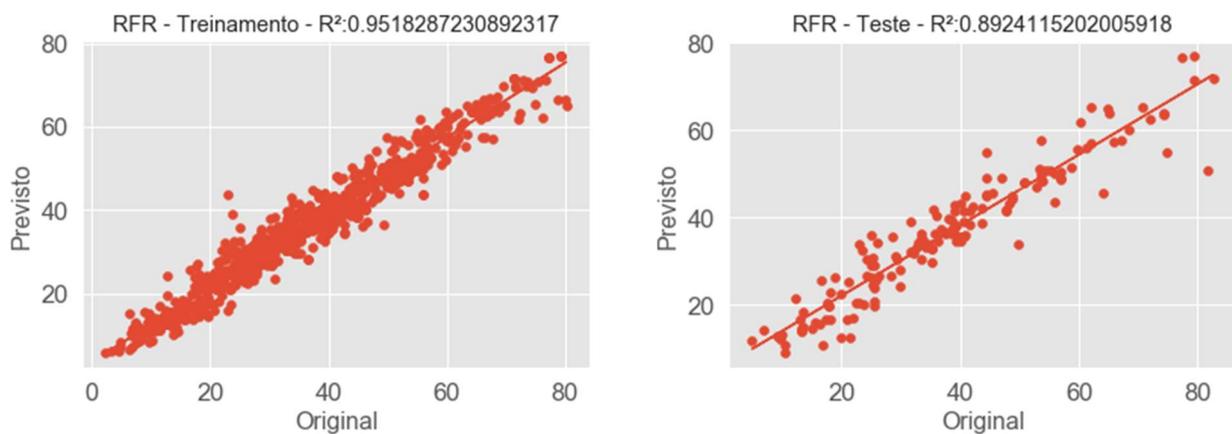


Figura 6.5: Resultados original *versus* previsto obtidos na implementação das florestas aleatórias a parcela de teste.



Na Figura 6.6 são apresentados os valores de  $R^2$  original *versus* previsto obtidos na implementação das florestas aleatórias.

Figura 6.6: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das florestas aleatórias para as parcelas de treinamento e teste.



### 6.3. MÁQUINAS VETORIAIS DE SUPORTE

Para o modelo de máquinas vetoriais de suporte, a variação de parâmetros implementada e os parâmetros que apresentaram os melhores resultados estão descritos na Tabela 6.5.

Tabela 6.5: Variação de parâmetros e parâmetros utilizados na implementação das máquinas vetoriais de suporte.

<b>Parâmetro</b>	<b>Variação</b>	<b>Configuração utilizada</b>
<i>kernel</i>	rbf-linear-poly	Rbf
C	50-500	100

Os parâmetros apresentados na Tabela 6.5 estão descritos na Seção 3.3 e, como mencionado anteriormente, os valores desses parâmetros foram determinados por meio de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de desempenho obtidos por meio da implementação das máquinas vetoriais de suporte estão apresentados na Tabela 6.6.

Tabela 6.6: Erros médios obtidos com a implementação das máquinas vetoriais de suporte.

<b>Treinamento RMSE (MPa)</b>	<b>Teste RMSE (MPa)</b>	<b>Treinamento R<sup>2</sup></b>	<b>Teste R<sup>2</sup></b>
2,555	7,456	0,976	0,829

A Figura 6.7 e a Figura 6.8 exibem os valores originais e previstos para os conjuntos de teste e treinamento, respectivamente, obtidos com a implementação das máquinas vetoriais de suporte.

Figura 6.7: Resultados original *versus* previsto obtidos na implementação do máquinas vetoriais de suporte para a parcela de treinamento.

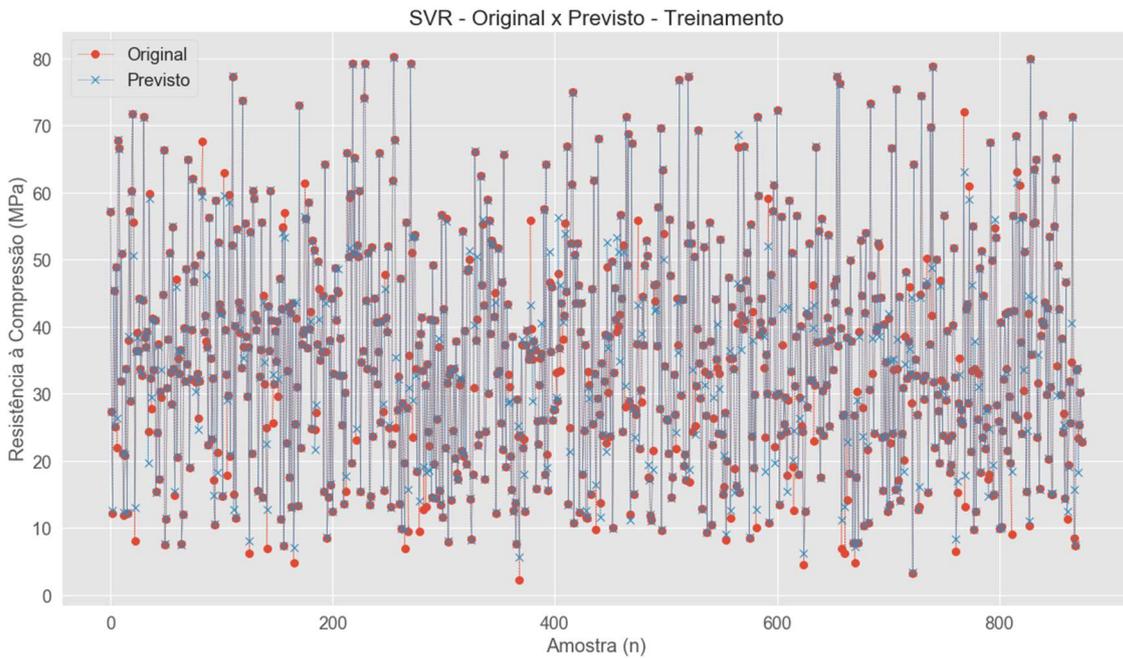
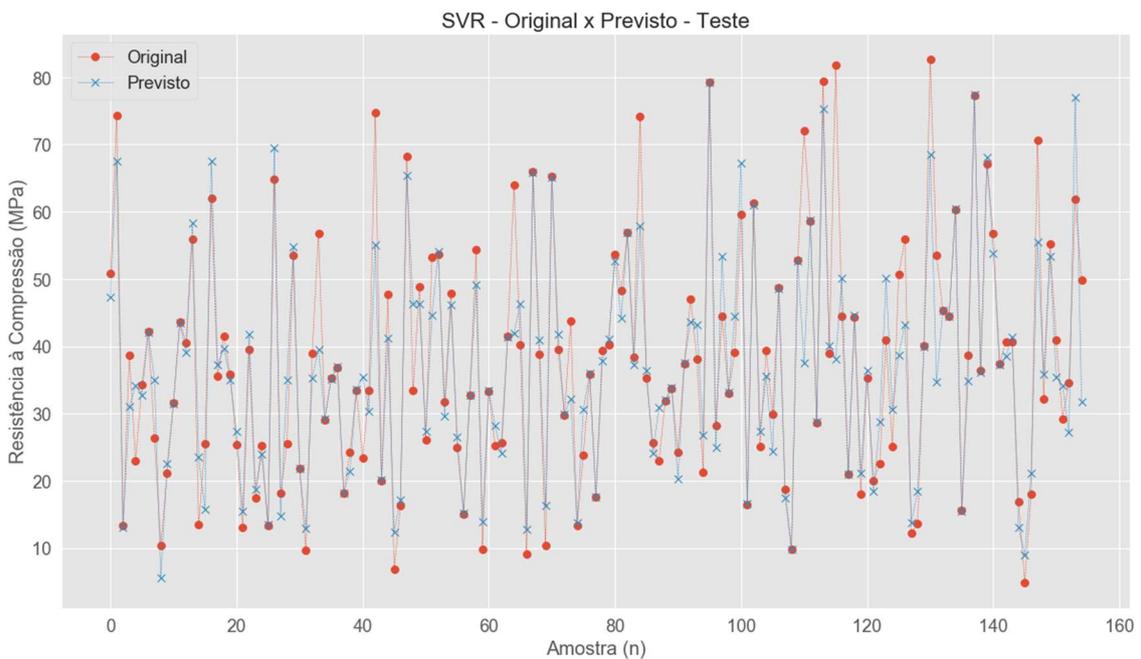
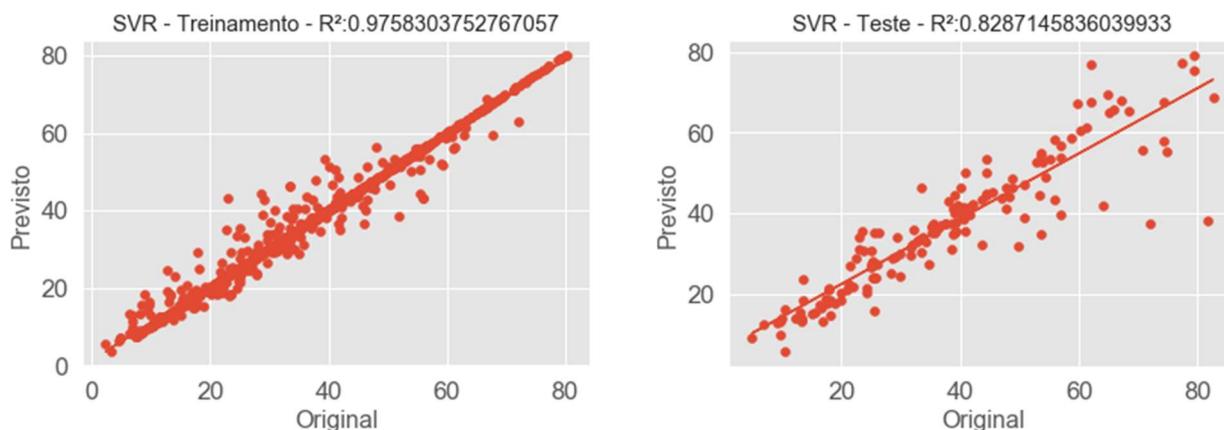


Figura 6.8: Resultados original *versus* previsto obtidos na implementação do máquinas vetoriais de suporte para a parcela de teste.



A Figura 6.9 apresenta os valores de  $R^2$  original *versus* previsto obtidos na implementação das máquinas vetoriais de suporte.

Figura 6.9: Resultados de  $R^2$  original *versus* previsto obtidos na implementação do máquinas vetoriais de suporte para as parcelas de treinamento e teste.



#### 6.4. REDES NEURAIS ARTIFICIAIS

Para o modelo de redes neurais artificiais, os parâmetros que apresentaram os melhores resultados estão descritos na Tabela 6.7.

Tabela 6.7: Parâmetros utilizados na implementação das redes neurais artificiais.

Parâmetro	Configuração utilizada
Quantidade de neurônios de camada de entrada	8
Número de camadas intermediárias	1
Quantidade de neurônios de camada de intermediária	15
Função de ativação	relu-linear

Os parâmetros apresentados na Tabela 6.7 estão descritos na Seção 3.4 e, como mencionado anteriormente, os valores desses parâmetros foram determinados por meio de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de desempenho obtidos por meio da implementação das redes neurais artificiais estão apresentados na Tabela 6.8.

Tabela 6.8: Erros médios obtidos com a implementação das redes neurais artificiais.

Treinamento RMSE (MPa)	Teste RMSE (MPa)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
4,893	6,354	0,911	0,876

A Figura 6.10 e a Figura 6.11 exibem os valores originais e previstos para os conjuntos de teste e treinamento, respectivamente, obtidos com a implementação das redes neurais artificiais.

Figura 6.10: Resultados original *versus* previsto obtidos na implementação de redes neurais artificiais para a parcela de treinamento.

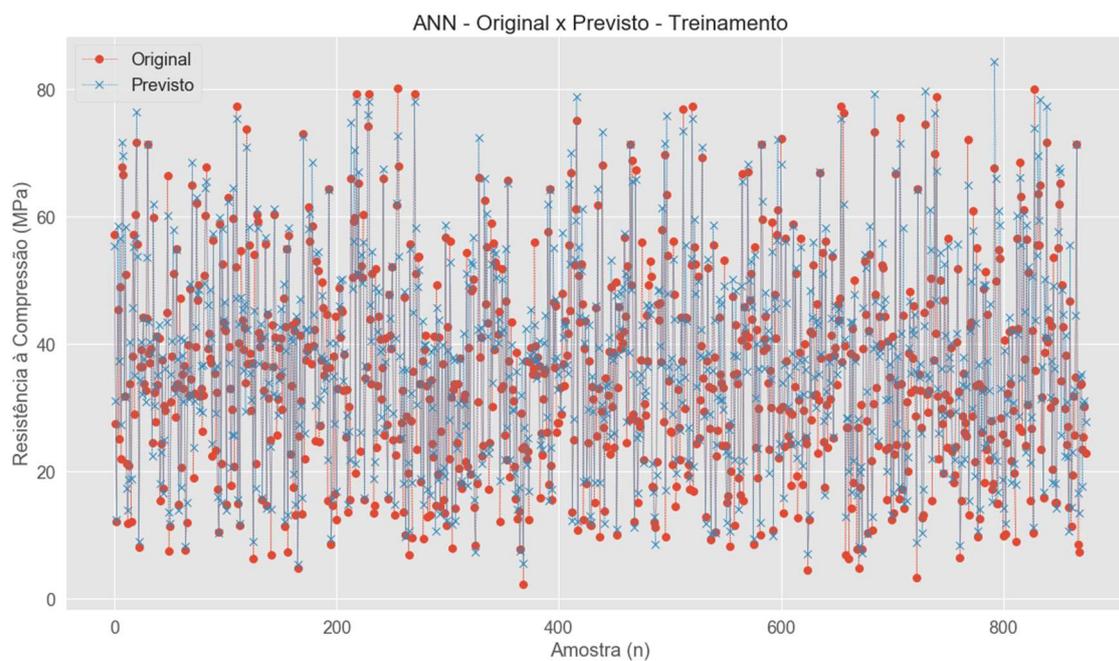
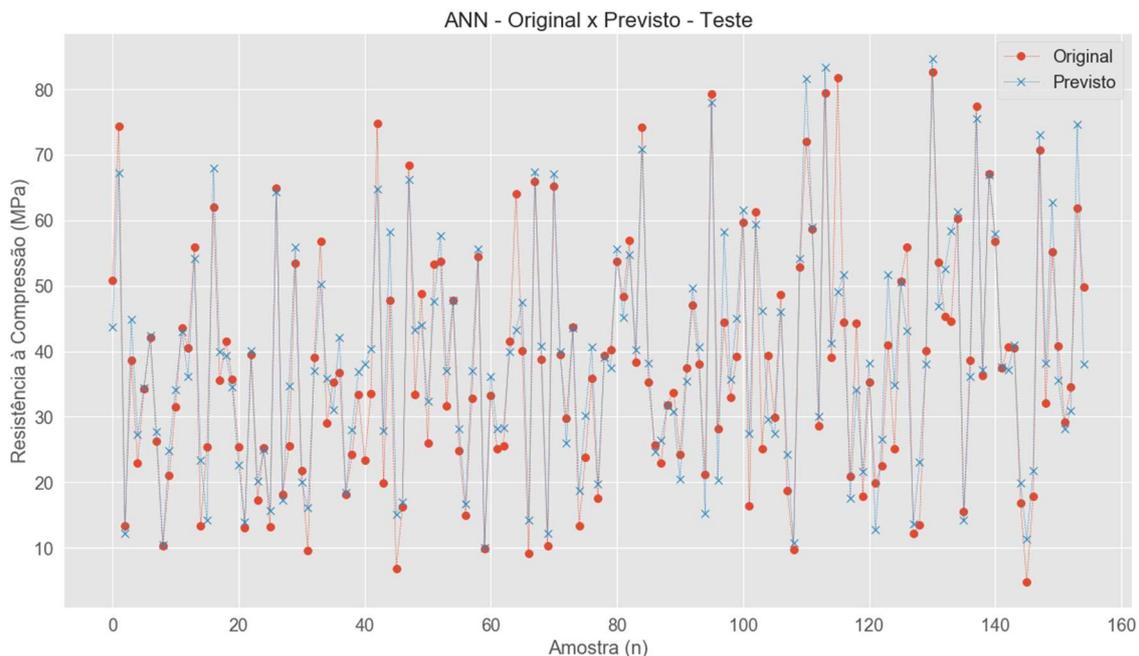
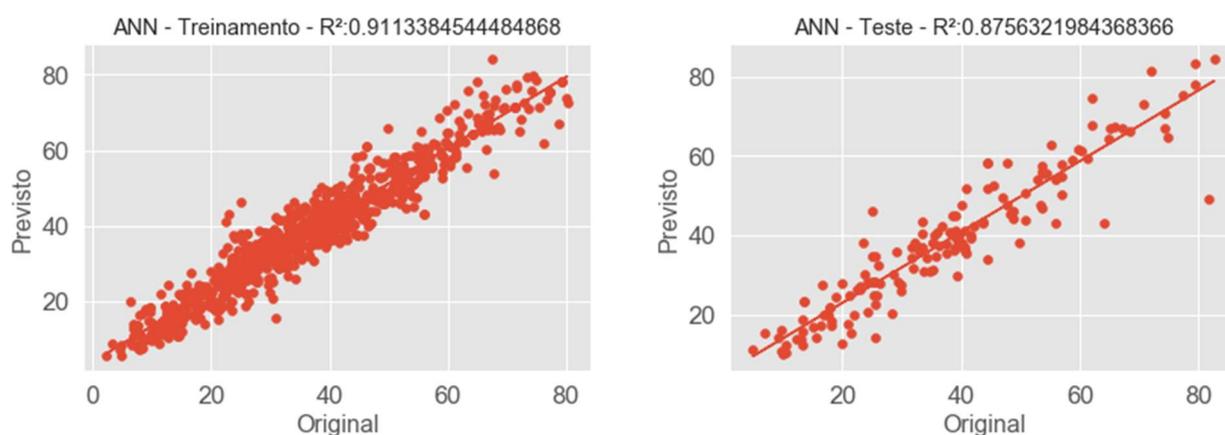


Figura 6.11: Resultados original *versus* previsto obtidos na implementação de redes neurais artificiais para a parcela de teste.



A Figura 6.12 apresenta os valores de  $R^2$  original *versus* previsto obtidos na implementação das redes neurais artificiais.

Figura 6.12: Resultados de  $R^2$  original *versus* previsto para redes neurais artificiais para as parcelas de treinamento e teste.



## 6.5. REGRESSOR GRADIENTE *BOOSTING*

Para o modelo de Regressão por Gradiente *Boosting*, a variação de parâmetros implementada e os parâmetros que apresentaram os melhores resultados estão descritos na Tabela 6.9.

Tabela 6.9: Variação de parâmetros e parâmetros utilizados na implementação do regressor gradiente *boosting*.

Parâmetro	Varição	Configuração utilizada
Nº de estágios de <i>boosting</i> a serem realizados	230	230
Profundidade máxima dos estimadores de regressão	2-30	14
Nº mínimo de amostras para dividir um nó interno	10-500	150
Taxa de aprendizado	0,2	0,2

Os parâmetros apresentados na Tabela 6.9 estão descritos na Seção 3.5 e, como mencionado anteriormente, os valores desses parâmetros foram determinados por meio de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de desempenho obtidos por meio da implementação do regressor gradiente *boosting* estão apresentados na Tabela 6.10.

Tabela 6.10: Erros médios obtidos com a implementação de regressor gradiente *boosting*.

Treinamento RMSE (MPa)	Teste RMSE (MPa)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
1,427	4,113	0,992	0,948

A Figura 6.13 e a Figura 6.14 exibem os valores originais e previstos para os conjuntos de teste e treinamento, respectivamente, obtidos com a implementação do regressor gradiente *boosting*.

Figura 6.13: Resultados original *versus* previsto obtidos na implementação do regressor gradiente *boosting* para a parcela de treinamento.

