



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ESTRUTURAL E CONSTRUÇÃO CIVIL
GRADUAÇÃO EM ENGENHARIA CIVIL

LUCIANY LOPES PINHEIRO

**USO DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE
PROPRIEDADES DE RESISTÊNCIA À COMPRESSÃO DE CONCRETOS DE ALTO
DESEMPENHO E DE ULTRA ALTO DESEMPENHO**

FORTALEZA

2022

LUCIANY LOPES PINHEIRO

USO DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE
PROPRIEDADES DE RESISTÊNCIA À COMPRESSÃO DE CONCRETOS DE ALTO
DESEMPENHO E DE ULTRA ALTO DESEMPENHO

Monografia submetida à Coordenação do curso de Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para obtenção do Título de Engenheira Civil.

Orientador: Prof. Dr. Lucas Feitosa de Albuquerque Lima Babadopulos

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- P72u Pinheiro, Luciany Lopes.
Uso de ferramentas de inteligência artificial para previsão de propriedades de resistência à compressão de concretos de alto desempenho e de ultra alto desempenho / Luciany Lopes Pinheiro. – 2022.
88 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Civil, Fortaleza, 2022.
Orientação: Prof. Dr. Lucas Feitosa de Albuquerque Lima Babadopulos.
1. Concreto de alto desempenho (CAD). 2. Concreto de ultra alto desempenho (CUAD). 3. Dosagem de concreto. 4. Aprendizagem de máquina. 5. Análise de dados. I. Título.
- CDD 620
-

LUCIANY LOPES PINHEIRO

USO DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE
PROPRIEDADES DE RESISTÊNCIA À COMPRESSÃO DE CONCRETOS DE ALTO
DESEMPENHO E DE ULTRA ALTO DESEMPENHO

Monografia submetida à Coordenação do curso
de Engenharia Civil da Universidade Federal
do Ceará, como requisito parcial para obtenção
do Título de Engenheira Civil.

Aprovada em 19/07/2022.

BANCA EXAMINADORA

Prof. Dr. Lucas Feitosa de Albuquerque Lima Babadopulos (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Jorge Barbosa Soares
Universidade Federal do Ceará (UFC)

Prof. Dr. Marcelo Bruno de Almeida Veras
Universidade Federal do Ceará (UFC)

FORTALEZA

2022

Don't waste your time or time will waste you.

AGRADECIMENTOS

Aos meus pais, Ediane e Luciano, por todo o suporte e por sempre acreditarem em mim. Também agradeço à minha avó por sempre fazer tudo por mim e participar desta conquista.

Agradeço à Neyliane e Larissa que acreditaram em mim desde a minha entrada na UFC por todos os momentos e vamos marcar aquele churrasco na Alemanha.

Além disso, agradeço aos meus amigos Tereza, Matheus, Ranielly e Mariana por compartilharem essa jornada comigo desde o início nas alegrias e tristezas e estarem comemorando comigo hoje depois de tudo. Obrigada pela amizade!

Ao Igor que me ajudou muito nesse fim de trajetória, trabalhamos juntos no grupo de pesquisa e é um amigo que também levarei para a vida.

Por fim agradeço ao meu professor orientador Lucas Babadopulos, por compartilhar o seu tempo e conhecimento que me deu a oportunidade de realizar esta pesquisa, além disso por ser inspiração de comprometimento e participar ativamente de melhorias na universidade.