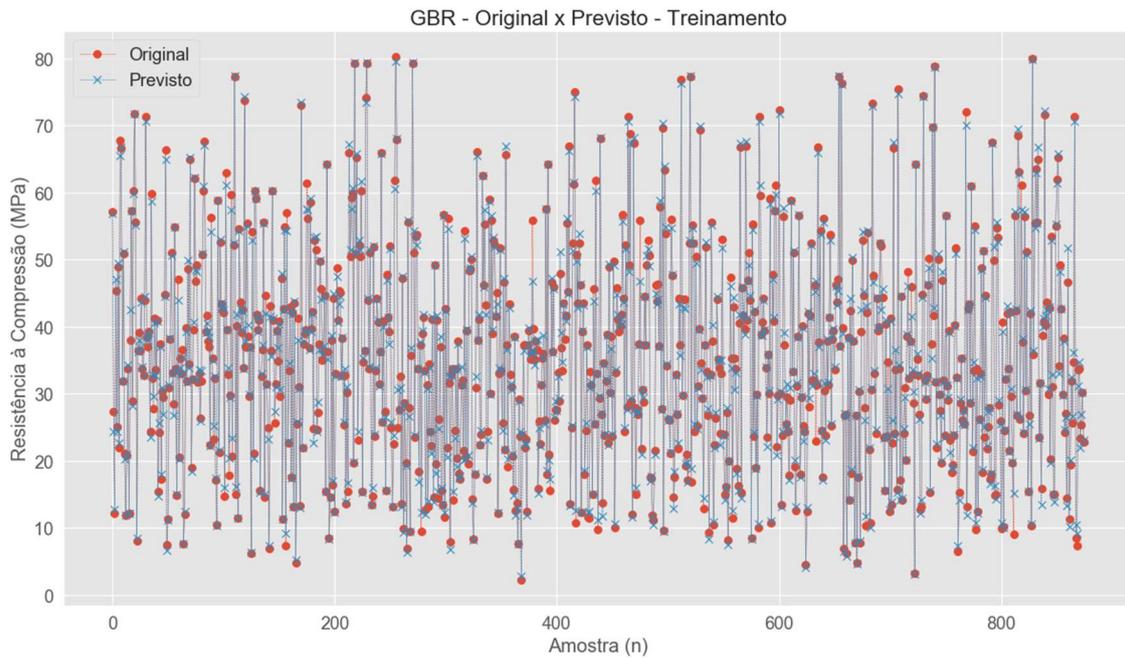
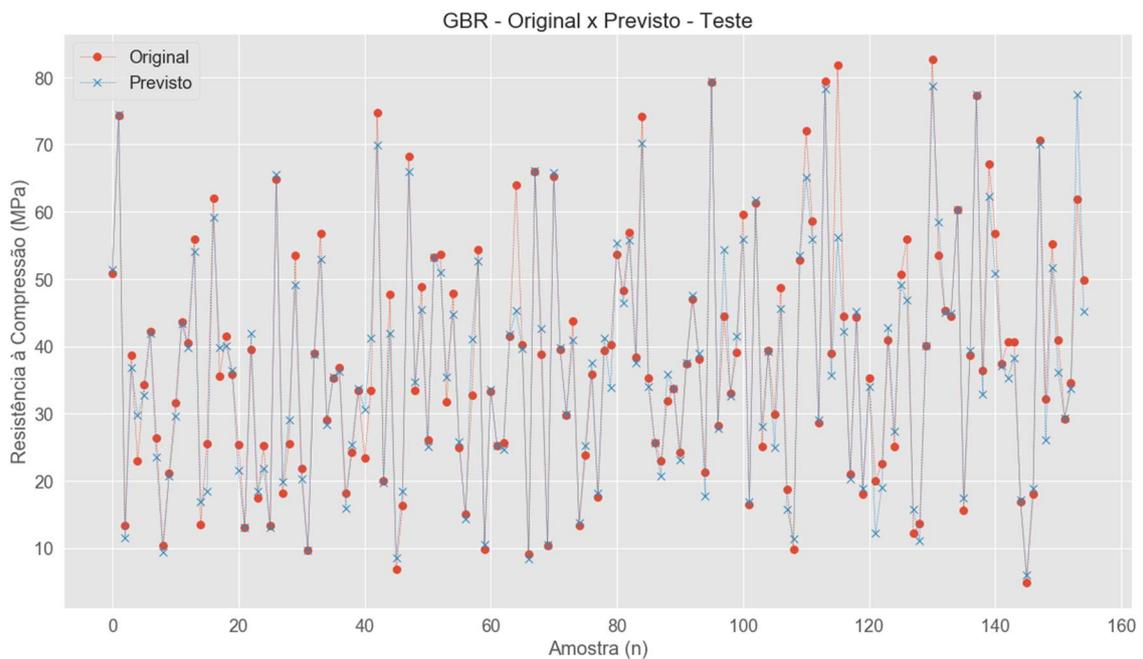
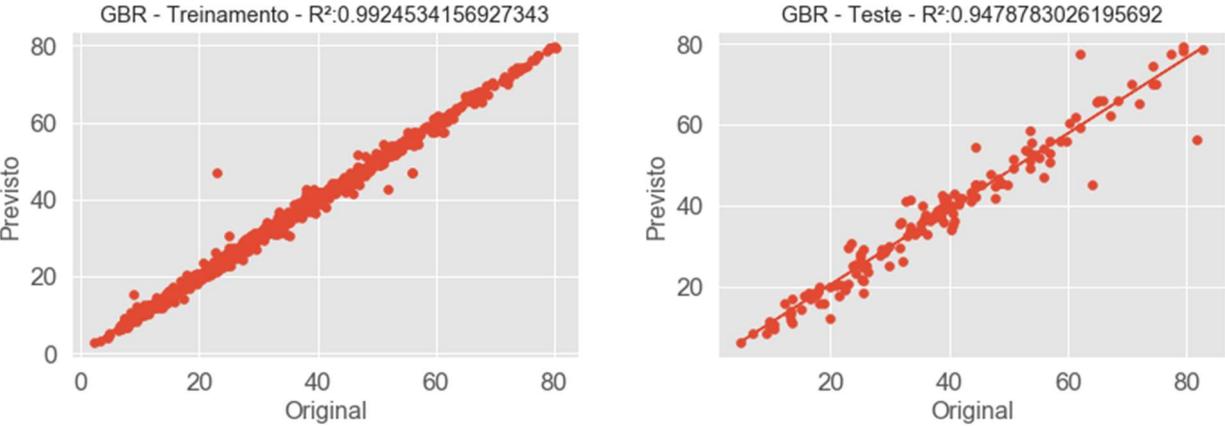


Figura 6.14: Resultados original *versus* previsto obtidos na implementação do regressor gradiente *boosting* para a parcela de teste.



A Figura 6.15 apresenta os valores de  $R^2$  original *versus* previsto obtidos na implementação do regressor gradiente *boosting*.

Figura 6.15: Resultados de  $R^2$  original *versus* previsto obtidos na implementação do regressor gradiente *boosting* para as parcelas de treinamento e teste.



## 7. APRESENTAÇÃO DOS RESULTADOS - RESISTÊNCIA AO ARRANCAMENTO

Neste capítulo, são apresentados os resultados obtidos pelos modelos computacionais empregados para determinar a força de aderência através dos ensaios *pull-out*.

A Seção 7.1 aborda o uso do banco de dados de Carvalho *et al.* (2017) para treinar os modelos computacionais com o objetivo de determinar a resistência ao arrancamento de barras finas de aço ancoradas em blocos de concreto. Na Seção 7.2, é comparado os resultados obtidos nos modelos computacionais aos valores encontrados por meio de equações empíricas disponíveis na literatura.

Na Seção 7.3, o algoritmo é treinado com o banco de dados de Carvalho *et al.* (2017) usando uma base de dados ampliada, ou seja, com outros valores obtidos na literatura especializada, visando comparar o resultado obtido no método computacional. Os resultados desses testes podem ser comparados aos valores obtidos no ensaio experimental. Em seguida, treinamos os algoritmos anteriormente utilizados com a base de dados ampliada e comparamos seus resultados com os valores experimentais.

Para avaliar a performance das implementações dos modelos na determinação da resistência ao arrancamento, utilizamos a raiz do erro quadrático médio (RMSE) e o coeficiente de determinação ( $R^2$ ). A seguir, apresentamos a variedade de parâmetros usados em cada um dos modelos computacionais e os parâmetros escolhidos por meio da calibração proporcionada pelo *GridSearchCV*.

## 7.1. BASE DE DADOS DE CARVALHO

### 7.1.1. ÁRVORES DE DECISÃO

A variação dos parâmetros implementados e os parâmetros que apresentaram os melhores resultados para o modelo de árvore de decisão estão descritos na Tabela 7.1.

Tabela 7.1: Variação de parâmetros e parâmetros utilizados na implementação das árvores de decisão.

Parâmetro	Variação	Configuração utilizada
Função utilizada para medir a qualidade da divisão	mse-mae	mse
Profundidade máxima dos estimadores de regressão	None-3	None
Nº máximo de características	None-3	2
Nº mínimo de amostras para um nó de folha	1-5	2
Nº mínimo de amostras para dividir um nó interno	2-30	5

Os parâmetros listados na Tabela 7.2 são descritos na Seção 3.2 e, como mencionado anteriormente, seus valores foram definidos através de hiperparametrização utilizando o *GridSearchCV*.

A Tabela 7.2. apresenta os parâmetros de desempenho obtidos a partir da implementação das árvores de decisão.

Tabela 7.2: Erros médios obtidos com a implementação das árvores de decisão.

Treinamento RMSE (kN)	Teste RMSE (kN)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
2,40	1,26	0,89	0,95

A Figura 7.1 e a Figura 7.2 mostram os valores originais e previstos para o conjunto de teste e treinamento, respectivamente, obtidos na implementação das árvores de decisão.

Figura 7.1: Resultados original *versus* previsto obtidos na das árvores de decisão para a parcela de treinamento.

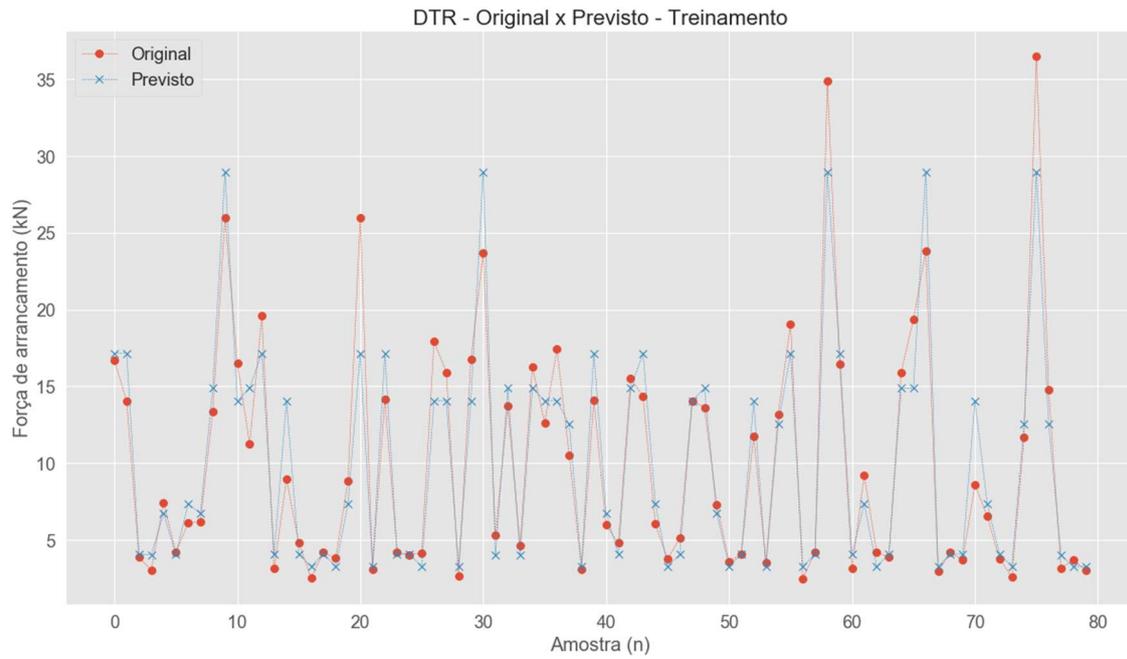
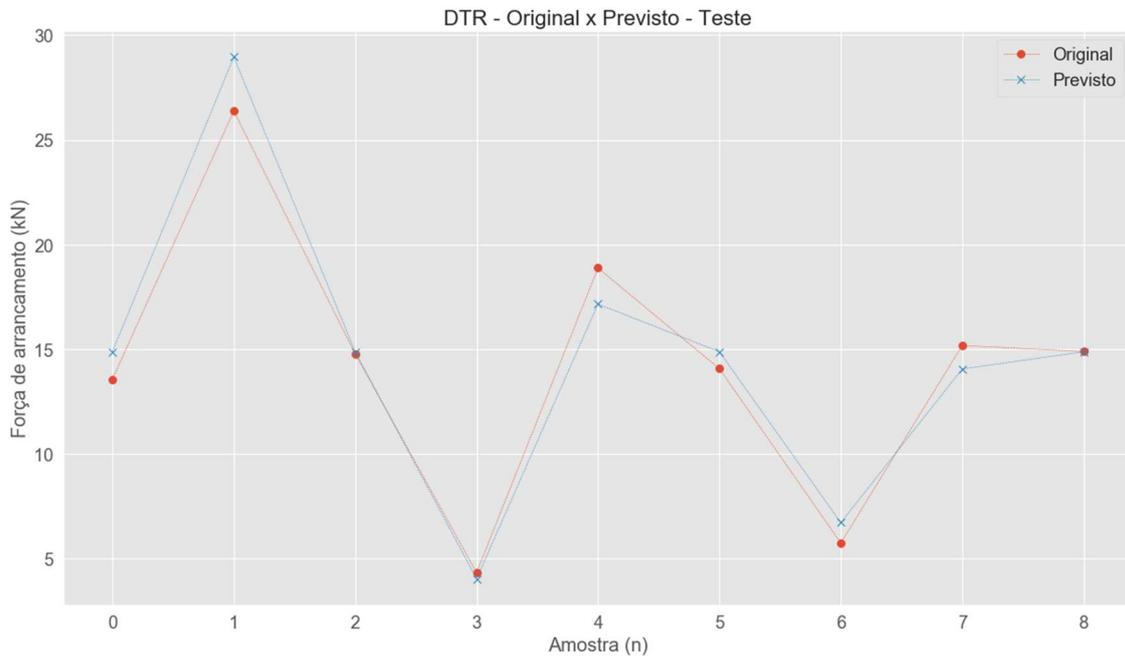
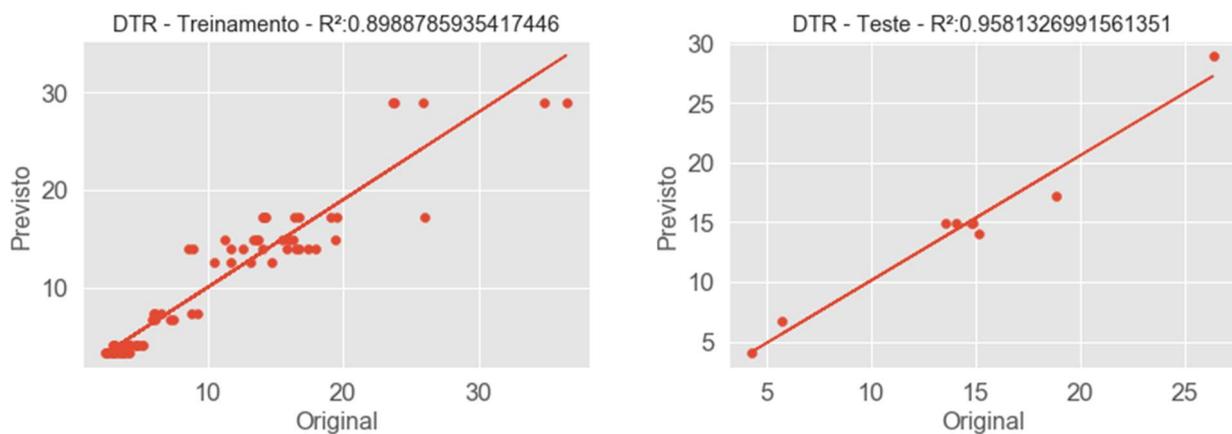


Figura 7.2: Resultados original *versus* previsto obtidos na implementação das árvores de decisão para a parcela de teste.



A Figura 7.3 apresenta a comparação entre os valores de  $R^2$  originais e previstos obtidos na implementação das árvores de decisão.

Figura 7.3: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das árvores de decisão para as parcelas de treinamento e teste.



### 7.1.2. FLORESTAS ALEATÓRIAS

Os parâmetros que apresentaram os melhores resultados e a variação de parâmetros implementada no modelo de florestas aleatórias estão descritos na Tabela 7.3.

Tabela 7.3: Variação de parâmetros e parâmetros utilizados na implementação das florestas aleatórias.

Parâmetro	Variação	Configuração utilizada
Função utilizada para medir a qualidade da divisão	mse-mae	mae
Profundidade máxima dos estimadores de regressão	3-10	6
Quantidade máxima de nós	80-120	100
Nº mínimo de amostras para dividir um nó interno	6-10	7
Nº máximo de características	auto-sqrt-log2	Auto
Nº mínimo de amostras para um nó de folha	1-5	1

Os parâmetros listados na Tabela 7.3 são descritos na Seção 3.2 e, como mencionado anteriormente, seus valores foram definidos através de hiperparametrização utilizando o *GridSearchCV*.

A Tabela 7.4 apresenta os parâmetros de desempenho obtidos a partir da implementação das florestas aleatórias.

Tabela 7.4: Erros médios obtidos com a implementação das florestas aleatórias.

Treinamento RMSE (kN)	Teste RMSE (kN)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
2,47	1,30	0,89	0,96

A Figura 7.4 e a Figura 7.5 mostram os valores originais e previstos para o conjunto de teste e treinamento, respectivamente, obtidos na implementação das florestas aleatórias.

Figura 7.4: Resultados original *versus* previsto obtidos na implementação das florestas aleatórias para a parcela de treinamento.

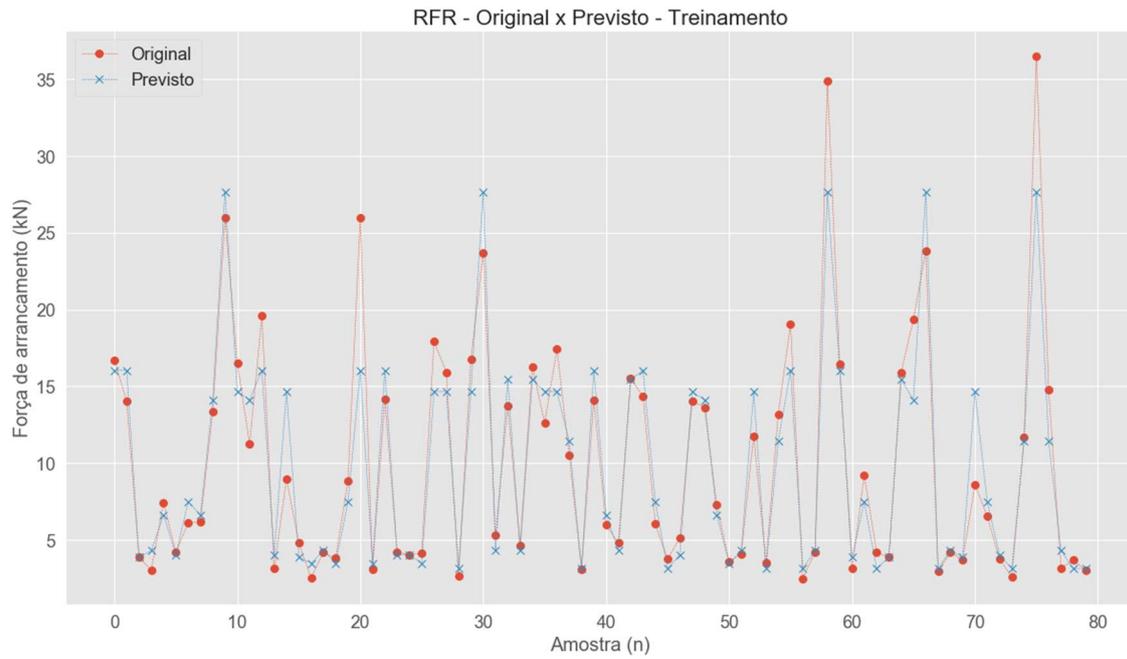
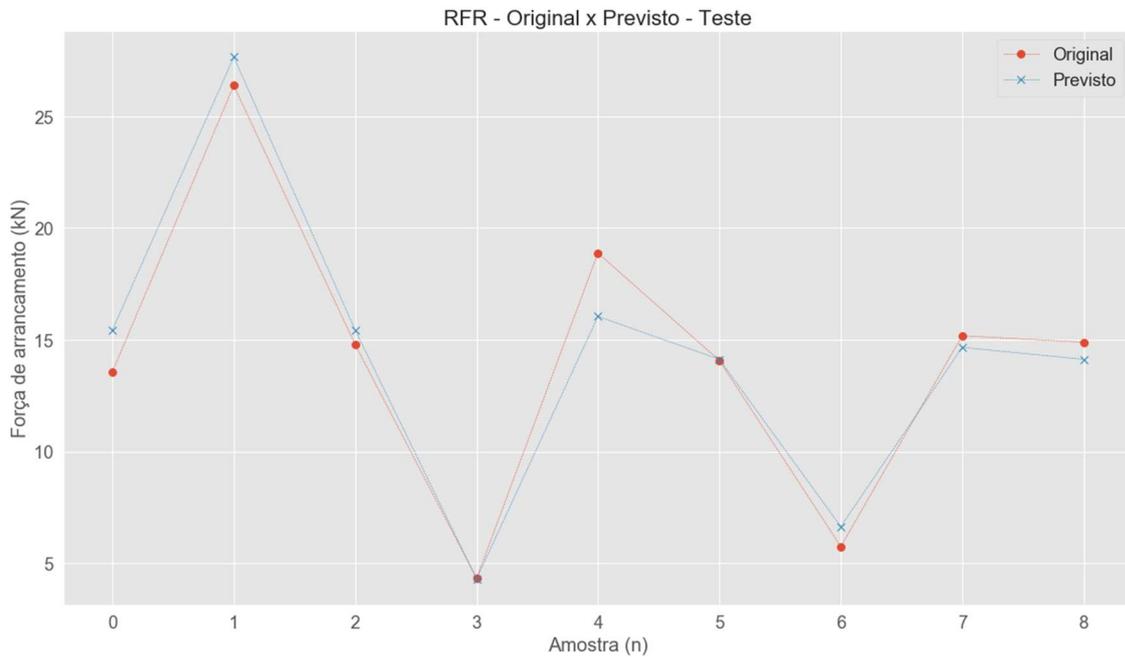
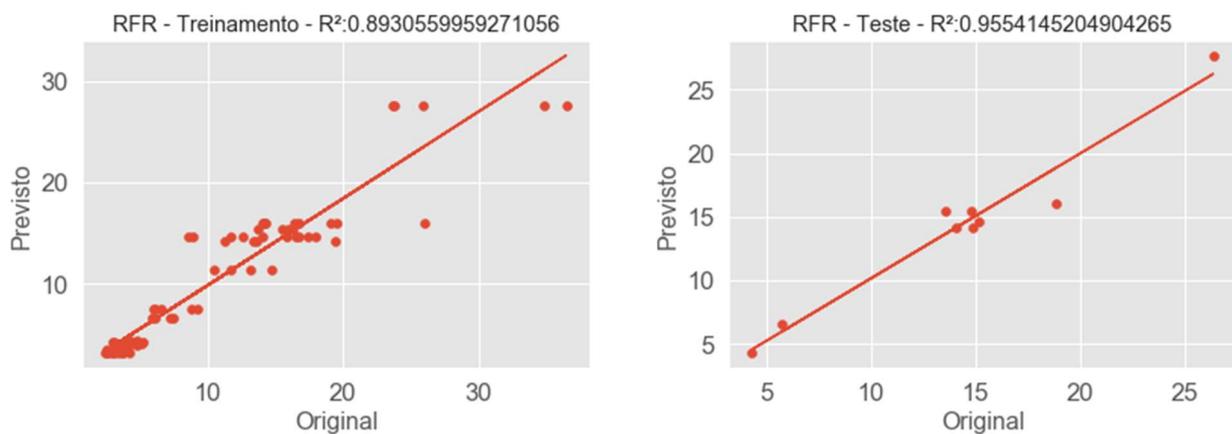


Figura 7.5: Resultados original *versus* previsto obtidos na implementação das florestas aleatórias para a parcela de teste.



A Figura 7.6 apresenta a comparação entre os valores de  $R^2$  originais e previstos obtidos na implementação das florestas aleatórias.

Figura 7.6: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das florestas aleatórias para as parcelas de treinamento e teste.



### 7.1.3. MÁQUINAS VETORIAIS DE SUPORTE

Os parâmetros que apresentaram os melhores resultados e a variação de parâmetros implementada no modelo de máquinas vetoriais de suporte estão descritos na Tabela 7.5.

Tabela 7.5: Variação de parâmetros e parâmetros utilizados na implementação das máquinas vetoriais de suporte.

<b>Parâmetro</b>	<b>Variação</b>	<b>Configuração utilizada</b>
<i>kernel</i>	rbf-linear-poly	rbf
<b>C</b>	50-500	500

Os parâmetros listados na Tabela 7.5 são descritos na Seção 3.3 e, como mencionado anteriormente, seus valores foram definidos através de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de desempenho obtidos a partir da implementação das máquinas vetoriais de suporte estão apresentados na Tabela 7.6.

Tabela 7.6: Erros médios obtidos com a implementação das máquinas vetoriais de suporte.

<b>Treinamento RMSE (kN)</b>	<b>Teste RMSE (kN)</b>	<b>Treinamento R<sup>2</sup></b>	<b>Teste R<sup>2</sup></b>
2,56	1,31	0,88	0,96

A Figura 7.7 e a Figura 7.8 mostram os valores originais e previstos para o conjunto de teste e treinamento, respectivamente, obtidos na implementação das máquinas vetoriais de suporte.

Figura 7.7: Resultados original *versus* previsto obtidos na implementação das máquinas vetoriais de suporte para a parcela de treinamento.

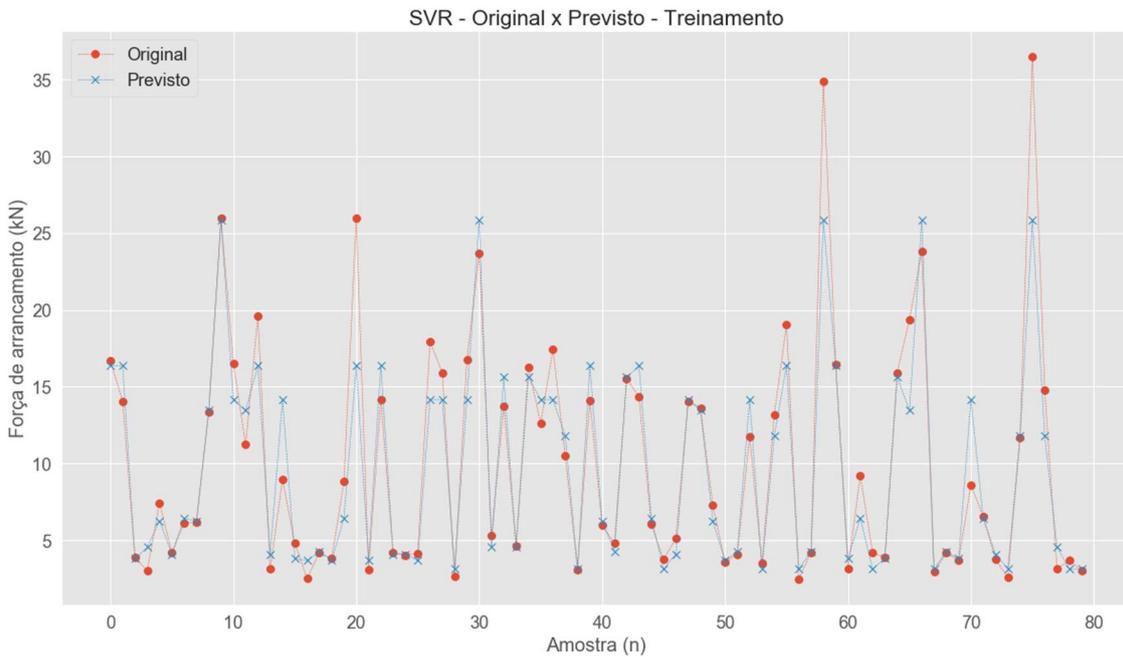
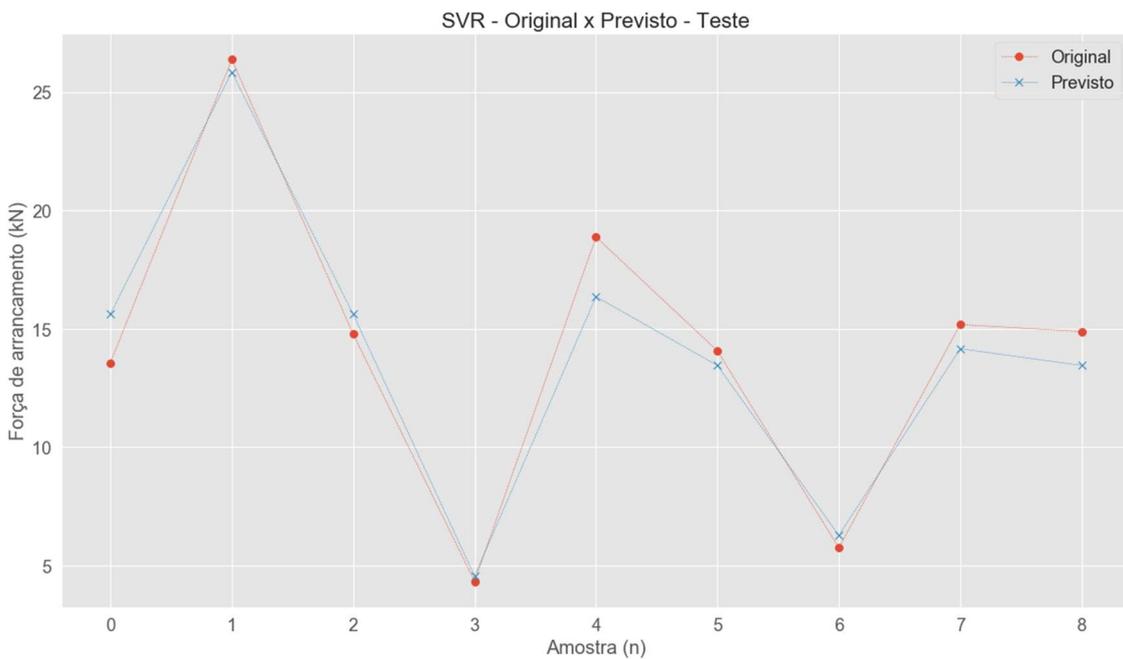
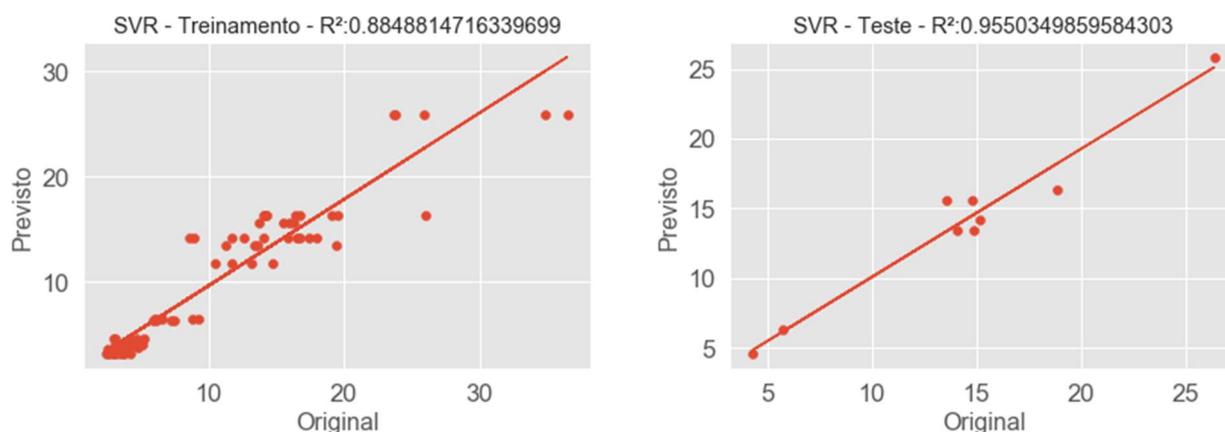


Figura 7.8: Resultados original *versus* previsto obtidos na implementação das máquinas vetoriais de suporte para a parcela de teste.



A Figura 7.9 apresenta a comparação entre os valores de  $R^2$  originais e previstos obtidos na implementação das máquinas vetoriais de suporte.

Figura 7.9: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das máquinas vetoriais de suporte para as parcelas de treinamento e teste.



#### 7.1.4. REDES NEURAIS ARTIFICIAIS

Os parâmetros que apresentaram os melhores resultados no modelo de redes neurais artificiais estão descritos na Tabela 7.7.

Tabela 7.7: Variação de parâmetros e parâmetros utilizados na implementação das redes neurais artificiais.

Parâmetro	Configuração utilizada
Quantidade de neurônios de camada de entrada	4
Número de camadas intermediárias	1
Quantidade de neurônios de camada de intermediária	10
Função de ativação	softplus-linear

Os parâmetros listados na Tabela 7.7 são descritos na Seção 3.4 e, como mencionado anteriormente, seus valores foram definidos através de hiperparametrização utilizando o *GridSearchCV*. Os parâmetros de desempenho obtidos a partir da implementação das redes neurais artificiais estão apresentados na Tabela 7.8.

Tabela 7.8: Erros médios obtidos com a implementação das redes neurais artificiais.

Treinamento RMSE (kN)	Teste RMSE (kN)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
2,54	1,16	0,87	0,96

A Figura 7.10 e a Figura 7.11 mostram os valores originais e previstos para o conjunto de teste e treinamento, respectivamente, obtidos na implementação das redes neurais artificiais.

Figura 7.10: Resultados original *versus* previsto obtidos na implementação das redes neurais artificiais para a parcela de treinamento.

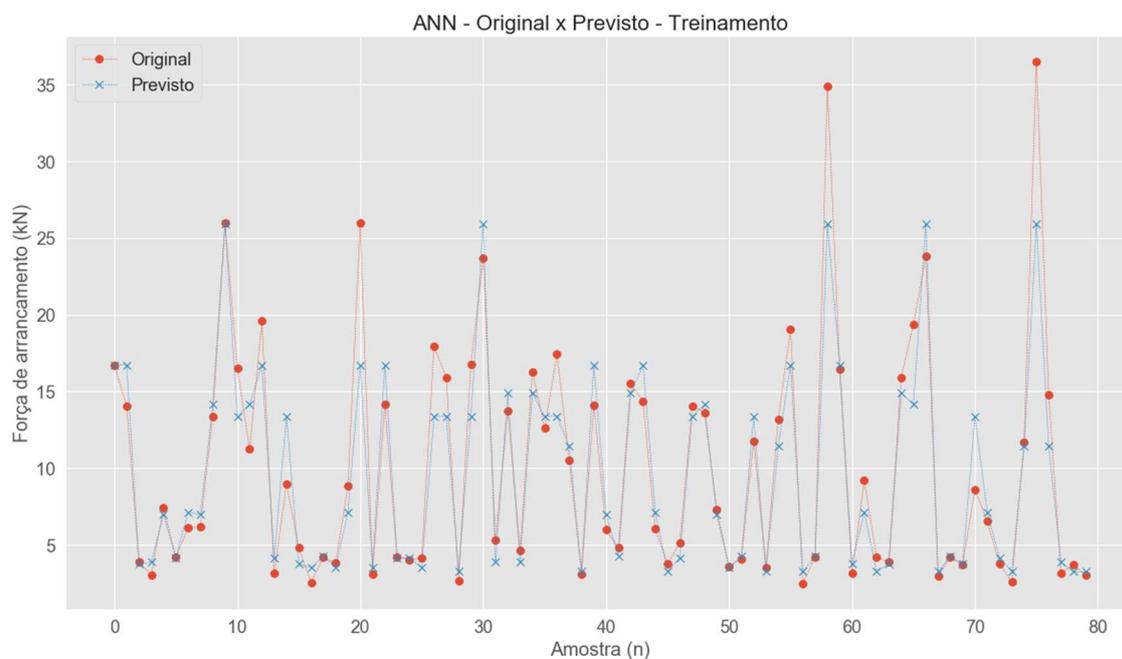
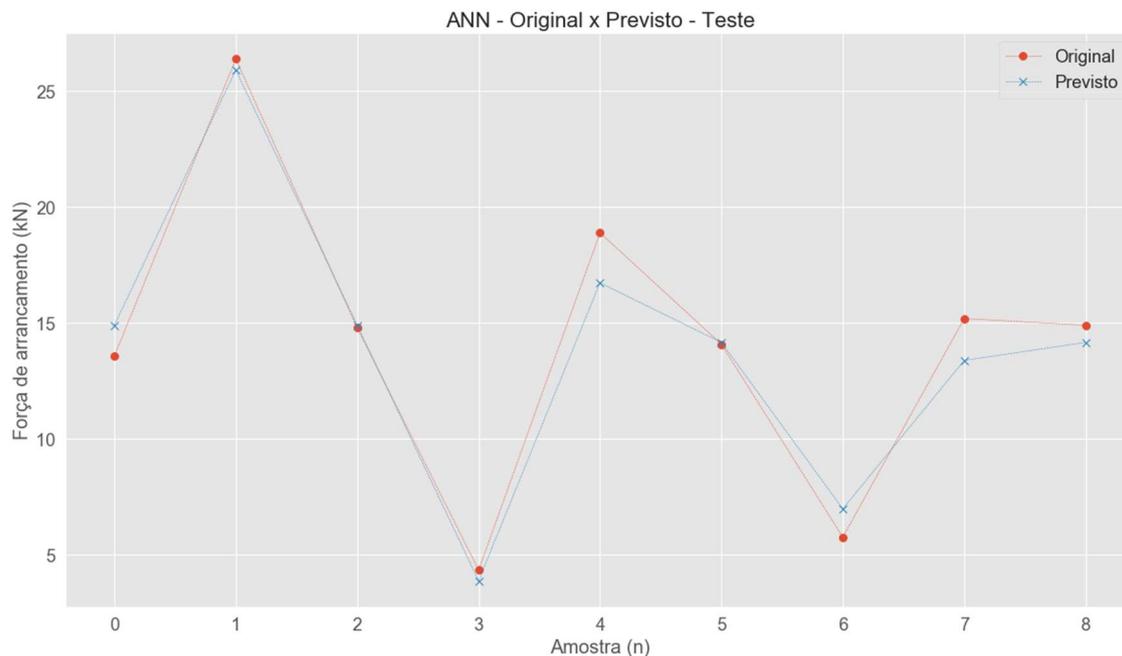
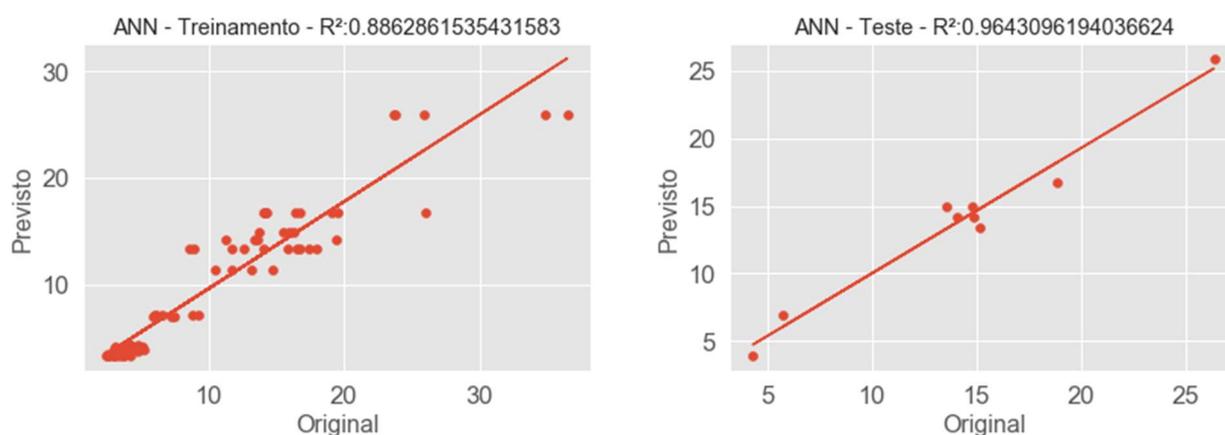


Figura 7.11: Resultados original *versus* previsto obtidos na implementação das redes neurais artificiais para a parcela de teste.



A Figura 7.12 apresenta a comparação entre os valores de  $R^2$  originais e previstos obtidos na implementação das redes neurais artificiais.

Figura 7.12: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das redes neurais artificiais para as parcelas de treinamento e teste.



### 7.1.5. REGRESSOR GRADIENTE *BOOSTING*

Os parâmetros que apresentaram os melhores resultados e a variação de parâmetros implementada no modelo de regressão por *boosting* gradiente estão descritos na Figura 7.9.

Tabela 7.9: Variação de parâmetros e parâmetros utilizados na implementação do regressor gradiente *boosting*.

Parâmetro	Variação	Configuração utilizada
Nº de estágios de <i>boosting</i> a serem realizados	230-300	230
Profundidade máxima dos estimadores de regressão	2-30	10
Nº mínimo de amostras para dividir um nó interno	10-500	50
Taxa de aprendizado	0,2-0,4	0,3

Os parâmetros listados na Figura 7.9 são descritos na Seção 3.5 e, como mencionado anteriormente, seus valores foram definidos através de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de desempenho obtidos a partir da implementação do modelo de regressão por *boosting* gradiente estão apresentados na Tabela 7.10.

Tabela 7.10: Erros médios obtidos com a implementação do regressor gradiente *boosting*.

Treinamento RMSE (kN)	Teste RMSE (kN)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
2,39	1,32	0,90	0,95

A Figura 7.13 e a Figura 7.14 mostram os valores originais e previstos para o conjunto de teste e treinamento, respectivamente, obtidos na implementação do modelo de regressão por *boosting* gradiente.

Figura 7.13: Resultados original *versus* previsto obtidos na implementação do regressor gradiente *boosting* para a parcela de treinamento.

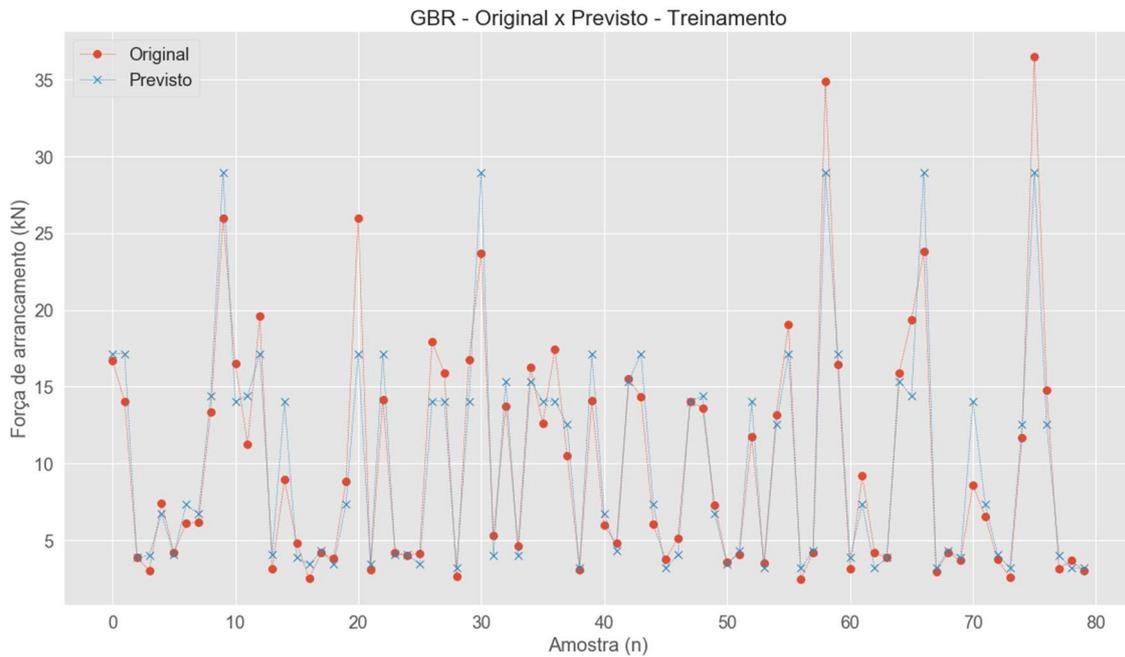
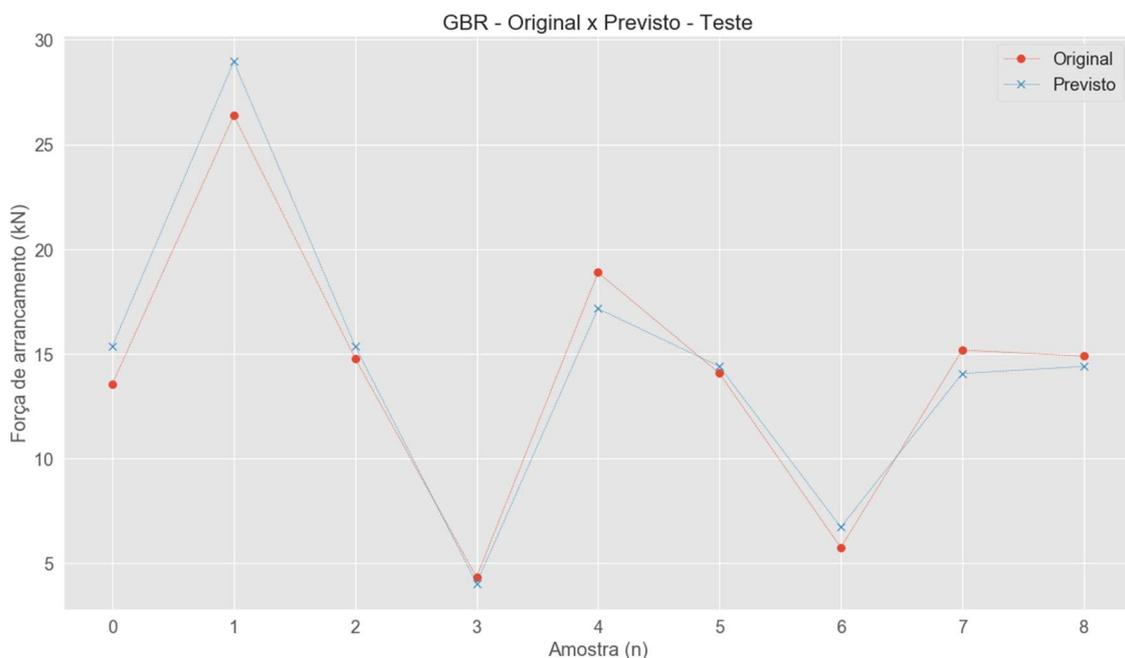
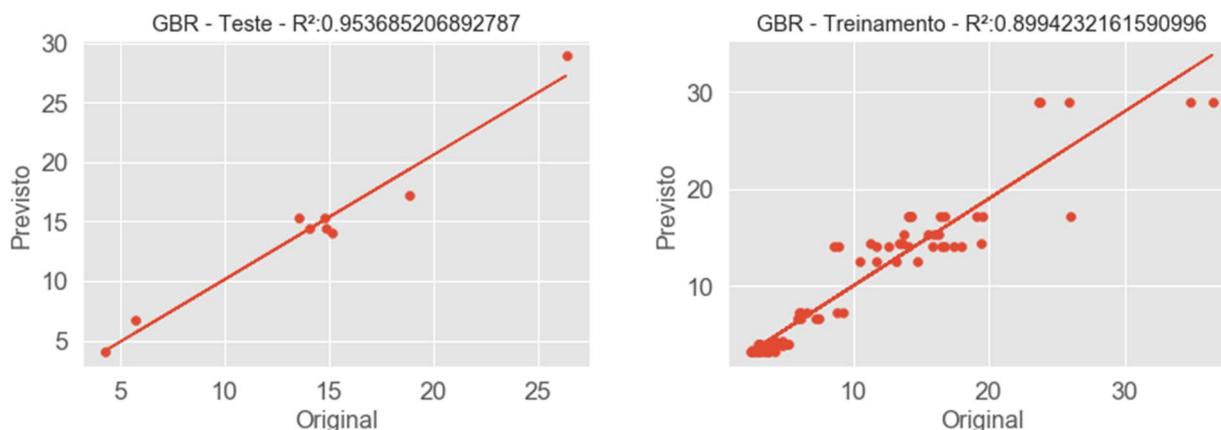


Figura 7.14: Resultados original *versus* previsto com a implementação de regressor gradiente *boosting* para a parcela de teste.