RESUMO

Os avanços na produção de concreto estão acelerados, possibilitando a confecção de concretos mais resistentes. Concretos de alto desempenho (CAD) já fazem parte do cotidiano das principais concreteiras, assim como se espera para Concretos de ultra alto desempenho (CUAD). Todavia seus métodos de dosagem não acompanharam o avanço no seu desenvolvimento, demandando tempo e recurso nos processos de formulação. Devido ao fato de a maioria dos métodos de dosagem utilizarem gráficos e tabelas com capacidade limitada de previsão para novos concretos, estes requerem sucessões de ajustes de traço. Desta forma, faz-se necessária a criação de novas ferramentas capazes de analisar a influência dos materiais constituintes da mistura e prever o comportamento do concreto a partir de uma dada composição. Para esta tarefa, os modelos de aprendizagem de máquina são opções potenciais, pois vêm sendo aplicados nas mais diversas áreas para previsão a partir de conjuntos complexos de variáveis de entrada. Áreas de saúde, economia e engenharia civil são exemplos das que já usam frequentemente estes modelos. Na engenharia civil, um problema relevante é justamente o da previsão de comportamento dos mais diversos tipos de concreto a partir de sua composição. As características mais estudadas são a resistência, a trabalhabilidade e a durabilidade. Os CADs e CUADs em geral são muito fluidos e nem sempre a literatura detalha o comportamento no estado fresco, então o foco do presente trabalho foi a resistência à compressão. Logo, este trabalho desenvolveu ferramentas de previsão de resistência à compressão para ambos utilizando bancos de dados atualizados pela pesquisa a partir de estudos publicados na literatura. Na análise exploratória preliminar, constatou-se que esses dois tipos de concreto têm diferenças acentuadas e não é recomendada uma análise conjunta. Separadamente, foram analisadas as correlações e influências dos materiais constituintes na resistência à compressão. Para a criação da ferramenta de previsão, foram testados modelos de Regressão Linear, de Árvore de Regressão, de Floresta Aleatória e de Rede Neural Artificial (RNA) com o processo de validação cruzada. O modelo de RNA apresentou melhor performance de predição, apresentando os valores de R^2 igual a 0,85 para CAD e 0,86 para CUAD. Os melhores modelos foram, em seguida, analisados por meio de análise de sensibilidade para investigar a interpretação dos comportamentos dos concretos em função de suas composições e comparar com os comportamentos esperados conforme literatura. Os modelos apresentaram boa performance de previsão e interpretação física adequada.

Palavras-chave: concreto de alto desempenho (CAD); concreto de ultra alto desempenho (CUAD); dosagem de concreto; aprendizagem de máquina; análise de dados.

ABSTRACT

Advances in concrete production are accelerating, making it possible to make more resistant concretes. High performance concrete (HPC) is already part of the daily life of the main concrete companies, as expected for ultra-high performance concrete (UHPC) in the future. However, its dosage methods did not follow the progress in its development, demanding time and resources in the formulation processes. Since most dosage methods use graphs and tables with limited predictive capacity for new concretes, these require a succession of mix adjustments. In this way, it is necessary to create new tools capable to analyse the influence of the materials in the mixture and predict the behaviour of concrete from a given composition. For this task, machine learning models are potential options, as they have been applied in the most diverse areas for prediction from complex sets of input variables. Health, economics and civil engineering are examples of those that already frequently use these models. In civil engineering, a relevant problem is precisely that of predicting the behaviour of the most diverse types of concrete based on their composition. The most studied characteristics are strength, workability and durability. HPC and UHPC in general are very fluid and the literature does not always detail the behavior in the fresh state, so the focus of the present work was the compressive strength. Therefore, this work developed compressive strength prediction tools for both databases updated by this research from studies published in the literature. In the preliminary exploratory analysis, it was found that these two types of concrete have great differences and a joint analysis is not recommended. Separately, the correlations and influences of the constituent materials on the compressive strength were analysed. For the creation of the prediction tool, Linear Regression, Regression Tree, Random Forest and Artificial Neural Network (ANN) models were tested with the cross-validation process. The ANN model presented better prediction performance with a R^2 values equal to 0.85 for HPC and 0.86 for UHPC. The best models were then analysed by its sensitivity to investigate the interpretation of concrete behaviour as a function of its composition and compare with the expected behaviour according to the literature. The models showed good prediction performance and adequate physical interpretation.

Palavras-chave: high performance concrete (HPC); ultra-high performance concrete (UHPC); concrete dosing; machine learning; data analyses.