A Figura 7.15 apresenta a comparação entre os valores de  $R^2$  originais e previstos obtidos na implementação do modelo de regressão por *boosting* gradiente.

Figura 7.15: Resultados de  $R^2$  original versus previsto com a implementação do regressor gradiente *boosting* para as parcelas de treinamento e teste.



## 7.2. EQUAÇÕES EMPÍRICAS

Para comparar os resultados obtidos, calculou-se a força de arrancamento utilizando a Equação (2.2) (CEB, 2010) apresentada anteriormente, considerando a base de Carvalho *et al.* (2017), somente para barras nervuradas, conforme a norma. Após as devidas correções nas unidades utilizadas, foi gerado o gráfico apresentado na Figura 7.16, que relaciona a força de arrancamento obtida experimentalmente com a força de arrancamento obtida por meio da equação empírica fornecida pelo código normativo.

Já na Figura 7.17 até a Figura 7.21, estão representados os resultados obtidos nos modelos de inteligência computacional comparados com os valores obtidos por meio do CEB 2010. Para uma análise mais detalhada dos resultados obtidos, destacou-se na figura o diâmetro ( $d$ ) das barras e o comprimento de ancoragem ( $l_d$ ). Esses valores estão presentes nos pontos correspondentes. As barras utilizadas na análise possuem diâmetros de 6,3 mm, 8,0 mm e 10 mm, enquanto que os comprimentos de ancoragem variam entre 5 mm e 10 mm.

Figura 7.16: Resultados de força de arrancamento *versus* resistência à compressão do concreto para os valores obtidos experimentalmente e o CEB (2010).

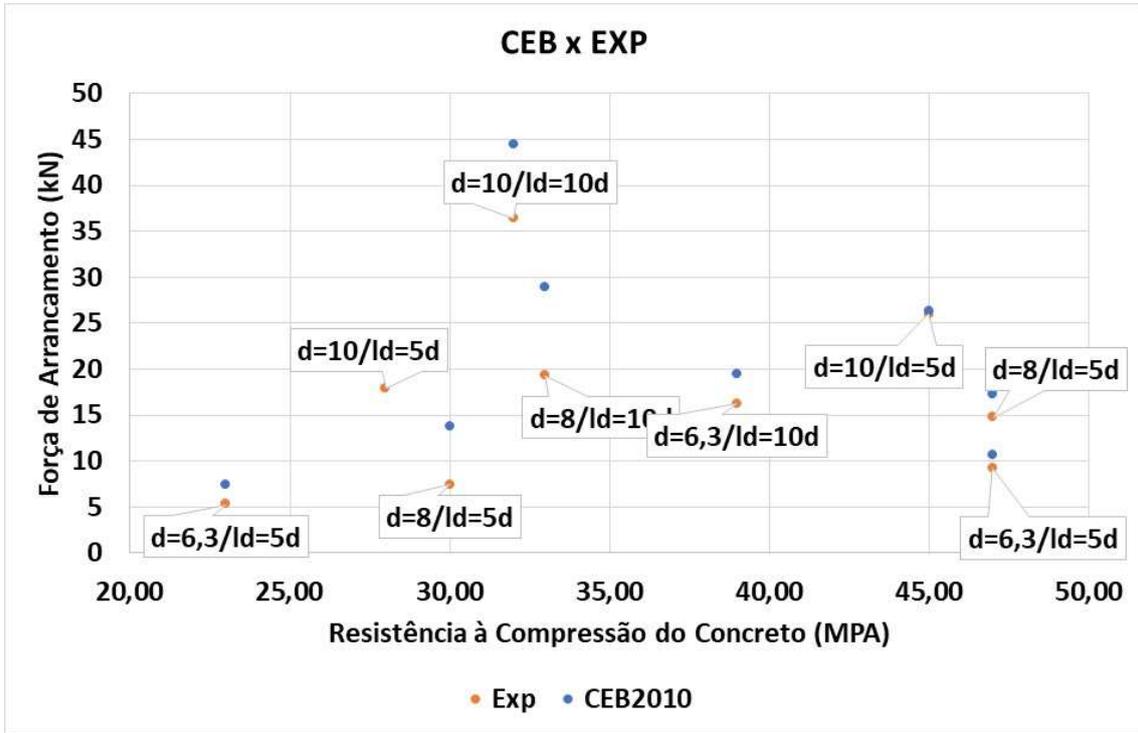


Figura 7.17: Resultados de força de arrancamento *versus* resistência à compressão do concreto para os valores obtidos no modelo de árvores de decisão (DTR) e o CEB (2010).

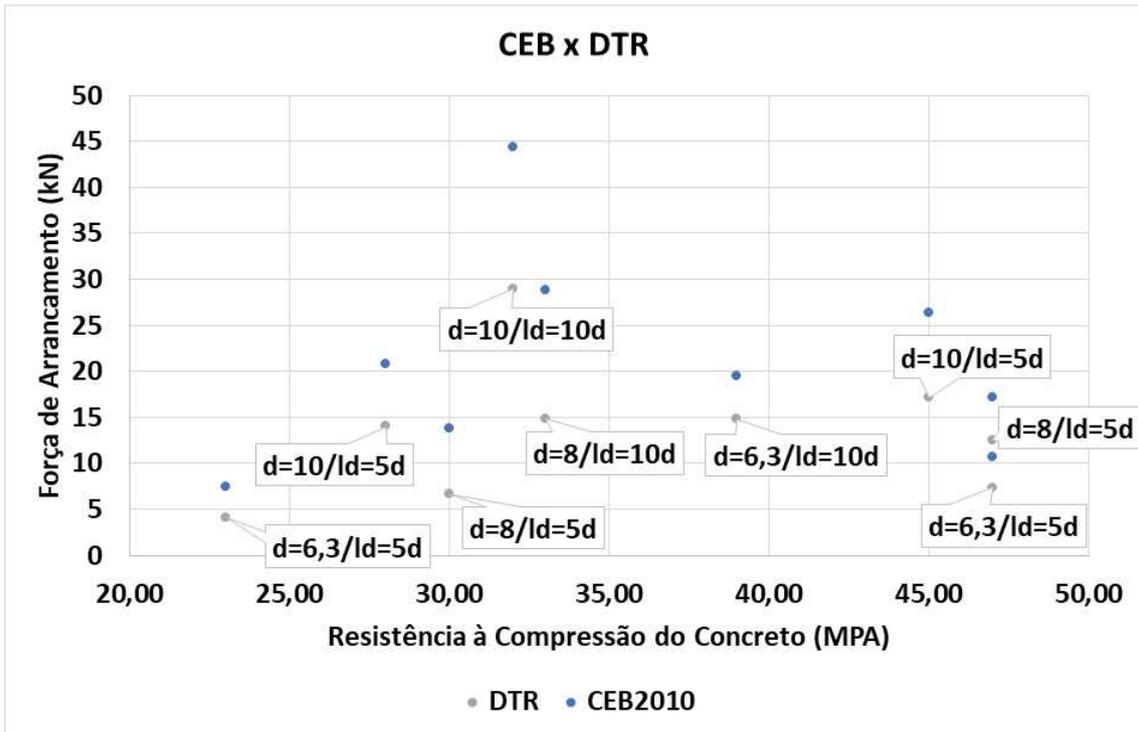


Figura 7.18: Resultados de força de arrancamento *versus* resistência à compressão do concreto para os valores obtidos no modelo de florestas aleatórias (RFR) e o CEB (2010).

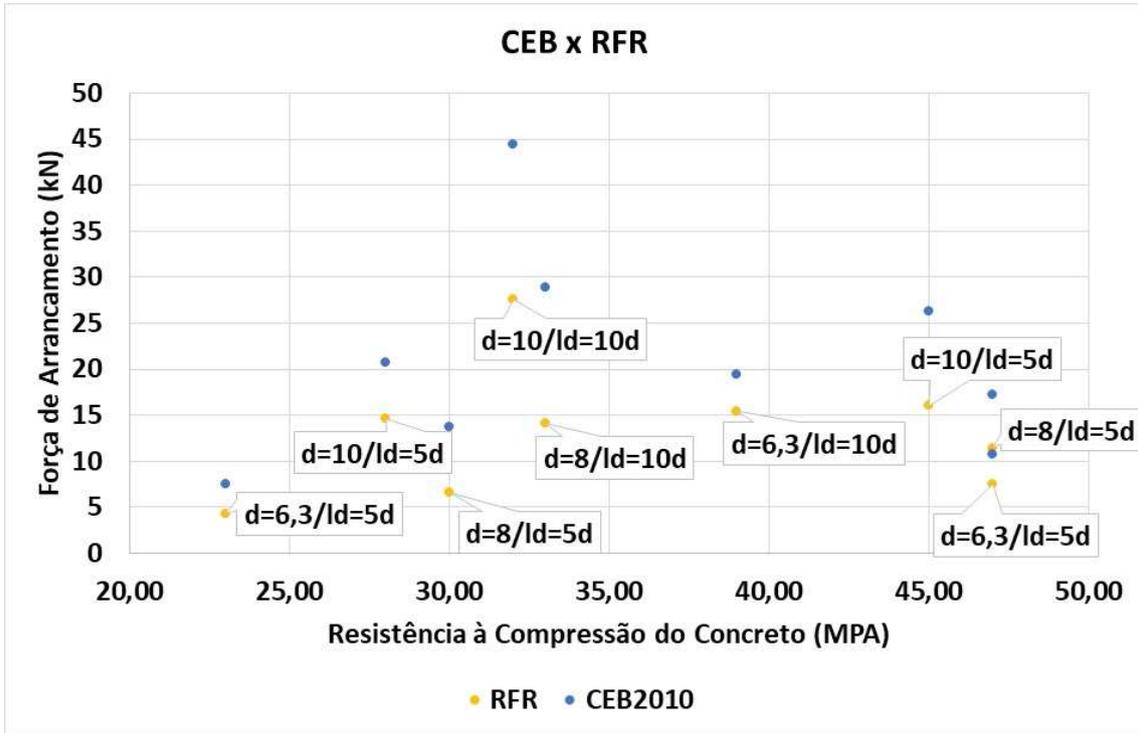


Figura 7.19: Resultados de força de arrancamento *versus* resistência à compressão do concreto para os valores obtidos no modelo de máquinas vetoriais de suporte (SVM) e o CEB (2010).

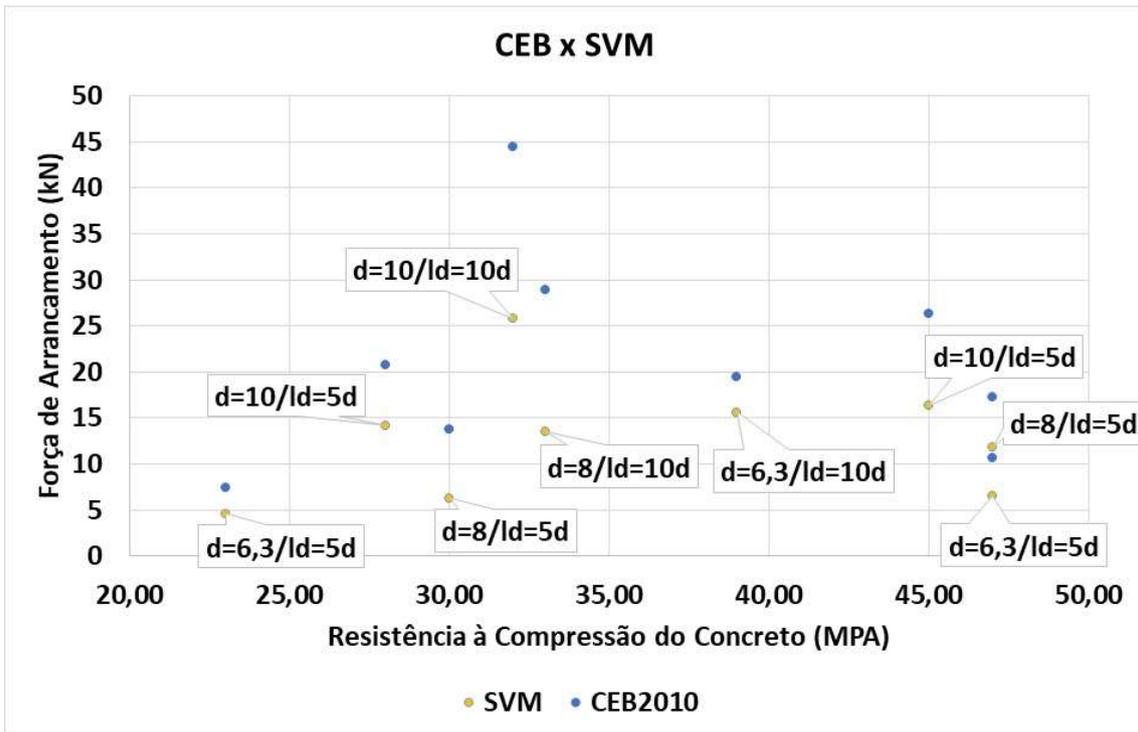


Figura 7.20: Resultados de força de arrancamento versus resistência à compressão do concreto para os valores obtidos no modelo de redes neurais (ANN) e o CEB (2010).

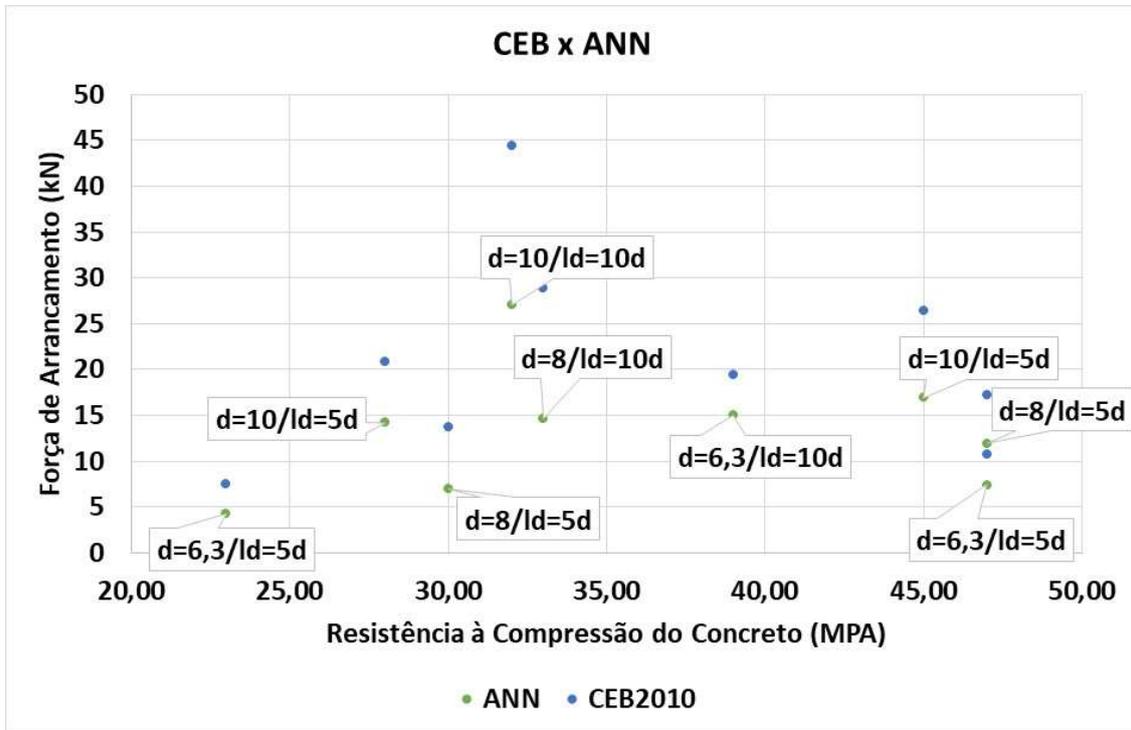
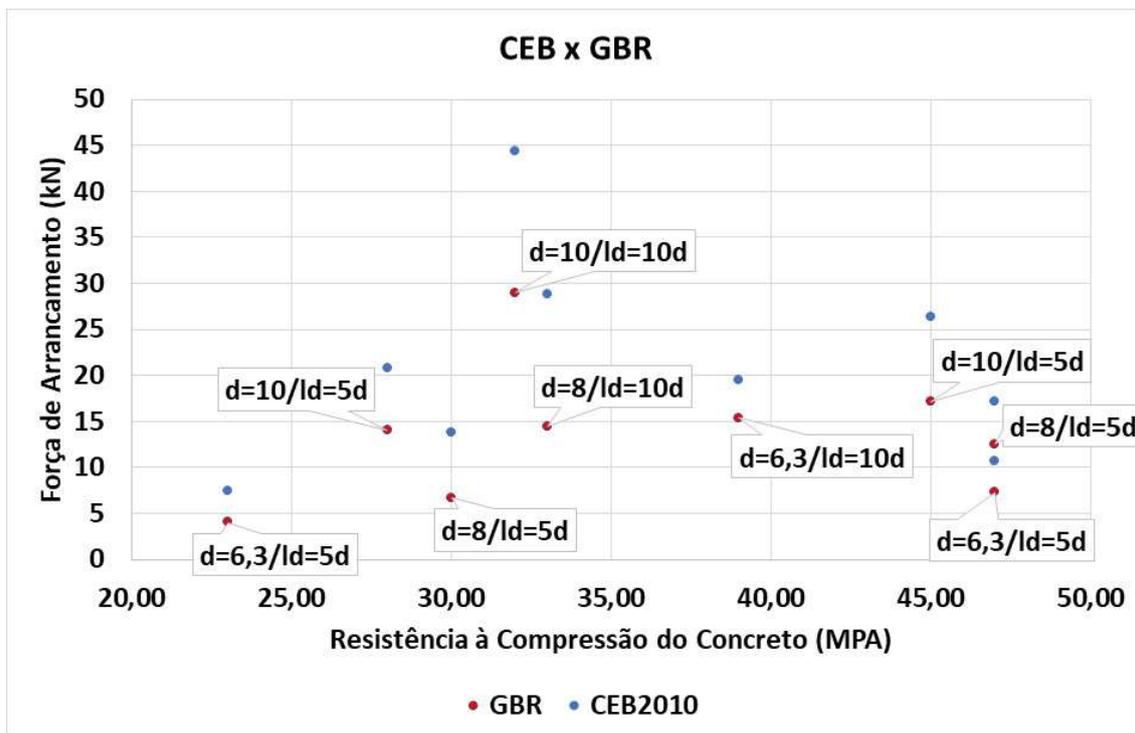


Figura 7.21: Resultados de força de arrancamento versus resistência à compressão do concreto para os valores obtidos no modelo de regressor gradiente *boosting* (GBR) e CEB (2010).



### 7.3. BASE DE DADOS AMPLIADA

Nesta seção, foram realizadas duas etapas de análise. Na primeira etapa, utilizou-se os resultados de força de arrancamento obtidos com os algoritmos treinados com a base de Carvalho *et al.* (2017) e comparou-se com os resultados de força de arrancamento obtidos por meio dos ensaios experimentais da base ampliada, apresentada na Subseção 5.2.4, com o objetivo de avaliar a adaptabilidade dos modelos. Na segunda etapa, a base de dados ampliada foi utilizada para o treinamento do algoritmo de inteligência computacional. A seguir, são apresentados os resultados obtidos.

#### 7.3.1. ETAPA 1:

A Tabela 7.11. apresenta os valores dos parâmetros de desempenho obtidos com cada um dos métodos computacionais treinados com a base de Carvalho *et al.* (2017) e testados com a base ampliada. Esses valores são importantes para avaliar a capacidade de adaptação dos modelos em relação à base de dados ampliada.

Tabela 7.11: Valores de RMSE obtidos através dos métodos computacionais treinados com a base de Carvalho *et al.* (2017) e testados com a base ampliada, em kN.

<b>DTR</b>	<b>RFR</b>	<b>SVM</b>	<b>ANN</b>	<b>GBR</b>
7,03	6,94	9,62	8,56	7,00

É importante destacar que, como mencionado anteriormente, neste estudo, as bases de Nogueira (2018), França (2004), Fernandes (2000) e Almeida Filho (2006) foram utilizadas em sua totalidade, com todos os ensaios, enquanto que as demais bases utilizam as médias dos valores de força de arrancamento, considerando grupos de ensaios experimentais separados por diâmetro da barra e resistência à compressão do concreto do corpo de prova. Para os gráficos de valores originais *versus* previstos apresentados abaixo, para as bases que incluem todos os valores de ensaios (ou seja, aquelas que apresentam valores repetidos de entrada), os resultados apresentados consideram a média dos valores de força de arrancamento obtidos em cada grupo de ensaio experimental.

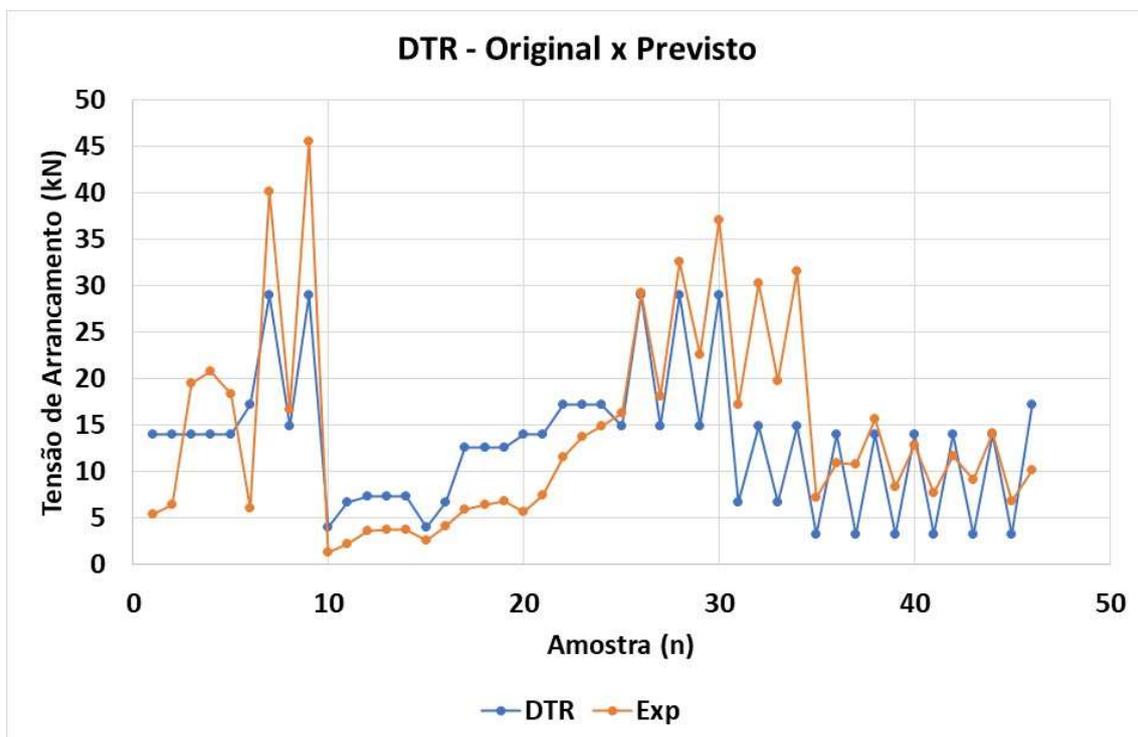
Como a base de dados utilizada no treinamento dos algoritmos apresentados nesta etapa do trabalho não inclui valores de entrada correspondentes à resistência à compressão do concreto da base de dados ampliada testada aqui, era esperado que os valores de  $R^2$  obtidos não

apresentassem correlação entre os valores obtidos pelos métodos computacionais e os valores experimentais. Portanto, esses resultados não foram apresentados.

- **ÁRVORES DE DECISÃO**

Na Figura 7.22 são apresentados os valores originais e previstos obtidos na implementação das árvores de decisão.

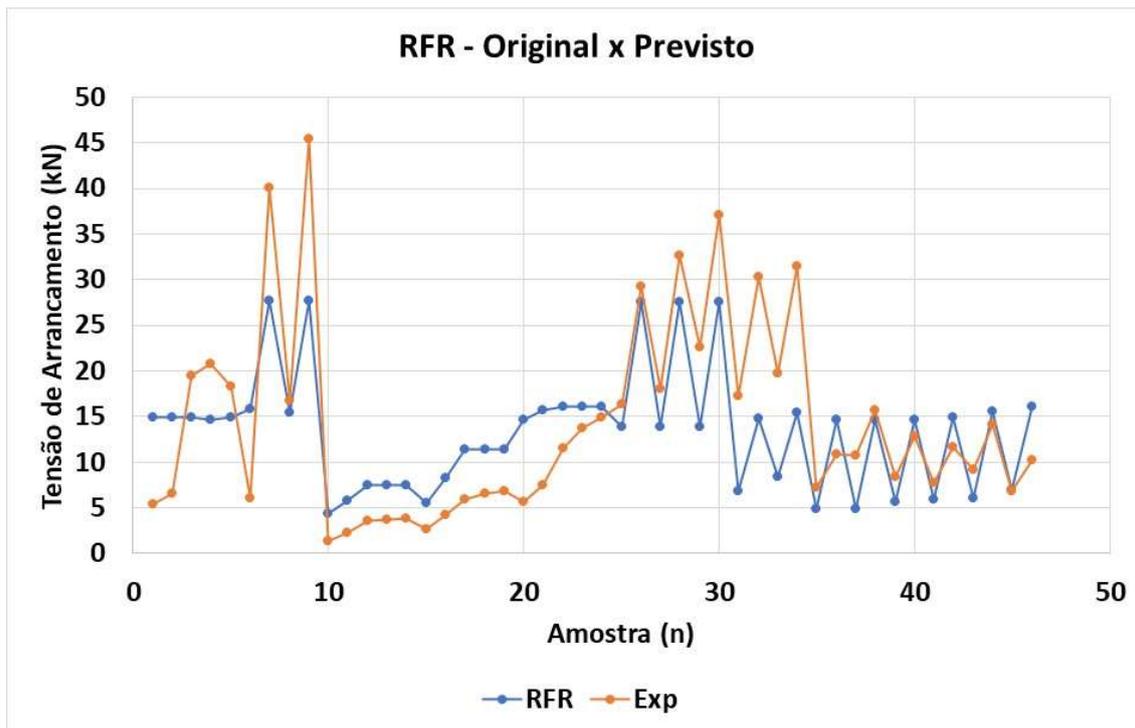
Figura 7.22: Resultados original *versus* previsto obtidos na implementação das árvores de decisão.



- FLORESTAS ALEATÓRIA

Na Figura 7.23 são apresentados os valores originais e previstos obtidos na implementação das florestas aleatórias.

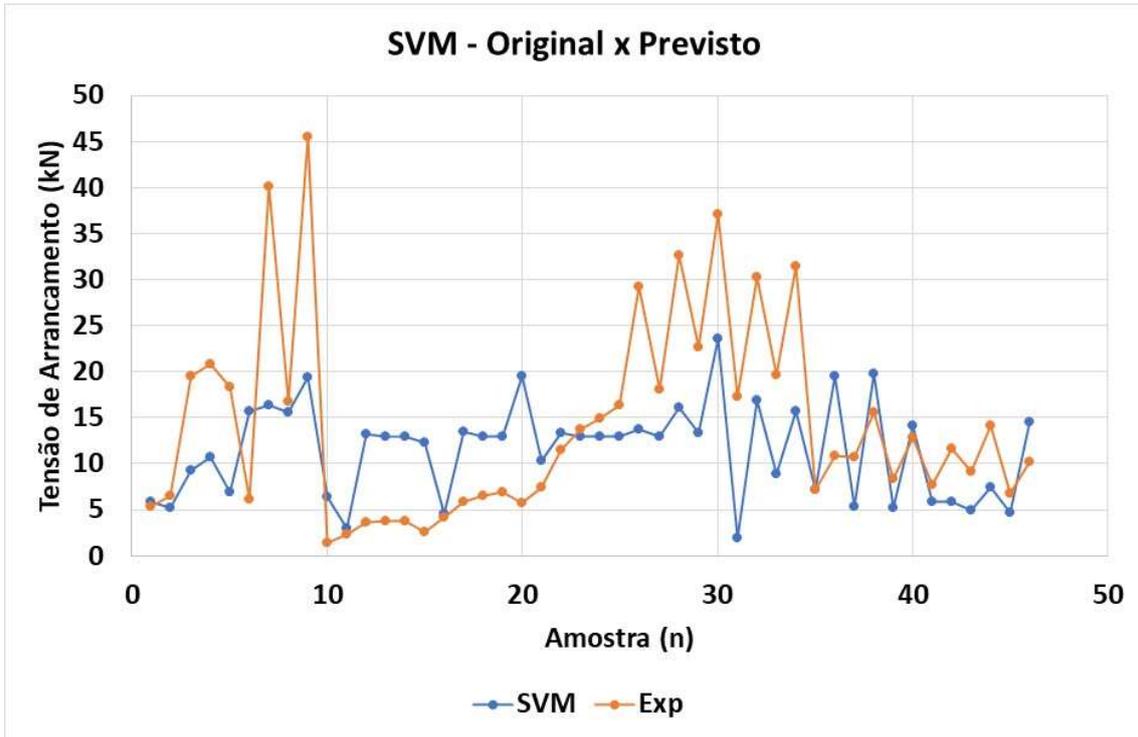
Figura 7.23: Resultados original *versus* previsto obtidos na implementação das florestas aleatórias.



- MÁQUINAS VETORIAIS DE SUPORTE

Na Figura 7.24 são apresentados os valores originais e previstos obtidos na implementação das máquinas vetoriais de suporte.

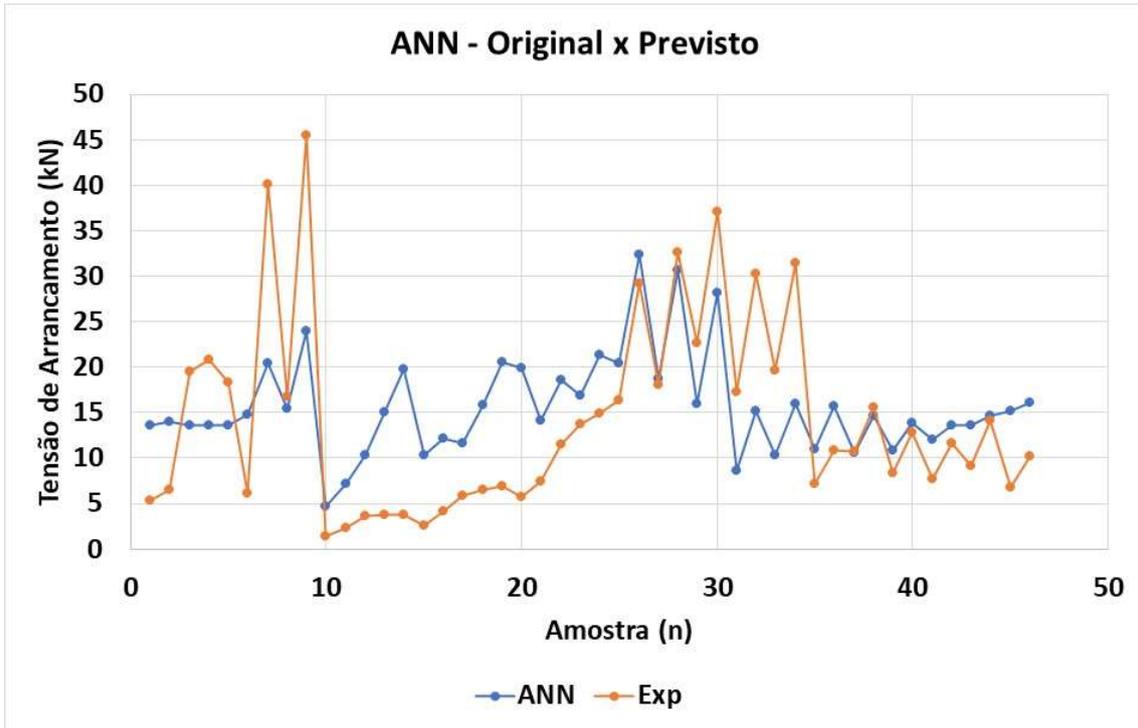
Figura 7.24: Resultados original *versus* previsto obtidos na implementação das máquinas vetoriais de suporte.



- REDES NEURAIS ARTIFICIAIS

Na Figura 7.25 são apresentados os valores originais e previstos obtidos na implementação das redes neurais artificiais.

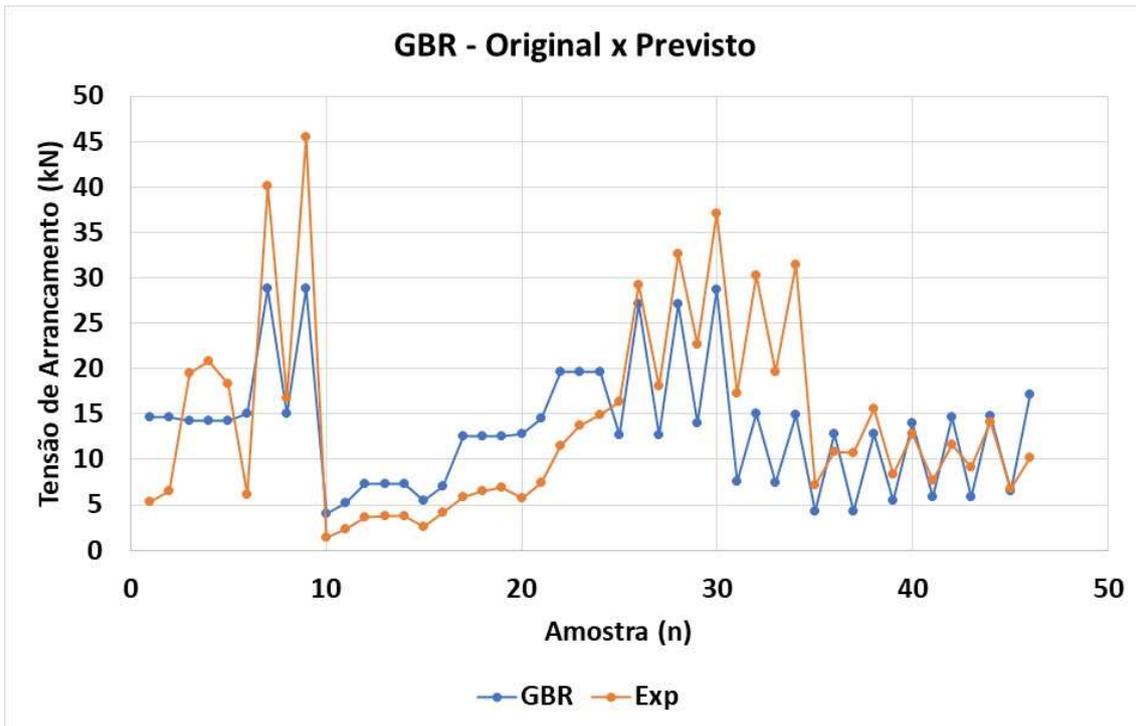
Figura 7.25: Resultados original *versus* previsto obtidos na implementação das redes neurais artificiais.



- **REGRESSOR GRADIENTE *BOOSTING***

Na Figura 7.26 são apresentados os valores originais e previstos obtidos na implementação do regressor gradiente *boosting*.

Figura 7.26: Resultados original *versus* previsto obtidos com a implementação de regressor gradiente *boosting* para a parcela de teste.



### 7.3.2. ETAPA 2:

Nesta etapa, o algoritmo foi treinado com toda a base de dados ampliada. Os parâmetros de desempenho obtidos são apresentados a seguir.

- **ÁRVORES DE DECISÃO**

Para o modelo de árvores de decisão, a variação de parâmetros implementada e os parâmetros que apresentaram os melhores resultados estão descritos na Tabela 7.12.

Tabela 7.12: Variação de parâmetros e parâmetros utilizados na implementação das árvores de decisão.

<b>Parâmetro</b>	<b>Variação</b>	<b>Configuração utilizada</b>
<b>Função utilizada para medir a qualidade da divisão</b>	mse-mae	mse
<b>Profundidade máxima dos estimadores de regressão</b>	None-3	None
<b>Nº máximo de características</b>	None-3	None
<b>Nº mínimo de amostras para um nó de folha</b>	1-5	1
<b>Nº mínimo de amostras para dividir um nó interno</b>	2-30	2

Os parâmetros listados na Tabela 7.12 são descritos na Seção 3.2 e, como mencionado anteriormente, os valores desses parâmetros foram determinados por meio de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de desempenho obtidos a partir da implementação das árvores de decisão são apresentados na Tabela 7.13.

Tabela 7.13: Erros médios obtidos com a implementação das árvores de decisão.

<b>Treinamento RMSE (kN)</b>	<b>Teste RMSE (kN)</b>	<b>Treinamento R<sup>2</sup></b>	<b>Teste R<sup>2</sup></b>
1,98	2,14	0,96	0,97

Na Figura 7.27 e na Figura 7.28 são apresentados os valores originais e previstos obtidos na implementação das árvores de decisão, para teste e treinamento, respectivamente.

Figura 7.27: Resultados original *versus* previsto obtidos na implementação das árvores de decisão para a parcela de treinamento.

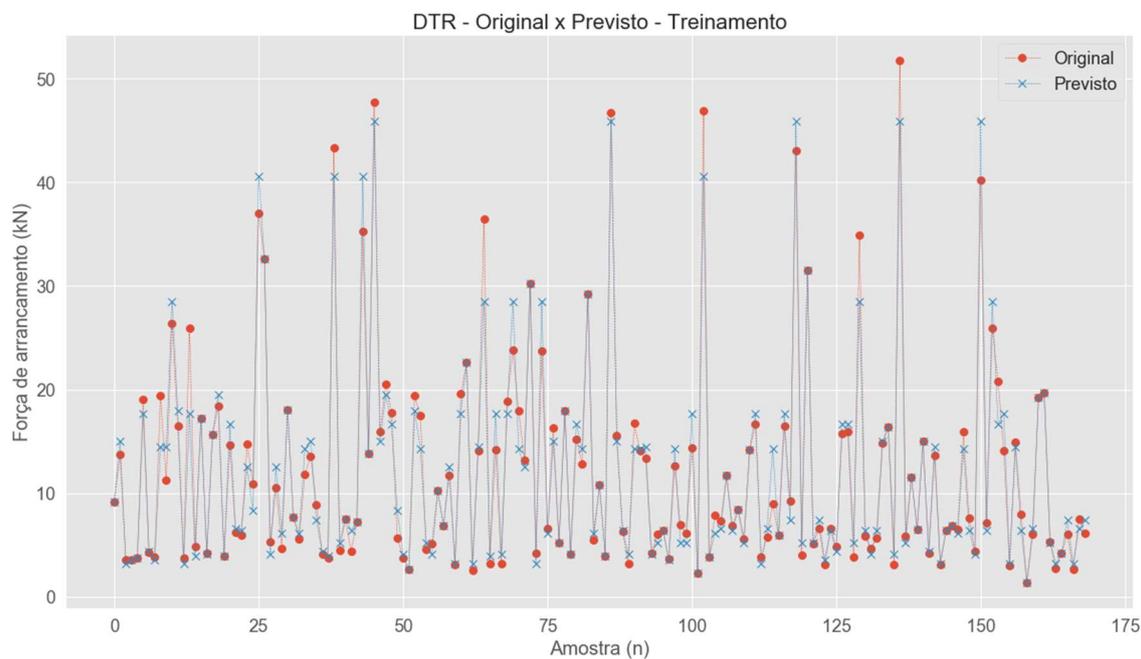
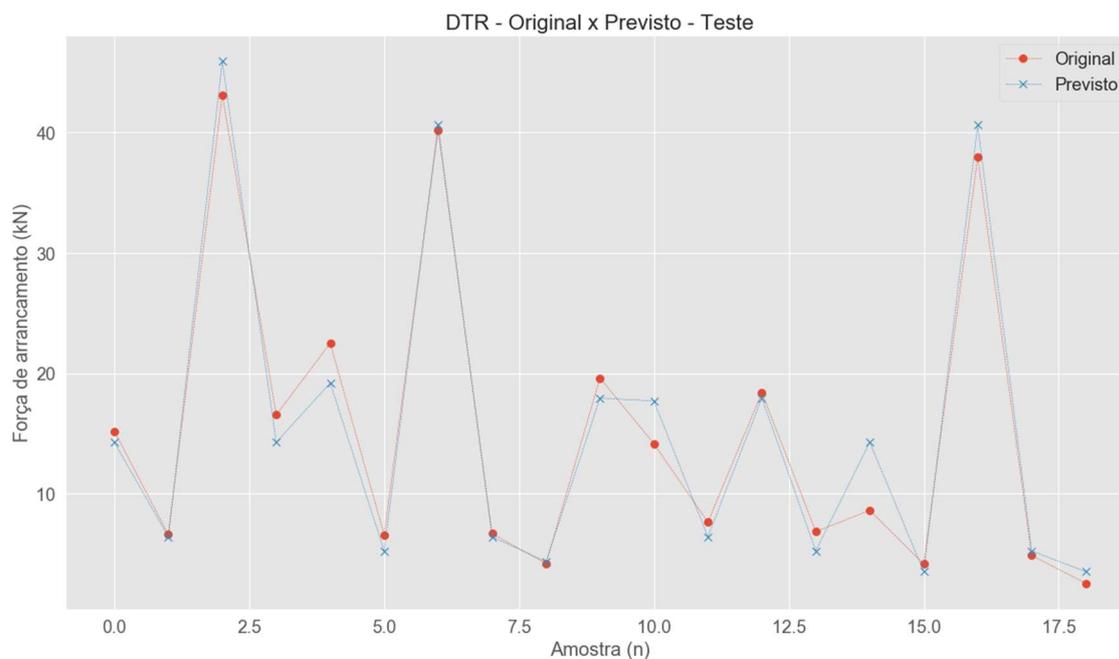
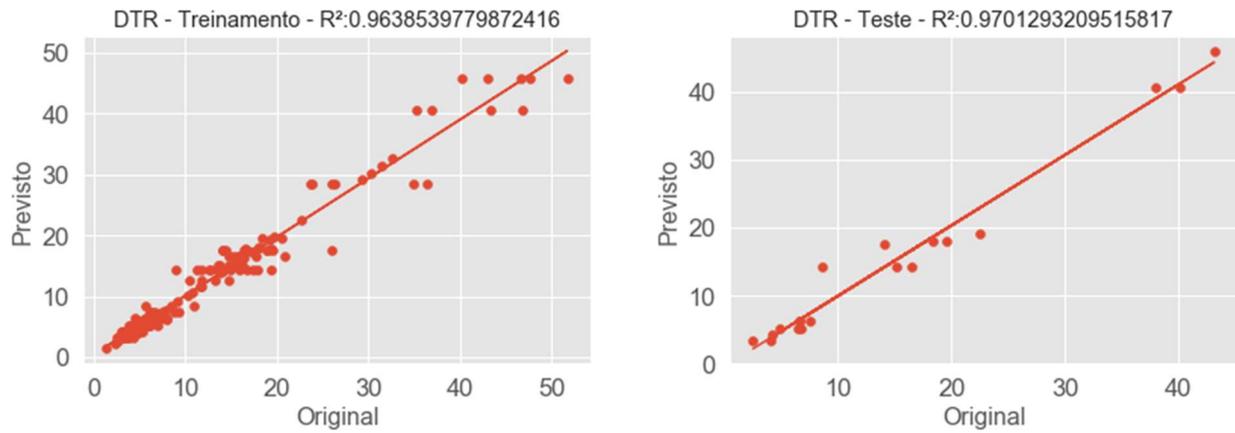


Figura 7.28: Resultados original *versus* previsto obtidos na implementação das árvores de decisão para a parcela de teste.