LISTA DE FIGURAS

Figura 1 – Comparação dos valores reais e previstos de resistência à compressão confinada utilizando um modelo de RNA.....	6
Figura 2 - Representação do traço de concreto.....	10
Figura 3 – Representação do processo realizado ao utilizar o método de dosagem de Aïtcin (2000)	11
Figura 4– Representação do ponto de saturação do superplastificante no decorrer do tempo de escoamento	12
Figura 5 - Passarela Seonyu, Coréia do Sul com um vão livre de 120m feito com CUAD	18
Figura 6 – Efeito da cinza volante e sílica ativa na resistência à compressão de CAD	20
Figura 7 – Efeito da sílica ativa na resistência à compressão de CUAD.....	21
Figura 8 – Efeito da Sílica Ativa na resistência à compressão de CAD.....	21
Figura 9 – Efeito das fibras no controle de fissuração do concreto.....	22
Figura 10 - Efeito das fibras de aço na resistência à compressão de CUAD	23
Figura 11 – Ilustração do funcionamento de um modelo de árvore de regressão	24
Figura 12 – Ilustração esquemática do funcionamento de um modelo de <i>Random Forest</i>	25
Figura 13 – Comparação da resistência à compressão observada e prevista de CUAD utilizando um modelo de <i>Random Forest</i>	26
Figura 14 – Estrutura de uma Rede Neural Artificial.....	27
Figura 15 – Comparação da resistência experimental e prevista de CUAD utilizando um modelo de RNA	28
Figura 16 – Comparação do <i>slump</i> medido e previsto de CAD utilizando um modelo de RNA	28
Figura 17 – Ilustração do funcionamento do método <i>K-Fold</i> de validação cruzada.....	29
Figura 18 – Representação ilustrativa dos erros de predição	30
Figura 19 – Ajuste do modelo de RNA desenvolvido por Hakim <i>et al.</i>	32
Figura 20 – Resultados modelo de Floresta aleatória em treino e teste	32
Figura 21 – Comparação da resistência real com as previstas pelos modelos de RNA de Moretti (2010)	33
Figura 22 – Representação da Metodologia Aplicada neste trabalho	34
Figura 23 – Mapa da origem dos dados utilizados nos bancos de dados	35
Figura 24 – <i>Pairplot</i> de correlação entre os materiais e a resistência à compressão.....	46
Figura 25 – Mapa de calor de correlação entre atributos com as bases de dados mescladas ...	47

Figura 26 – Distribuição dos dados para a base de dados de CAD em histograma	48
Figura 27 – <i>Boxplots</i> e identificação de <i>outliers</i> nas variáveis na base de dados de CAD	49
Figura 28 – Mapa de calor de correlação entre atributos da base de dados de CAD	50
Figura 29 – Gráficos <i>pairplot</i> da influência das variáveis na resistência à compressão de CAD	51
Figura 30 – Comparação valores reais e valores previstos de resistência à compressão de CAD para os modelos de previsão testados	52
Figura 31 – Gráficos de dependência parcial entre as variáveis da base de dados de CAD e a resistência à compressão.....	53
Figura 32 – Influência de diferentes materiais na resistência à compressão do CAD.....	54
Figura 33 – Influência do consumo de água para diferentes quantidades de cimento e superplastificante na resistência de CAD	56
Figura 34 – Influência do consumo de superplastificante para diferentes quantidades de cimento na resistência à compressão de CAD.....	57
Figura 35 – Influência do consumo de agregado miúdo na resistência de à compressão de CAD.....	57
Figura 36 – Distribuição das variáveis da base de dados de CUAD em histograma	59
Figura 37 – <i>Boxplots</i> e identificação de <i>outliers</i> nas variáveis da base de dados de CUAD ...	60
Figura 38 – Mapa de calor de correlação das variáveis da base de dados de CUAD.....	61
Figura 39 – Gráficos <i>pairplot</i> com a influência das variáveis na resistência à compressão de CUAD.....	62
Figura 40 – Comparação valores reais e valores previstos de resistência à compressão de CUAD para os modelos de previsão testados.....	64
Figura 41 – Dependência parcial entre as variáveis da base de dados de CUAD e a resistência à compressão.....	65
Figura 42 – Influência de diferentes materiais na resistência à compressão de CUAD	67
Figura 43 – Influência do consumo de água e superplastificante na resistência à compressão de CUAD	69
Figura 44 – Influência da substituição de cimento por adições na resistência à compressão de CUAD.....	70
Figura 45 – Influência de agregado miúdo na resistência à compressão de CUAD	71