Na Figura 7.29 são apresentados os valores de  $R^2$  original *versus* previsto obtidos na implementação das árvores de decisão.

Figura 7.29: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das árvores de decisão para as parcelas de treinamento e teste.



- FLORESTAS ALEATÓRIA

Para o modelo de florestas aleatórias, a variação de parâmetros implementada e os parâmetros que apresentaram os melhores resultados estão descritos na Tabela 7.14.

Tabela 7.14: Variação de parâmetros e parâmetros utilizados na implementação das florestas aleatórias.

Parâmetro	Variação	Configuração utilizada
Função utilizada para medir a qualidade da divisão	mse-mae	mse
Profundidade máxima dos estimadores de regressão	3-10	8
Quantidade máxima de nós	80-120	100
Nº mínimo de amostras para dividir um nó interno	6-10	7
Nº máximo de características	auto-sqrt-log2	Auto
Nº mínimo de amostras para um nó de folha	1-5	1

Os parâmetros apresentados na Tabela 7.14 estão descritos na Seção 3.2 e, conforme dito anteriormente, os valores desses parâmetros foram definidos por meio de hiperparametrização utilizando o *GridSearchCV*.

Os parâmetros de performance obtidos por meio da implementação das florestas aleatórias estão apresentados na Tabela 7.15.

Tabela 7.15: Erros médios obtidos com a implementação das florestas aleatórias.

Treinamento RMSE (kN)	Teste RMSE (kN)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
2,42	2,35	0,94	0,96

Na Figura 7.30 e na Figura 7.31 são apresentados os valores originais e previstos para teste e treinamento, respectivamente, obtidos na implementação das florestas aleatórias.

Figura 7.30: Resultados original *versus* previsto obtidos na implementação das florestas aleatórias para a parcela de treinamento.

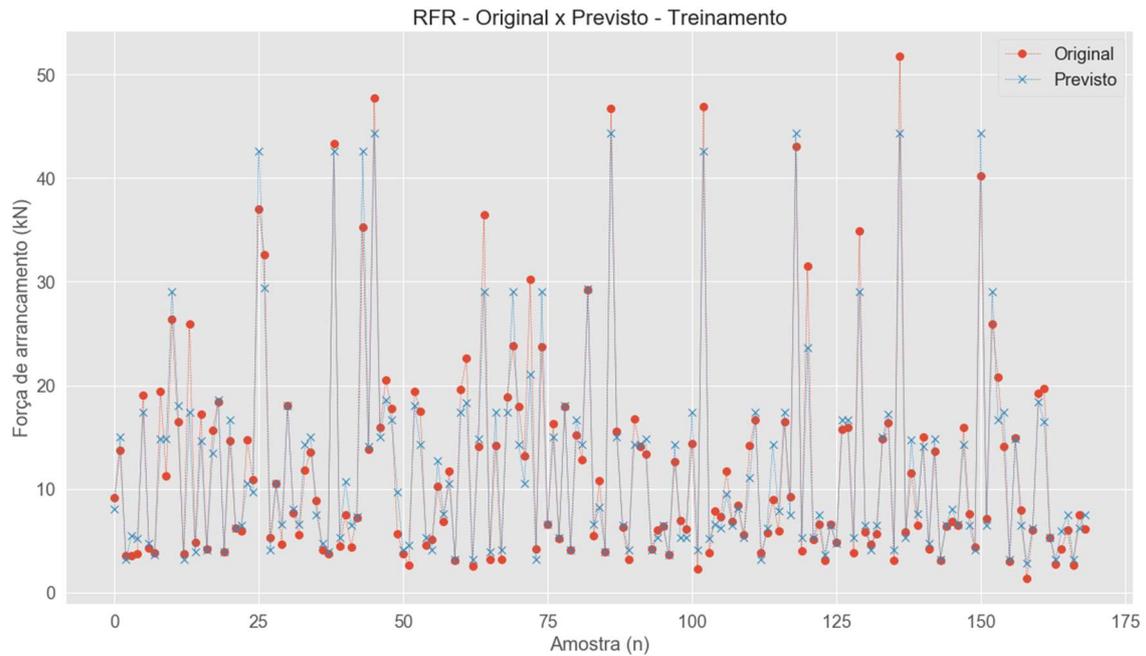
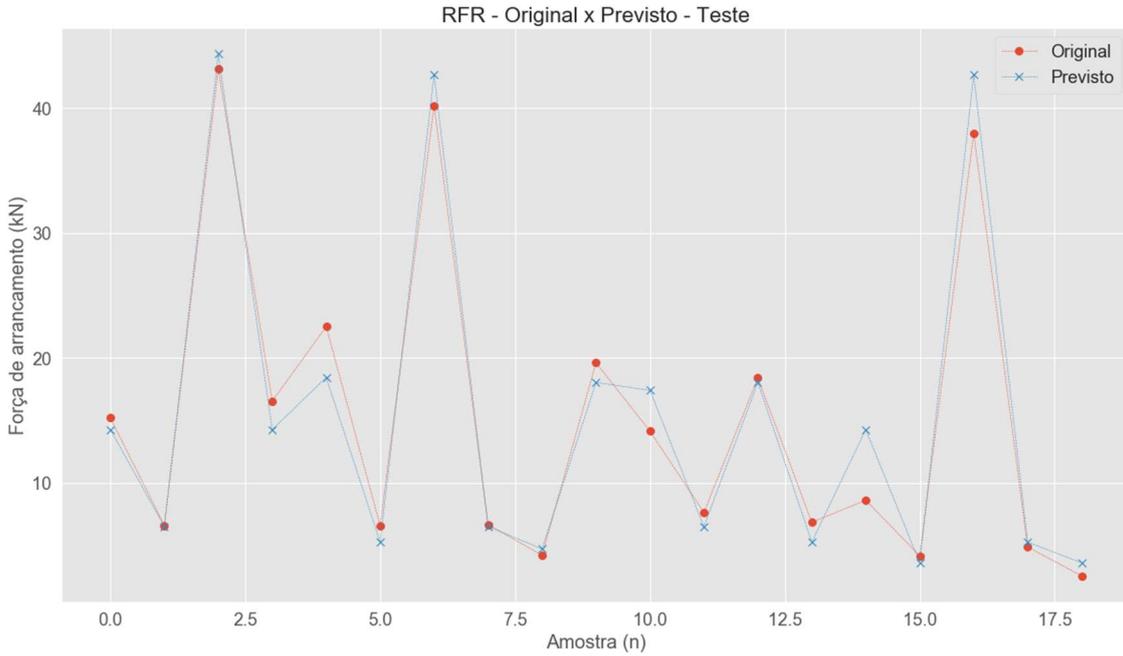
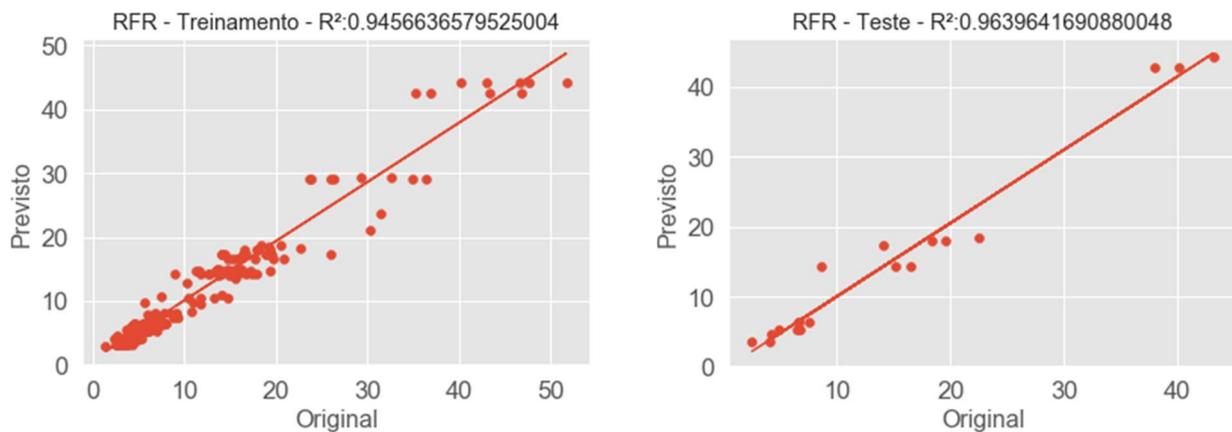


Figura 7.31: Resultados original *versus* previsto obtidos na implementação das florestas aleatórias para a parcela de teste.



Na Figura 7.32 são apresentados os valores de  $R^2$  original *versus* previsto obtidos na implementação das florestas aleatórias.

Figura 7.32: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das florestas aleatórias para as parcelas de treinamento e teste.



- **MÁQUINAS VETORIAIS DE SUPORTE**

Para o modelo de máquinas vetoriais de suporte, a variação de parâmetros implementada e os parâmetros que apresentaram os melhores resultados estão descritos na Tabela 7.16.

Tabela 7.16: Variação de parâmetros e parâmetros utilizados na implementação das máquinas vetoriais de suporte.

<b>Parâmetro</b>	<b>Variação</b>	<b>Configuração utilizada</b>
<b><i>kernel</i></b>	rbf-linear-poly	rbf
<b>C</b>	50-500	100

Os parâmetros apresentados na Tabela 7.16 estão descritos na Seção 3.3 e, como mencionado anteriormente, os valores foram definidos por hiperparametrização usando o *GridSearchCV*.

Os parâmetros de desempenho obtidos pela implementação das máquinas vetoriais de suporte estão na Tabela 7.17.

Tabela 7.17: Erros médios obtidos com a implementação das máquinas vetoriais de suporte.

<b>Treinamento RMSE (kN)</b>	<b>Teste RMSE (kN)</b>	<b>Treinamento R<sup>2</sup></b>	<b>Teste R<sup>2</sup></b>
3,01	5,02	0,92	0,83

A Figura 7.33 e a Figura 7.34 mostram os valores originais e previstos para os conjuntos de teste e treinamento, respectivamente, obtidos pela implementação das máquinas vetoriais de suporte.

Figura 7.33: Resultados original *versus* previsto obtidos na implementação das máquinas vetoriais de suporte para a parcela de treinamento.

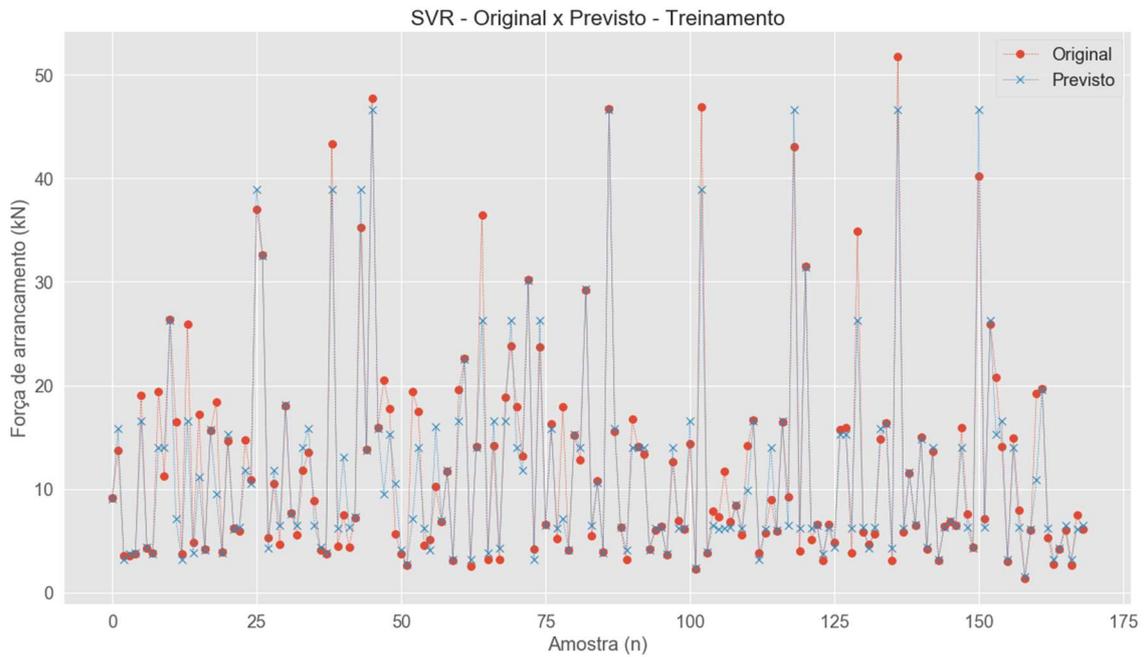
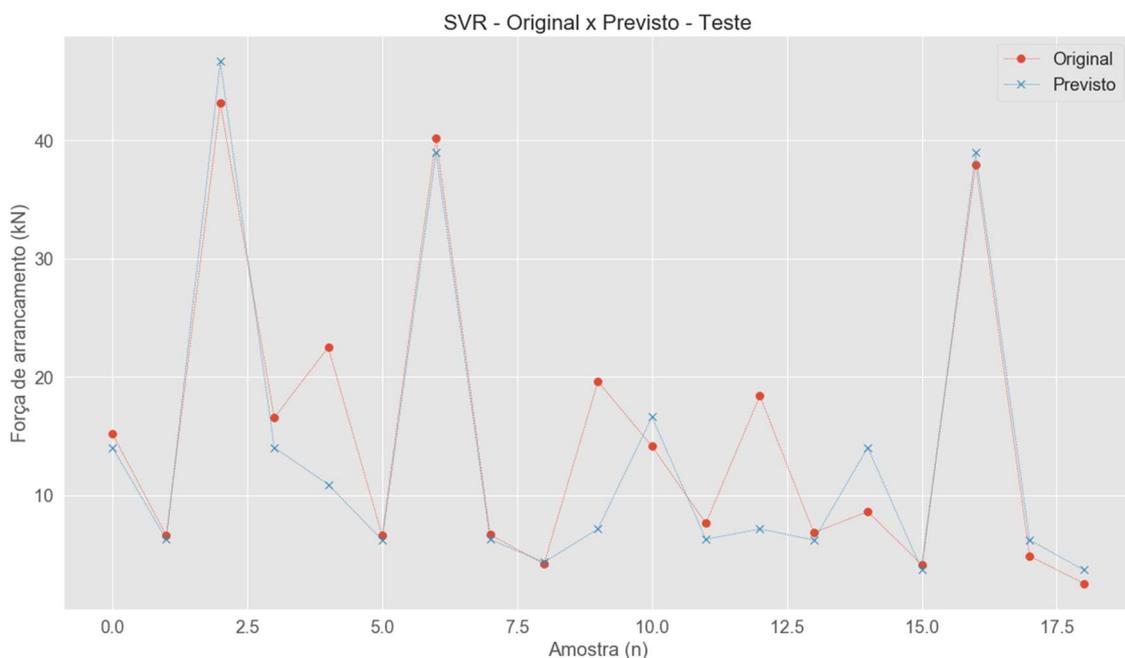
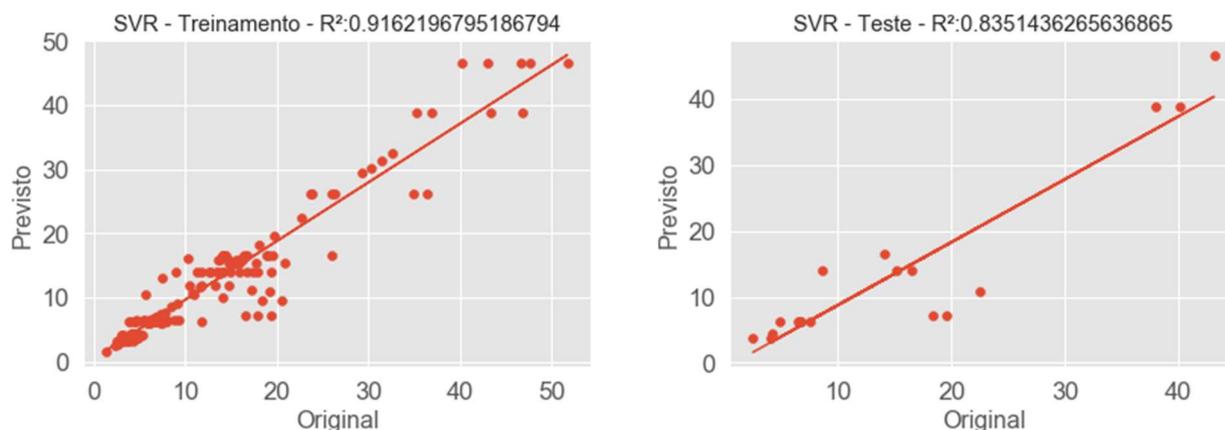


Figura 7.34: Resultados original *versus* previsto obtidos na implementação das máquinas vetoriais de suporte para a parcela de teste.



A Figura 7.35 apresenta os valores de  $R^2$  originais *versus* previstos obtidos pela implementação das máquinas vetoriais de suporte.

Figura 7.35: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das máquinas vetoriais de suporte para as parcelas de treinamento e teste.



#### • REDES NEURAIS ARTIFICIAIS

Para o modelo de redes neurais artificiais, os parâmetros que obtiveram melhores resultados estão listados na Tabela 7.18.

Tabela 7.18: Variação de parâmetros e parâmetros utilizados na implementação das redes neurais artificiais.

Parâmetro	Configuração utilizada
Quantidade de neurônios de camada de entrada	4
Número de camadas intermediárias	1
Quantidade de neurônios de camada de intermediária	10
Função de ativação	softplus-linear

Os parâmetros apresentados na Tabela 7.18 foram descritos na Seção 3.4 e seus valores foram definidos por hiperparametrização usando o *GridSearchCV*. Os parâmetros de desempenho obtidos pela implementação das redes neurais artificiais estão na Tabela 7.19.

Os parâmetros de performance obtidos através da implementação das redes neurais artificiais estão apresentados na Tabela 7.19.

Tabela 7.19: Erros médios obtidos com a implementação das redes neurais artificiais.

Treinamento RMSE (kN)	Teste RMSE (kN)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
2,54	2,36	0,94	0,96

A Figura 7.36 e a Figura 7.37 mostram os valores originais e previstos para os conjuntos de teste e treinamento, respectivamente, obtidos pela implementação das redes neurais artificiais.

Figura 7.36: Resultados original *versus* previsto obtidos na implementação das redes neurais artificiais para a parcela de treinamento.

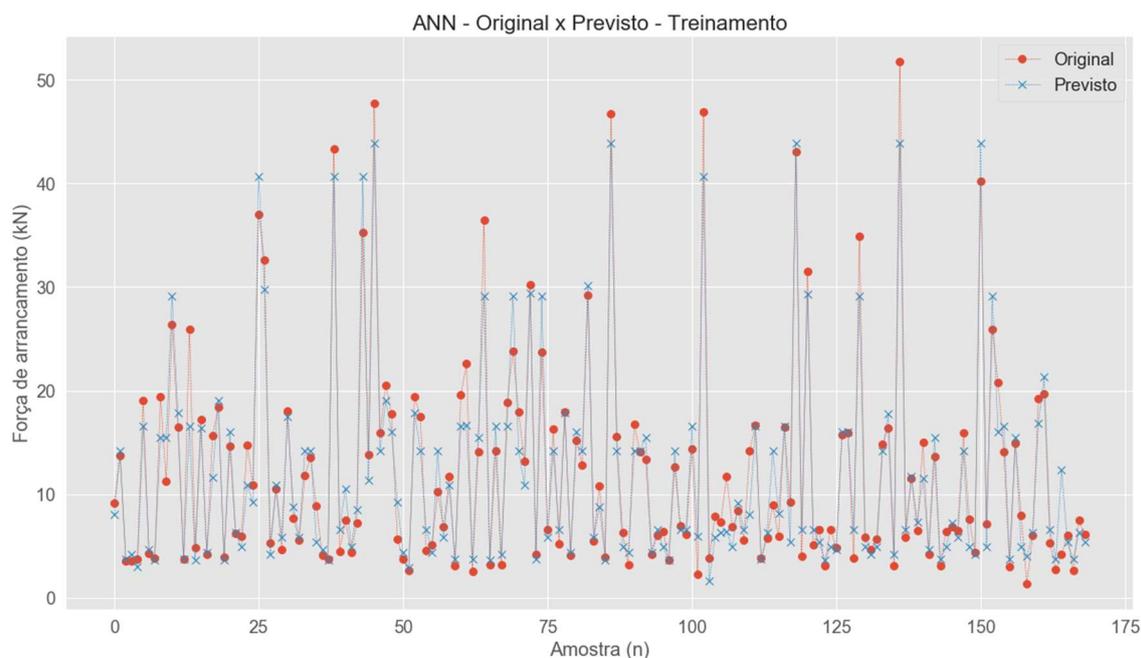
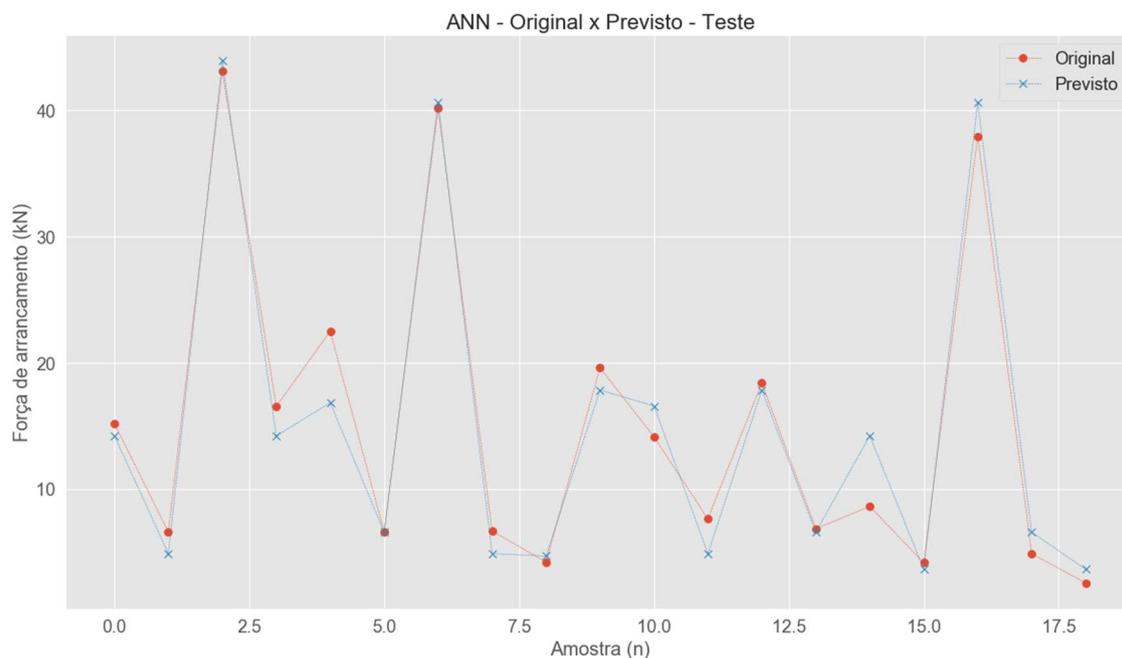
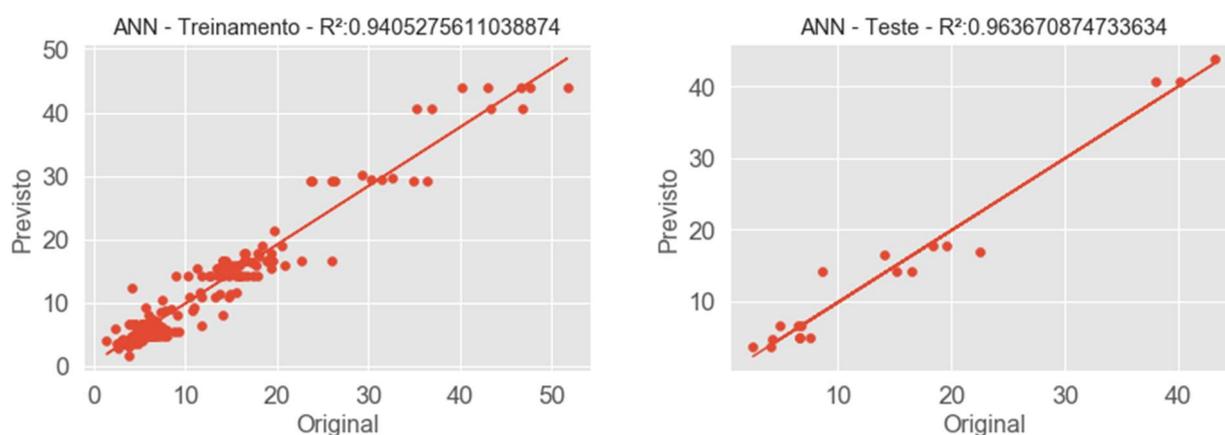


Figura 7.37: Resultados original *versus* previsto obtidos na implementação das redes neurais artificiais para a parcela de teste.



A Figura 7.38 apresenta os valores de  $R^2$  originais *versus* previstos obtidos pela implementação das redes neurais artificiais.

Figura 7.38: Resultados de  $R^2$  original *versus* previsto obtidos na implementação das redes neurais artificiais para as parcelas de treinamento e teste.



• **REGRESSOR GRADIENTE *BOOSTING***

Para o modelo de regressor gradiente *boosting*, os parâmetros variados e os parâmetros que apresentaram melhores resultados estão descritos na Tabela 7.20.

Tabela 7.20: Variação de parâmetros e parâmetros utilizados na implementação do regressor gradiente *boosting*.

Parâmetro	Variação	Configuração utilizada
Nº de estágios de <i>boosting</i> a serem realizados	230-300	300
Profundidade máxima dos estimadores de regressão	2-30	12
Nº mínimo de amostras para dividir um nó interno	10-500	50
Taxa de aprendizado	0,2-0,4	0,4

Os parâmetros apresentados na Tabela 7.20 foram descritos na Seção 3.5 e seus valores foram definidos por hiperparametrização usando o *GridSearchCV*.

Os parâmetros de desempenho obtidos pela implementação do regressor gradiente *boosting* estão na Tabela 7.21.

Tabela 7.21: Erros médios obtidos com a implementação do regressor gradiente *boosting*.

Treinamento RMSE (kN)	Teste RMSE (kN)	Treinamento R <sup>2</sup>	Teste R <sup>2</sup>
2,11	2,28	0,96	0,97

A Figura 7.39 e a Figura 7.40 mostram os valores originais e previstos para os conjuntos de teste e treinamento, respectivamente, obtidos pela implementação do regressor gradiente *boosting*.

Figura 7.39: Resultados original *versus* previsto obtidos na implementação do regressor gradiente *boosting* para a parcela de treinamento.

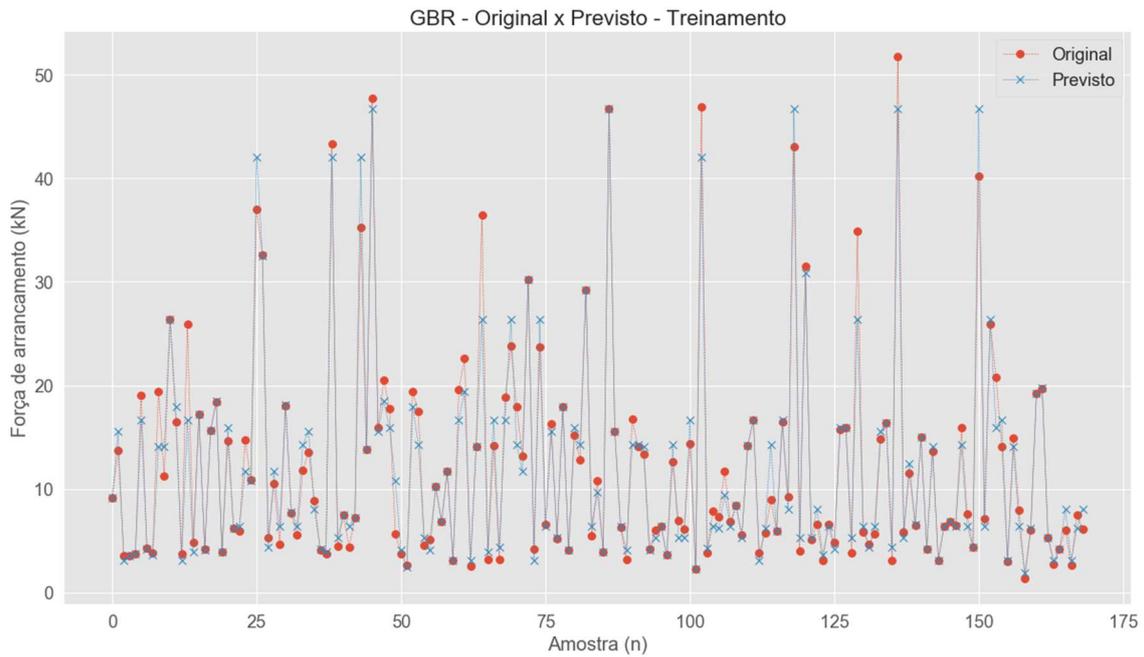
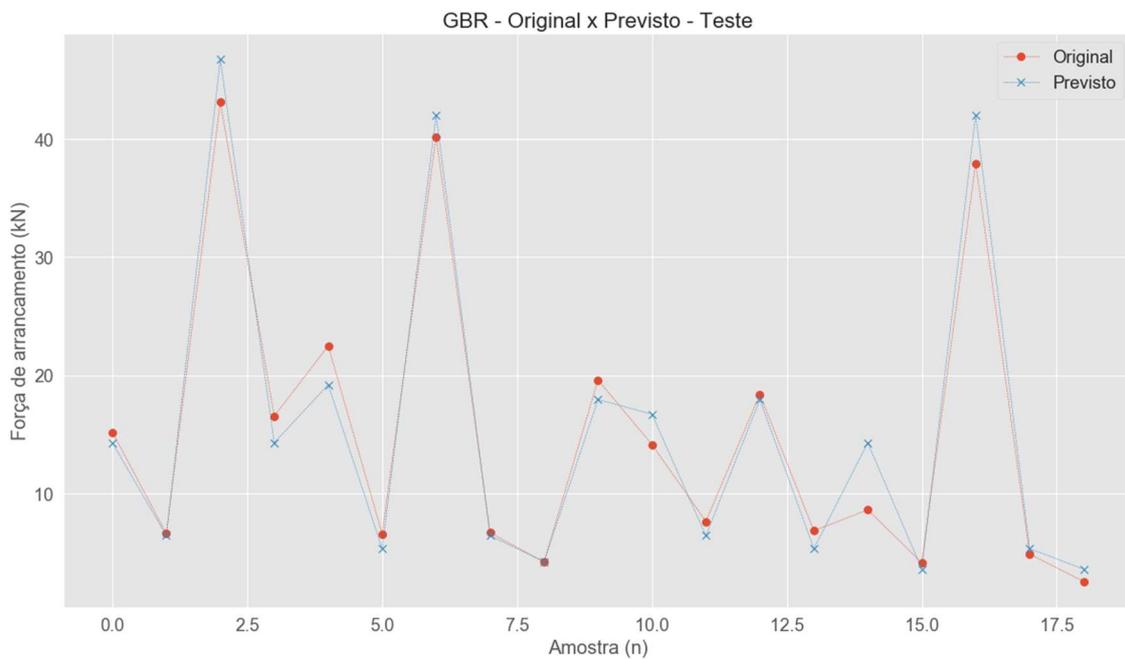
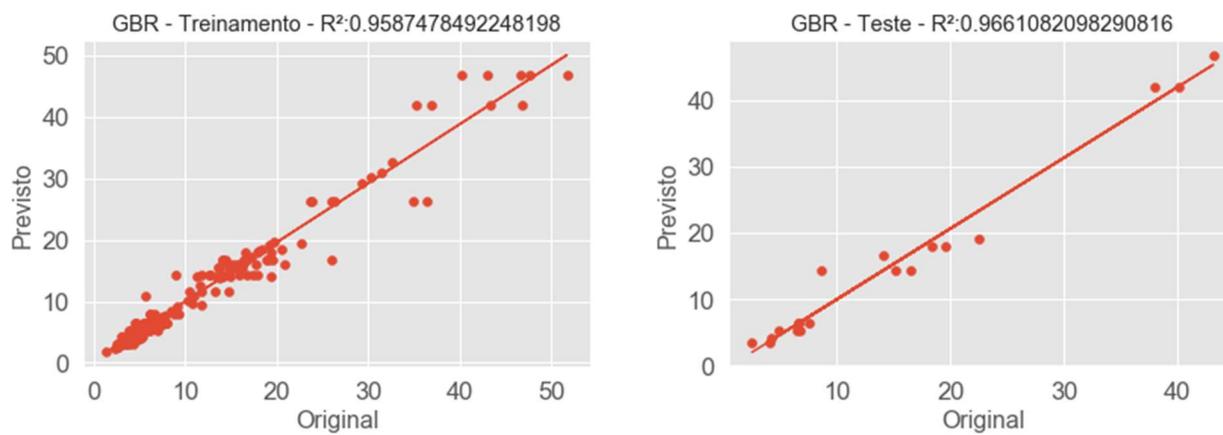


Figura 7.40: Resultados original *versus* previsto com a implementação de regressor gradiente *boosting* para a parcela de teste.



A Figura 7.41 apresenta os valores de  $R^2$  originais *versus* previstos obtidos pela implementação do regressor gradiente *boosting*.

Figura 7.41: Resultados de  $R^2$  original versus previsto com a implementação do regressor gradiente *boosting* para as parcelas de treinamento e teste.



## 8. ANÁLISE DOS RESULTADOS

Este trabalho teve como objetivo aplicar métodos de inteligência computacional para determinar a resistência à compressão do concreto, com base nos dados apresentados no estudo de Yeh (2006), e a resistência ao arrancamento de barras de aço em ensaios de *pull-out*, usando a base de dados de Carvalho *et al.* (2017) e uma base ampliada de trabalhos de diversos autores.

Para isso, foram utilizados cinco métodos de aprendizado de máquina e inteligência artificial. Além disso, foram utilizados métodos de pré-processamento de dados para otimizar os parâmetros de desempenho obtidos nas implementações. Nas seções a seguir, serão discutidos os resultados obtidos.

### 8.1. RESISTÊNCIA À COMPRESSÃO DO CONCRETO

Os parâmetros de performance RMSE e  $R^2$  obtidos para a determinação da resistência à compressão do concreto são apresentados resumidamente na Tabela 8.1.

Tabela 8.1: Comparação de resultados obtidos para a resistência à compressão do concreto.

Método computacional	Treinamento RMSE (MPa)	Teste RMSE (MPa)	Treinamento $R^2$	Teste $R^2$
Árvores de decisão	4,094	6,673	0,938	0,863
Florestas aleatória	3,061	5,910	0,952	0,892
Máquinas Vetoriais de Suporte	2,555	7,456	0,976	0,829
Redes Neurais Artificiais	4,893	6,354	0,911	0,876
Regressor Gradiente <i>Boosting</i>	1,427	4,113	0,992	0,948

Com base nos resultados apresentados, pode-se afirmar que o método computacional GBR (regressor gradiente *boosting*) apresentou o melhor desempenho (RMSE = 4,113 MPa e  $R^2 = 0,948$ ), considerando a parcela de teste. Além disso, pode-se observar que o método computacional de máquinas vetoriais de suporte obteve o pior desempenho entre as implementações utilizadas.

A baixa variação do erro nos dados fornecidos sugere que todos os métodos computacionais utilizados são adequados para determinar a resistência à compressão do concreto. Essa

consistência nos resultados indica que os métodos de inteligência computacional estão fornecendo estimativas consistentes e confiáveis para essa propriedade.

Isso significa que, independentemente do algoritmo específico utilizado, os resultados obtidos para a resistência à compressão do concreto são semelhantes e apresentam uma variação mínima. Isso é um indicativo positivo da robustez e eficácia desses métodos na determinação dessa propriedade crucial do material.

Essa consistência nos resultados também pode ser atribuída à capacidade dos métodos de inteligência computacional em lidar com diferentes tipos de dados e modelar relações complexas. Esses métodos são capazes de aprender padrões subjacentes aos dados e realizar ajustes precisos nos parâmetros do modelo, resultando em estimativas consistentes da resistência à compressão.

A Tabela 8.2 apresenta uma comparação dos parâmetros de desempenho obtidos neste trabalho com resultados encontrados na literatura consultada.

Tabela 8.2: Comparação dos parâmetros de performance obtidos nesse trabalho com resultados apresentados em outras literaturas.

<b>PESQUISA</b>	<b>RMSE (MPa)</b>
Rede neural artificial (YEH, 2006)	5,70
Rede neural artificial (COOK <i>et al.</i> , 2019)	6,33
Máquina vetorial de suporte (COOK <i>et al.</i> , 2019)	5,22
Florestas aleatórias (COOK <i>et al.</i> , 2019)	3,27
<b>Árvores de decisão</b>	<b>6,67</b>
<b>Florestas aleatórias</b>	<b>5,91</b>
<b>Máquinas vetoriais de suporte</b>	<b>7,46</b>
<b>Redes neurais artificiais</b>	<b>6,35</b>
<b>Regressor gradiente <i>boosting</i></b>	<b>4,11</b>

A maioria dos resultados obtidos neste trabalho demonstram uma melhoria em relação aos resultados de trabalhos anteriores disponíveis na literatura. Os modelos de inteligência computacional utilizados neste estudo mostraram-se eficazes na previsão da resistência à

compressão de espécimes de concreto. Além disso, a alta consistência entre os parâmetros de performance previstos, como o erro percentual médio e a resistência à compressão experimental dos espécimes de concreto sugere uma abordagem alternativa e não destrutiva para a obtenção dessa propriedade. Com isso, este estudo oferece uma contribuição relevante para a área de construção civil ao apresentar uma nova abordagem para determinação da resistência à compressão do concreto.

## 8.2. RESISTÊNCIA AO ARRANCAMENTO

### 8.2.1. BASE DE DADOS DE CARVALHO

Os parâmetros de performance RMSE e  $R^2$  obtidos para a determinação da resistência à compressão do concreto são apresentados resumidamente na Tabela 8.3.

Tabela 8.3: Comparação dos resultados obtidos com a base de Carvalho *et al.* (2017).

<b>Método computacional</b>	<b>Treinamento RMSE (kN)</b>	<b>Teste RMSE (kN)</b>	<b>Treinamento R<sup>2</sup></b>	<b>Teste R<sup>2</sup></b>
<b>Árvores de decisão</b>	2,40	1,26	0,89	0,95
<b>Florestas aleatórias</b>	2,47	1,30	0,89	0,96
<b>Máquinas vetoriais de suporte</b>	2,56	1,31	0,88	0,96
<b>Redes neurais artificiais</b>	2,54	1,16	0,87	0,96
<b>Regressor gradiente <i>boosting</i></b>	2,39	1,32	0,90	0,95

Com base nos resultados apresentados, pode-se afirmar que o método de rede neural artificial (ANN) obteve o melhor desempenho na parcela de teste (RMSE = 1,16 kN e  $R^2 = 0,96$ ).

Como mencionado anteriormente, a utilização de métodos computacionais para estudar a aderência de barras de pequeno diâmetro em blocos de concreto por meio de ensaios do tipo *pull-out* ainda é relativamente nova. Portanto, foi necessário complementar os dados da base de Carvalho *et al.* (2017) com informações de outros estudos para validar o algoritmo treinado.

### 8.2.2. EQUAÇÃO EMPÍRICA

Com base nos resultados apresentados, é evidente que não há correlação entre os valores encontrados para a força de arrancamento por meio das equações empíricas disponíveis na literatura para barras de diâmetros finos. Especificamente, o CEB (2010), que é um código normativo projetado para ajudar engenheiros estruturais no dimensionamento de ancoragens de barras solicitadas à tração, frequentemente produz valores da força de arrancamento maiores do que os encontrados experimentalmente. Conseqüentemente, o uso dessa equação nos casos estudados pode resultar em valores que comprometem a segurança. Esses resultados ressaltam a importância de mais estudos sobre o comportamento de barras finas de aço.

### 8.2.3. BASES DE DADOS AMPLIADA

- ETAPA 1

Os valores de RMSE obtidos para cada um dos métodos computacionais treinados com a base Carvalho *et al.* (2017) e testados com a base ampliada são apresentados de forma resumida na Tabela 8.4.

Tabela 8.4: Valores de RMSE obtido através dos métodos computacionais treinados com a base de Carvalho *et al.* (2017) e testados na base de dados ampliada, em kN.

<b>DTR (kN)</b>	<b>RFR (kN)</b>	<b>SVM (kN)</b>	<b>ANN (kN)</b>	<b>GBR (kN)</b>
7,03	6,94	9,62	8,56	7,00

Pelos valores apresentados, pode-se constatar que o algoritmo treinado com a base de dados de Carvalho *et al.* (2017) não se adaptou bem aos valores obtidos através de outras bases experimentais. Essa falta de adaptação se deve, principalmente, à diferença na amplitude dos dados de entrada disponíveis na base de Carvalho *et al.* (2017), em comparação com as entradas disponíveis na base ampliada. A resistência à compressão do concreto, por exemplo, apresenta valores acima de 50 MPa na base ampliada, enquanto que na base de Carvalho *et al.* (2017) essa amplitude de dados não é contemplada. Essa limitação na base de dados de Carvalho *et al.* (2017) prejudica o aprendizado dos métodos computacionais, impedindo que eles apresentem a resposta correta para os dados utilizados.

- **ETAPA 2**

Nesta etapa, os algoritmos foram treinados com toda a base de dados ampliada. O resumo dos resultados obtidos para cada método implementado é apresentado na Tabela 8.5.

Tabela 8.5: Comparação de resultados obtidos na etapa 2.

<b>Método computacional</b>	<b>Treinamento RMSE (kN)</b>	<b>Teste RMSE (kN)</b>	<b>Treinamento R<sup>2</sup></b>	<b>Teste R<sup>2</sup></b>
<b>Árvores de decisão</b>	1,98	2,14	0,96	0,97
<b>Florestas aleatórias</b>	2,42	2,35	0,94	0,96
<b>Máquinas vetoriais de suporte</b>	3,01	5,02	0,92	0,83
<b>Redes neurais artificiais</b>	2,54	2,36	0,94	0,96
<b>Regressor gradiente <i>boosting</i></b>	2,11	2,28	0,96	0,97

Com base nos resultados apresentados, pode-se afirmar que o método computacional DTR (árvores de decisão aleatória) obteve o melhor desempenho (RMSE = 2,14 kN e R<sup>2</sup> = 0,97), considerando a parcela de teste. Além disso, na etapa de treinamento com a base de dados ampliada, verificou-se uma melhora significativa em relação ao modelo anteriormente apresentado. Isso se deve à disponibilidade de uma maior quantidade e variedade de dados experimentais na base ampliada, o que resultou em um melhor entendimento do método computacional sobre como ocorre a força de arrancamento quando há maior diversidade nos valores de entrada, especialmente com relação à resistência à compressão do concreto.

## 9. CONCLUSÃO

Este trabalho teve como objetivo principal a implementação e validação de métodos computacionais para auxiliar na determinação de importantes características do concreto, tais como resistência à compressão e força de arrancamento de barras de aço e concreto em ensaios *pull-out*, usando várias bases de dados consolidadas, sem a necessidade de ensaios destrutivos. Para isso, foram aplicados métodos de inteligência computacional para determinação da resistência à compressão do concreto, a partir de bases de dados apresentadas no estudo de Yeh (2006), e para determinação da resistência ao arrancamento de barras de aço em ensaios *pull-out*, usando a base de dados de Carvalho *et al.* (2017) e uma base ampliada, obtida a partir de pesquisas em trabalhos de diferentes autores, considerando diferentes traços do concreto e geometrias dos corpos de prova, com o objetivo de minimizar os fatores de erro e permitir a aplicação em casos simulados e reais.

Cinco métodos computacionais de aprendizado de máquina e inteligência artificial foram utilizados, juntamente com métodos de pré-processamento de dados para otimizar os parâmetros de desempenho obtidos nas implementações.

Com os resultados apresentados, pode-se concluir que:

- Os modelos computacionais apresentados são capazes de auxiliar na determinação da resistência à compressão do concreto. Na base de dados analisada, o modelo computacional com maior precisão foi o regressor gradiente *boosting*, mas todos os métodos computacionais apresentaram bons resultados.
- Os modelos computacionais apresentados também são capazes de auxiliar na determinação da força de arrancamento de barras de aço em ensaios *pull-out*. Na base de dados de Carvalho *et al.* (2017), o modelo computacional com maior adaptabilidade foi a rede neural artificial, mas todos os métodos apresentaram bons resultados.
- Na base de dados ampliada, as árvores de decisão foram o modelo computacional com maior adaptabilidade, mas todos os métodos apresentaram bons resultados.
- As técnicas de pré-processamento, como validação cruzada e hiperparametrização utilizando o *GridSearchCV*, auxiliam na melhora dos resultados obtidos. Além disso, as técnicas de limpeza, como o cálculo do desvio padrão de cada amostra, separadas por diâmetro e resistência do concreto, retirando os valores considerados outliers, ajudam na obtenção de melhores resultados, especialmente em bases experimentais novas.
- O algoritmo treinado para a determinação da força de arrancamento com a base de Carvalho *et al.* (2017) não consegue prever os resultados experimentais quando a base de dados

ampliada é testada devido à diferença de amplitude dos dados de entrada disponíveis na base de Carvalho *et al.* (2017) em comparação com a base ampliada. É necessário complementar o treinamento de dados para que a base compreenda ensaios experimentais de outras bases.