LISTA DE TABELAS

Tabela 1 – Classificação de concretos de cimento Portland quanto a resistência dada pela ABNT NBR 8953:2015	14
Tabela 2 – Classificação de CAD pela resistência	14
Tabela 3 - Classificação de CUAD pela resistência aos 28 dias de acordo com diversos pesquisadores.....	17
Tabela 4 – Efeito de diferentes tipos de cura na resistência à compressão de CUAD	19
Tabela 5 – Métricas dos modelos utilizados por Muliauwan <i>et al.</i>	31
Tabela 6 – Estruturas de RNA testadas por Moretti (2010)	33
Tabela 7 – Resumo de referências que compõem a base de dados de CAD	36
Tabela 8 – Informações incluídas na base de dados de CAD e suas unidades de medida	36
Tabela 9 – Informações sobre os materiais utilizados nas pesquisas de CAD	37
Tabela 10 – Resumo de referências que compõem a base de dados de CUAD	37
Tabela 11 – Informações incluídas na base de dados de CUAD e suas unidades de medida ..	38
Tabela 12 – Informações sobre os materiais utilizados nas pesquisas de CUAD	39
Tabela 13 – Hiperparâmetros utilizados em cada modelo de previsão	40
Tabela 14 – Traços de referência de CAD e CUAD usados nas análises de sensibilidade.....	42
Tabela 15 – Massas específicas utilizadas no estudo paramétrico	44
Tabela 16 - Variáveis utilizadas no processo de previsão	45
Tabela 17 – Métricas de desempenho de cada modelo utilizado na previsão da resistência à compressão de CAD	51
Tabela 18 - Métricas de desempenho de cada modelo utilizado na previsão da resistência à compressão de CUAD	63

SUMÁRIO

1	INTRODUÇÃO	5
2	PROBLEMA E PERGUNTAS DE PESQUISA.....	7
2.1	Problema de pesquisa.....	7
2.2	Questões motivadoras	7
3	OBJETIVOS.....	8
3.1	Objetivo geral	8
3.2	Objetivos específicos	8
4	REVISÃO BIBLIOGRÁFICA.....	9
4.1	Concreto.....	9
4.1.1	Estado fresco do concreto.....	9
4.1.2	Estado endurecido do concreto.....	9
4.1.3	Dosagem do concreto	10
4.1.4	Aditivos	12
4.2	Concreto de alto desempenho (CAD).....	12
4.2.1	Aplicações de concreto de alto desempenho (CAD).....	13
4.2.2	Classificação e características	13
4.2.3	Dosagem de concreto de alto desempenho.....	15
4.3	Concreto de ultra alto desempenho (CUAD).....	16
4.3.1	Classificação	16
4.3.2	Aplicações	17
4.3.3	Dosagem.....	18
4.3.3	Cura	19
4.4	Adições	19
4.5	Inteligência artificial	23
4.5.1	Modelos	23
4.5.2	Método de validação cruzada	29

4.5.3	Métricas	29
4.6	Trabalhos relacionados	31
5	METODOLOGIA	34
5.1	Atualização da base de dados	34
5.1.1	Base de dados de concreto de alto desempenho	35
5.1.2	Base de dados de concreto de ultra alto desempenho.....	37
5.2	Análise preliminar dos dados.....	39
5.3	Desenvolvimento da ferramenta	40
5.4	Análise dos modelos	41
5.4.1	Análise de sensibilidade	41
5.4.2	Análise paramétrica	42
6	RESULTADOS.....	45
6.1	Análise preliminar com as bases de dados mescladas	45
6.1.1	Tratamento dos dados	45
6.1.2	Análise preliminar dos dados	45
6.2	Análise da base de dados de concreto de alto desempenho	48
6.2.1	Visualização dos dados.....	48
6.2.2	Análise preliminar dos dados	50
6.2.3	Modelos de previsão.....	51
6.2.4	Análise de sensibilidade	52
6.3	Análise da base de dados de concreto de ultra alto desempenho.....	58
6.3.1	Tratamento dos dados.....	58
6.3.2	Análise preliminar dos dados	61
6.3.3	Modelos de previsão	62
6.3.4	Análise de sensibilidade	64
7	CONCLUSÃO E RECOMENDAÇÕES	72
	REFERÊNCIAS	76

1 INTRODUÇÃO

O concreto é o mais importante material estrutural e de construção civil da atualidade, mesmo sendo o mais recente, e é considerado uma das descobertas mais interessantes para o desenvolvimento humano e sua qualidade de vida (ISAIA; TUTIKIAN; HELENE, 2011). Além dos seus materiais básicos (cimento, água e agregados), outros materiais como cinza volante, escória e nanosílica vêm sendo implementados para melhorar a resistência e durabilidade de certos tipos de concreto. Entre eles, destacam-se os concretos de alto desempenho (CAD) (NAJIGIVI *et al.*, 2013). Por mais que o CAD seja considerado um material novo ele, na verdade vem sendo desenvolvido gradualmente e sua definição e classificação tem mudado já que antigamente resistências hoje consideradas comuns eram inalcançáveis, assim como continuará mudando com o desenvolvimento de materiais ainda mais resistentes como o concreto de ultra alto desempenho (CUAD) (ACI, 1997), que normalmente não apresenta agregados graúdos (maiores que 4,75mm), tipicamente apresentando apenas agregados de até cerca de 1mm de diâmetro máximo característico.