- O algoritmo treinado para a determinação da força de arrancamento com a base ampliada é capaz de prever os resultados experimentais de forma mais precisa do que algoritmos treinados com a base de dados de Carvalho *et al.* (2017).
- A equação empírica disponível no CEB (2010) não apresenta boa correlação com os resultados obtidos para a força de arrancamento, tanto nos modelos experimentais quanto nos modelos computacionais, para barras de pequeno diâmetro.
- Com base nos resultados apresentados, podemos afirmar que os modelos de inteligência computacional utilizados são uma alternativa confiável e eficaz para resolver problemas complexos, como a previsão da resistência à compressão do concreto. Esses modelos oferecem uma abordagem promissora para substituir ensaios experimentais dispendiosos, permitindo prever com alta confiabilidade as propriedades do concreto.

Ao utilizar uma base de dados consolidada, os modelos de inteligência computacional desenvolvidos demonstraram uma boa correlação entre os valores experimentais de força de arrancamento e os valores de tensão obtidos pelos métodos computacionais aplicados. Isso é evidenciado pelo baixo valor do RMSE (raiz do erro quadrático médio) e pelo valor de  $R^2$  próximo de 1. Esses resultados indicam que os modelos são capazes de prever com precisão as propriedades do concreto com base nos dados disponíveis.

No entanto, é importante ressaltar que esses resultados são específicos para a base de dados utilizada no treinamento dos modelos. Para avaliar a generalização desses modelos em diferentes situações e condições de ensaio, análises adicionais são necessárias, principalmente considerando uma maior variedade e quantidade de dados experimentais.

Apesar disso, os resultados obtidos sugerem que a aplicação de métodos de inteligência computacional pode ser uma alternativa confiável e eficiente para a previsão de propriedades importantes do concreto, eliminando a necessidade de ensaios destrutivos dispendiosos. Essa abordagem oferece uma maneira mais eficiente e econômica de avaliar as propriedades do material, contribuindo para o controle de qualidade e a análise na indústria da construção.

Assim, este trabalho teve como objetivo contribuir para a análise da aplicabilidade de métodos de inteligência computacional na determinação de características essenciais do concreto, como a resistência à compressão e a força de arrancamento de barras finas por meio de ensaios pull-out. Utilizando uma base de dados consolidada, os modelos desenvolvidos demonstraram ser capazes

de determinar esses parâmetros do concreto sem a necessidade de ensaios destrutivos. Isso representa uma abordagem mais eficiente, econômica e promissora para a avaliação das propriedades do concreto na indústria da construção.

### 9.1. TRABALHOS FUTUROS

O estudo apresentado neste trabalho descreve a aplicação de modelos computacionais para determinar as propriedades do concreto sem a necessidade de ensaios destrutivos. Para futuras pesquisas, sugere-se:

- Utilização de métodos computacionais mais precisos ou métodos de inteligência computacional mistos, tanto para a previsão da resistência à compressão do concreto quanto para a previsão da força de arrancamento, ou seja, modelos que utilizam mais de um método computacional tendo em vista a otimização dos resultados.
- Ampliação das bases de dados com resultados experimentais disponíveis na literatura acadêmica, que visam determinar a resistência ao arrancamento em ensaios *pull-out*. Assim, os modelos computacionais podem ser consolidados para prever a força de arrancamento em bases mais amplas, ou seja, com valores de entrada mais diversos.
- Aplicação de métodos computacionais para prever outras importantes características do concreto, como o módulo de elasticidade longitudinal e transversal, *slump*, resistência ao cisalhamento do concreto, resistência em ensaios de flexão, etc.
- Aplicação de métodos computacionais para prever a resistência ao arrancamento em barras de aço através de ensaios de vigas rotuladas.

Dessa forma, novos trabalhos podem auxiliar na obtenção dos resultados aqui apresentados, contribuindo para uma melhor compreensão da aplicação dos métodos computacionais na determinação de parâmetros do concreto.

## 10. BIBLIOGRAFIA

- ABD, A. M.; ABD, S. M. Modelling the strength of lightweight foamed concrete using support vector machine (SVM). *Case Studies in Construction Materials*, v. 6, p. 8–15, 2017.
- ABNT. NBR 5739:2007 Concreto - Ensaio de compressão de corpos-de-prova cilíndricos. *Associação Brasileira de Normas Técnicas*, p. 14, 2007.
- ABNT. *NBR 6118 - Projeto de Estruturas de Concreto - Procedimento*. Rio de Janeiro: [s.n.], 2014.
- AKPINAR, P.; KHASHMAN, A. Intelligent classification system for concrete compressive strength. *Procedia Computer Science*, v. 120, p. 0–000, 2017.
- ALSHIHRI, M. M.; AZMY, A. M.; EL-BISY, M. S. Neural networks for predicting compressive strength of structural light weight concrete. *Construction and Building Materials*, v. 23, n. 6, p. 2214–2219, 2009.
- AZIMI-POUR, M.; ESKANDARI-NADDAF, H.; PAKZAD, A. Linear and non-linear SVM prediction for fresh properties and compressive strength of high volume fly ash self-compacting concrete. *Construction and Building Materials*, v. 230, p. 117021, 2020.
- BABANAJAD, S. K. *Application of genetic programming for uniaxial and multiaxial modeling of concrete*. Switzerland: Springer, 2015.
- BARBOSA, M. T. G. *Avaliação do comportamento da aderência em concretos de diferentes classes de resistência*. 2001. 210 f. UFRJ, Rio de Janeiro, 2001.
- BASTOS, P. S. DOS S. *Fundamentos do concreto armado*. Bauru: Unesp, 2006.
- 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*, 2018.
- BELALIA DOUMA, O. *et al.* Prediction of properties of self-compacting concrete containing fly ash using artificial neural network. *Neural Computing and Applications*, 2017.
- BENNETT, K. P.; DEMIRIZ, A. Semi-supervised support vector machines. 1999, [S.l.: s.n.], 1999. p. 368–374.
- BISHOP, C. M. *Neural networks for pattern recognition*. [S.l.]: Oxford university press, 1995.
- BREIMAN, L. Arcing the edge. *Statistics*, v. 4, p. 1–14, 1997.
- BREIMAN, L. Random forests. *Machine learning*, v. 45, n. 1, p. 5–32, 2001.
- BUITINCK, L. *et al.* API design for machine learning software: experiences from the scikit-learn project. *arXiv preprint arXiv:1309.0238*, p. 1–15, 2013.

- CARVALHO, E. P. *et al.* Experimental investigation of steel-concrete bond for thin reinforcing bars. *Latin American Journal of Solids and Structures*, v. 14, n. 11, p. 1932–1951, 2017.
- CASTRO, A. L. DE; LIBORIO, J. B. L.; PANDOLFELLI, V. C. Desempenho de concretos avançados para a construção civil, formulados a partir do método de dosagem computacional. *Cerâmica*, v. 55, n. 335, p. 233–251, 2009.
- CEB. Model Code 2010. *Fédération internationale du béton (fib)*, v. Volume II, 2010.
- CEB, R. CEB/FIP Recommendations on reinforcement Steel for reinforced concrete. *RC-6: Bond test for reinforcement Steel: 2. Pull-out test, Revised Edition*, 1983.
- CHAPRA, S. C.; CANALE, R. P. *Métodos Numéricos para Engenharia-7ª Edição*. [S.l.]: McGraw Hill Brasil, 2016.
- CHEN, W.-F. *Plasticity in reinforced concrete*. [S.l.]: J. Ross Publishing, 2007.
- CHITHRA, S. *et al.* A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks. *Construction and Building Materials*, 2016.
- CHOPRA, P.; SHARMA, R. K.; KUMAR, M. Prediction of compressive strength of concrete using artificial neural network and genetic programming. *Advances in Materials Science and Engineering*, v. 2016, 2016.
- CHOU, J. *et al.* Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on a Comparison of Data-Mining Techniques. *JOURNAL OF COMPUTING IN CIVIL ENGINEERING*, 2011.
- CLEVERT, D. A.; UNTERTHINER, T.; HOCHREITER, S. Fast and accurate deep network learning by exponential linear units (ELUs). *4th International Conference on Learning Representations, ICLR 2016 - Conference Track Proceedings*, p. 1–14, 2016.
- COOK, R. *et al.* Prediction of Compressive Strength of Concrete: Critical Comparison of Performance of a Hybrid Machine Learning Model with Standalone Models. *Journal of Materials in Civil Engineering*, v. 31, n. 11, p. 1–15, 2019.
- DAHL, G. E.; SAINATH, T. N.; HINTON, G. E. Improving deep neural networks for LVCSR using rectified linear units and dropout. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, v. I, n. 2010, p. 8609–8613, 2013.
- DAHOU, Z. *et al.* Artificial neural network model for steel-concrete bond prediction. *Engineering Structures*, v. 31, n. 8, p. 1724–1733, 2009.
- DENG, F. *et al.* Compressive strength prediction of recycled concrete based on deep learning.

*Construction and Building Materials*, 2018.

DESHPANDE, N.; LONDHE, S.; KULKARNI, S. Modeling compressive strength of recycled aggregate concrete by Artificial Neural Network, Model Tree and Non-linear Regression. *International Journal of Sustainable Built Environment*, v. 3, n. 2, p. 187–198, 2014.

DOZAT, T. Incorporating Nesterov Momentum into Adam. *ICLR Workshop*, v. 1, n. 1, p. 2013–2016, 2016.

DRUCKER, H. *et al.* Support vector regression machines. 1997, [S.l: s.n.], 1997. p. 155–161.

DUAN, Z. H.; KOU, S. C.; POON, C. S. Prediction of compressive strength of recycled aggregate concrete using artificial neural networks. *Construction and Building Materials*, 2013.

EFRON, B.; TIBSHIRANI, R. Improvements on cross-validation: the 632+ bootstrap method. *Journal of the American Statistical Association*, v. 92, n. November, p. 37–41, 1997.

ESKANDARI, H.; TAYYEBINIA, M. Effect of 32.5 and 42.5 Cement Grades on ANN Prediction of Fibrocement Compressive Strength. 2016, [S.I.]: Elsevier Ltd, 2016. p. 2193–2201.

FERNANDES, R. M. *A influência das ações repetidos na aderencia aço concreto*. 2000. Universidade de São Paulo, 2000.

FILHO, F. M. DE A. *Contribuição ao estudo da aderência entre barras de aço e concretos auto-adensáveis*. 2006. 155 f. 2006.

FORMAN, G. BNS feature scaling: an improved representation over tf-idf for svm text classification. 2008, [S.I.]: ACM, 2008. p. 263–270.

FRANÇA, V. *Aderência aço-concreto: uma análise do comportamento do concreto fabricado com resíduos de borracha*. 2004. Universidade Estadual Paulista Julio Mesquita Filho, 2004.

FRIEDMAN, J. Stochastic Gradient Boosting. p. 1–10, 1999.

FRIEDMAN, J. H. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, p. 1189–1232, 2001.

FUSCO, P. B. *Estruturas de Concreto - Solicitações normais - Estados limites últimos*. Rio de Janeiro: Guanabara dois, 2000.

GANDOMI, A. H.; ALAVI, A. H. Applications of computational intelligence in behavior simulation of concrete materials. *Studies in Computational Intelligence*, v. 359, p. 221–243, 2011.

GEORGIU, G. M.; KOUTSOUGERAS, C. Complex domain backpropagation. *IEEE transactions on Circuits and systems II: analog and digital signal processing*, v. 39, n. 5, p. 330–334, 1992.

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover

classification. *Pattern Recognition Letters*, v. 27, n. 4, p. 294–300, 2006.

GOLAFSHANI, E. M. *et al.* Prediction of bond strength of spliced steel bars in concrete using artificial neural network and fuzzy logic. *Construction and Building Materials*, v. 36, p. 411–418, 2012.

GOLUB, G. H.; HEATH, M.; WAHBA, G. Generalized cross-validation as a method for choosing a good ridge parameter. *Technometrics*, v. 21, n. 2, p. 215–223, 1979.

GOOD, P. I. *Resampling methods*. [S.l.]: Springer, 2006.

GULLI, A.; PAL, S. *Deep Learning with Keras*. [S.l.]: Packt Publishing Ltd, 2017.

GUNN, S. R. Support vector machines for classification and regression. *ISIS technical report*, v. 14, n. 1, p. 5–16, 1998.

GUPTA, S. Using artificial neural network to predict the compressive strength of concrete containing Nano-Silica. *Civil Engineering and Architecture*, v. 1, n. 3, p. 96–102, 2013.

HAMMOUDI, A. *et al.* Comparison of artificial neural network (ANN) and response surface methodology (RSM) prediction in compressive strength of recycled concrete aggregates. *Construction and Building Materials*, v. 209, 2019.

HECHT-NIELSEN, R. Theory of the backpropagation neural network. *Neural networks for perception*. [S.l.]: Elsevier, 1992. p. 65–93.

HETLAND, M. L. *Beginning Python*. [S.l.]: Springer, 2008.

HIBBELER, R. C. C. *Resistência dos Materiais*. 7. ed. São Paulo, SP: Pearson, 2010.

HOANG, N. D. *et al.* A backpropagation artificial neural network software program for data classification in civil engineering developed in . NET framework. *DTU Journal of Science and Technology*, v. 03, n. 34, p. 51–56, 2019.

HOŁA, J.; SCHABOWICZ, K. New technique of nondestructive assessment of concrete strength using artificial intelligence. *NDT & E International*, v. 38, n. 4, p. 251–259, 2005.

HOPFIELD, J. J. Artificial neural networks. *IEEE Circuits and Devices Magazine*, v. 4, n. 5, p. 3–10, 1988.

KAPLAN, G. *et al.* Artificial Neural Network Estimation of the Effect of Varying Curing Conditions and Cement Type on Hardened Concrete Properties. *Buildings*, v. 9, n. 1, p. 10, 2019.

KAVEH, A.; KALATEH-AHANI, M.; FAHIMI-FARZAM, M. Constructability optimal design of reinforced concrete retaining walls using a multi-objective genetic algorithm. *Structural Engineering and Mechanics*, v. 47, n. 2, p. 227–245, 2013.

KHADEMI, F. *et al.* Multiple linear regression, artificial neural network, and fuzzy logic prediction of

28 days compressive strength of concrete. *Frontiers of Structural and Civil Engineering*, v. 11, n. 1, p. 90–99, 1 mar. 2017.

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.

KLAMBAUER, G. *et al.* Self-normalizing neural networks. *Advances in Neural Information Processing Systems*, v. 2017- Decem, p. 972–981, 2017.

KOVÁCS, Z. L. *Redes neurais artificiais*. [S.l.]: Editora Livraria da Física, 2002.

KUMMER, L. M. *Resistência à compressão e módulo de elasticidade dos concretos de uma central dosadora de concreto de Lajeado/RS*. . [S.l: s.n.]. , 2017

LI, Z. *Advanced concrete technology*. [S.l.]: John Wiley & Sons, 2011.

LIN, C.-F.; WANG, S.-D. Fuzzy support vector machines. *IEEE transactions on neural networks*, v. 13, n. 2, p. 464–471, 2002.

MAKNI, M. *et al.* Artificial neural network for the prediction of the steel-concrete bond behaviour. *European Journal of Environmental and Civil Engineering*, v. 18, n. 8, p. 862–881, 2014.

METHA, P. K.; MONTEIRO, P. J. M. *Concreto: Microestrutura, propriedades e materiais*. [S.l: s.n.], 2008.

MIRANDA, M. P. *Avaliação experimental da influência das características do corpo de prova no ensaio de arrancamento (Pull-Out Test)*. 2018. 2018.

MIRANDA, M. P. *et al.* Steel-concrete bond behavior: An experimental and numerical study. *Construction and Building Materials*, v. 271, p. 121918, 2021.

MISES, R. VON. Mechanik der plastischen Formänderung von Kristallen. *ZAMM-Journal of Applied Mathematics and Mechanics/Zeitschrift für Angewandte Mathematik und Mechanik*, v. 8, n. 3, p. 161–185, 1928.

MUTHUPRIYA, P.; SUBRAMANIAN, K.; VISHNURAM, B. G. Prediction of compressive strength and durability of high performance concrete by artificial neural networks. *Iran University of Science & Technology*, v. 1, n. 1, p. 189–209, 2011.

NADERPOUR, H.; RAFIEAN, A. H.; FAKHARIAN, P. Compressive strength prediction of environmentally friendly concrete using artificial neural networks. *Journal of Building Engineering*, v. 16, n. October 2017, p. 213–219, 2018.

NEERAJA, D.; SWAROOP, G. Prediction of compressive strength of concrete using artificial neural networks. *Research Journal of Pharmacy and Technology*, v. 10, n. 1, 2017.

- NEVILLE, A. M. *Propriedades do concreto-5ª Edição*. [S.I.]: Bookman Editora, 2015.
- NGUYEN, H. *et al.* Efficient machine learning models for prediction of concrete strengths. *Construction and Building Materials*, v. 266, p. 120950, 2021.
- NGUYEN, T. *et al.* Deep neural network with high-order neuron for the prediction of foamed concrete strength. *Computer-Aided Civil and Infrastructure Engineering*, 2018.
- NIKOO, M.; TORABIAN MOGHADAM, F.; SADOWSKI, Ł. Prediction of Concrete Compressive Strength by Evolutionary Artificial Neural Networks. *Advances in Materials Science and Engineering*, 2015.
- NOGUEIRA, B. Determinação do coeficiente de conformação superficial de barras de aço para uso em concreto armado. p. 127, 2018.
- OSUNA, E.; FREUND, R.; GIROSIT, F. Training support vector machines: an application to face detection. 1997, [S.I.]: IEEE, 1997. p. 130–136.
- PEDAMONTI, D. Comparison of non-linear activation functions for deep neural networks on MNIST classification task. *arXiv preprint arXiv:1804.02763*, n. 3, 2018.
- PEDREGOSA, F. *et al.* Scikit-learn: Machine learning in Python. *Journal of machine learning research*, v. 12, n. Oct, p. 2825–2830, 2011.
- REBELO, L. D. T. Avaliação automática do resultado estético do tratamento conservador do cancro da mama. 2008.
- REDDY, T. C. S. Predicting the strength properties of slurry infiltrated fibrous concrete using artificial neural network. *Frontiers of Structural and Civil Engineering*, v. 12, n. 4, p. 490–503, 2018.
- REUTER, U.; SULTAN, A.; REISCHL, D. S. A comparative study of machine learning approaches for modeling concrete failure surfaces. *Advances in Engineering Software*, v. 116, n. July 2017, p. 67–79, 2018.
- RINCHON, J. P. M.; CONCHA, N. C.; CALILUNG, M. G. V. Reinforced concrete ultimate bond strength model using hybrid neural network-genetic algorithm. *HNICEM 2017 - 9th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management*, v. 2018-Janua, n. December, p. 1–6, 2017.
- SABĂU, M. Simulated data on bond of steel reinforcement in self-compacting concrete. *Data in Brief*, v. 30, p. 105594, 2020.
- SAMUI, P. Determination of compressive strength of concrete by statistical learning algorithms. *Engineering Journal*, 2013.
- SANCAK, E. Prediction of bond strength of lightweight concretes by using artificial neural networks.

- Scientific Research and Essays*, v. 4, n. 4, p. 256–266, 2009.
- SARLE, W. S. Neural networks and statistical models. *Proceedings of the Nineteenth Annual SAS Users Group International Conference*, 1994.
- SCHOLKOPF, B.; SMOLA, A. J. Learning with kernels: support vector machines, regularization, optimization, and beyond. *IEEE Transactions on Neural Networks*, v. 16, n. 3, p. 781–781, 2001.
- SHAO, J. Linear model selection by cross-validation. *Journal of the American statistical Association*, v. 88, n. 422, p. 486–494, 1993.
- SHARIATI, M. *et al.* A novel hybrid extreme learning machine–grey wolf optimizer (ELM-GWO) model to predict compressive strength of concrete with partial replacements for cement. *Engineering with Computers*, 2020.
- SHIRGIR, B.; MAMDOOHI, A. R.; HASSANI, A. Prediction of Pervious Concrete Permeability and Compressive Strength Using Artificial Neural Networks. *International Journal of Transportation Engineering*, v. 2, n. 4, p. 307–316, 2015.
- SULTANA, N. *et al.* Soft computing approaches for comparative prediction of the mechanical properties of jute fiber reinforced concrete. *Advances in Engineering Software*, v. 149, n. July, p. 102887, 2020.
- SUYKENS, J. A. K.; VANDEWALLE, J. Least squares support vector machine classifiers. *Neural processing letters*, v. 9, n. 3, p. 293–300, 1999.
- TANYILDIZI, H. Prediction of the strength properties of carbon fiber-reinforced lightweight concrete exposed to the high temperature using artificial neural network and support vector machine. *Advances in Civil Engineering*, v. 2018, 2018.
- TORKY, A. A.; ABURAWWASH, A. A. A Deep Learning Approach to Automated Structural Engineering of Prestressed Members. *International Journal of Structural and Civil Engineering*, v. 7, n. 4, p. 347–352, 2018.
- VALE SILVA, B. *Investigação do potencial dos ensaios APULOT e pull-out para estimativa da resistência a compressão do concreto*. 2010. UNESP, 2010.
- WANG, L.; WANG, G.; ALEXANDER, C. A. Big data and visualization: methods, challenges and technology progress. *Digital Technologies*, v. 1, n. 1, p. 33–38, 2015.
- YASEEN, Z. M. *et al.* Predicting compressive strength of lightweight foamed concrete using extreme learning machine model. *Advances in Engineering Software*, 2018.
- YEH, I.-C. Analysis of Strength of Concrete Using Design of Experiments and Neural Networks. *Journal of Materials in Civil Engineering*, v. 18, n. 4, p. 597–604, 2006.

YU, Y. *et al.* A novel optimised self-learning method for compressive strength prediction of high performance concrete. *Construction and Building Materials*, v. 184, p. 229–247, 2018.

ZHANG, M.-L.; ZHOU, Z.-H. Improve multi-instance neural networks through feature selection. *Neural Processing Letters*, v. 19, n. 1, p. 1–10, 2004.