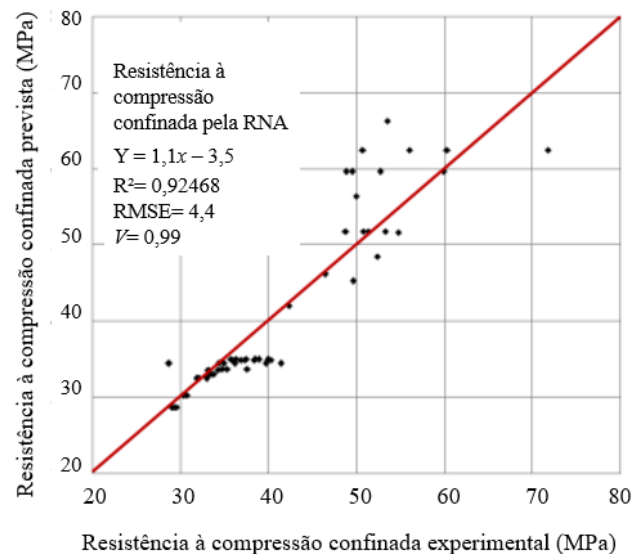
O desenvolvimento de CADs e CUADs é fruto da necessidade de construir em ambientes agressivos mantendo a resistência das estruturas, tendo o concreto evoluído para proporcionar o desenvolvimento de misturas com excelente trabalhabilidade, resistência, estabilidade dimensional e elevada durabilidade (SILVA; GARCIA, 2020). Hoang *et al.* (2016) comentam que geralmente materiais especiais são utilizados para desenvolver esses tipos de concreto satisfazendo requisitos de resistência e durabilidade.

Najigivi *et al.* (2013) trazem a discussão de que convencionalmente esses tipos de concretos podem ser formulados utilizando dados empíricos de experimentos já realizados. Há muita experiência de tecnólogos do concreto envolvida e uso de tabelas e gráficos sobre concretos do passado na intenção de prever comportamento dos concretos a serem formulados. Porém, a experiência é humanamente limitada, já que temos vários tipos de materiais com diferentes propriedades que acabam não sendo considerados. Pesquisadores estudam a capacidade de modelos de regressão mais simples como regressão linear para a modelagem da resistência à compressão do concreto, mas há outras técnicas como os modelos de inteligência artificial que tem uma capacidade superior aos modelos convencionais (HOANG *et al.*, 2016). Vem crescendo o interesse em programas de computador que podem resolver problemas complexos de maneira mais simples, e incluindo quantidade de informação dificilmente gerida pela mente humana. Sendo assim, a área da ciência de dados vem sendo aplicada cada vez mais em diversas áreas e o que mais se fala são em modelos de aprendizagem de máquina do tipo

Redes Neurais Artificiais (RNAs), que são inspirados nos neurônios biológicos (NAJIGIVI *et al.*, 2013).

Muitos pesquisadores vêm utilizando modelos de Inteligência Artificial com aprendizagem de máquina para a previsão do comportamento dos mais diversos concretos. Um pesquisador muito presente nessa área é Yeh (1998a, 1998b, 1999, 2006, 2007a, 2007b, 2008, 2009a, 2009b) que já utilizou Redes neurais para a previsão da resistência e do abatimento do tronco de cone (*slump*) de concretos com vários tipos de adições e modificações e conseguiu bons resultados em seus trabalhos. Muliauwan *et al.* (2020) trazem modelos de previsão da resistência à compressão utilizando RNA e máquina de vetor de suporte (MVS) e comparam com um modelo de regressão linear (RL). Khan, Ayub e Rafeeqi (2013) trazem comparações de um modelo de RNA e modelos matemáticos já existentes para a previsão da resistência à compressão de concreto com fibras e os resultados do modelo desenvolvido são muito satisfatórios como se pode ver no exemplo da Figura 1.

Figura 1 – Comparação dos valores reais e previstos de resistência à compressão confinada utilizando um modelo de RNA



Fonte: Adaptado de Khan, Ayub e Rafeeqi (2013)

2 PROBLEMA E PERGUNTAS DE PESQUISA

Ainda hoje, as principais ferramentas de dosagem são empíricas e envolvem grandes esforços em tentativa-e-erro onde a experiência individual do profissional e a subjetividade influem no resultado e no tempo necessário para atingi-lo. Com o uso mais frequente de concreto de alto desempenho (CAD) e concreto de ultra alto desempenho (CUAD), para os quais essas etapas são ainda mais dispendiosas, faz-se necessário estudos de aperfeiçoamento das ferramentas de dosagem, por necessidades de eficiência econômica, qualidade ou ainda por pressões por sustentabilidade (redução dos consumos de cimento com manutenção das resistências).

Nesse contexto, novas ferramentas computacionais têm o potencial de sistematizar as experiências de diversos processos de dosagem de diferentes origens e acelerar o processo de tentativa-e-erro. Trata-se do uso de ferramentas de inteligência artificial (IA) que trabalham a aprendizagem de máquina, que tratam e predizem dados de diversas naturezas, incluindo aqueles envolvidos na dosagem de concretos. Essas novas ferramentas poderão auxiliar no processo de dosagem trazendo maior celeridade, confiabilidade e objetividade aos resultados.

2.1 Problema de pesquisa

O problema que motivou este trabalho foi a dificuldade de acesso a ferramentas de dosagem eficientes disponíveis que possam acelerar o processo de dosagem de CAD e CUAD, com as quais se poderia tornar a formulação um processo mais barato e confiável. Além disso, é necessária a constante atualização de bases de dados e uma melhor faixa de classificação e diferenciação entre CAD e CUAD. Finalmente, poucos estudos abordam a influência do teor nulo de agregado graúdo no CUAD e a possibilidade de uso de uma mesma ferramenta de predição de comportamento para ambos os tipos de concreto.

2.2 Questões motivadoras

- a) Existe uma base de dados atualizada com dados de dosagem, de resistência mecânica e de fluidez para concretos de alto desempenho (CAD) e de ultra alto desempenho (CUAD)?
- b) Pode-se utilizar uma mesma ferramenta para a previsão de dados de resistência de CAD e CUAD? A falta de agregado graúdo no concreto de ultra alto desempenho traz efeitos tão diferentes e relevantes?

- c) Qual o melhor modelo de aprendizagem de máquina na previsão de dados de dosagem em todos os intervalos de resistência para CAD e CUAD? Ele é satisfatório?

3 OBJETIVOS

3.1 Objetivo geral

O objetivo geral deste trabalho é desenvolver uma ferramenta de previsão de propriedades de resistência à compressão para Concretos de Alto Desempenho (CAD) e de Ultra Alto Desempenho (CUAD) utilizando modelos de aprendizagem de máquina a partir de bancos de dados de dosagem atualizados por este trabalho.

3.2 Objetivos específicos

Pretende-se, como objetivos específicos:

- a) Produzir um banco de dados atualizado com dados de dosagem, de resistência mecânica para concretos de alto desempenho (CAD) e de ultra alto desempenho (CUAD), partindo das bases de dados já publicamente disponíveis na literatura, combinando-as com dados mais recentes publicados na literatura;
- b) Desenvolver ferramentas de previsão de resistência mecânica de CAD e CUAD, baseadas em modelos de aprendizagem de máquina;
- c) Avaliar se uma ferramenta única é capaz de prever concomitantemente a resistência mecânica tanto de CAD quanto de CUAD;

4 REVISÃO BIBLIOGRÁFICA

4.1 Concreto

Na mistura do concreto, o cimento juntamente com a água forma uma pasta que envolve os agregados, de maneira que em suas primeiras horas se apresenta em um estado capaz de ser moldado por meio de formas e com o tempo endurece adquirindo resistência mecânica, tornando-se um material com excelente desempenho estrutural (ISAIA; TUTIKIAN; HELENE, 2011).

4.1.1 Estado fresco do concreto

O concreto possui duas fases distintas, a primeira denominada estado fresco e corresponde ao período desde a mistura dos materiais que será transportada, lançada e adensada. Neste estado, a principal característica estudada é a consistência ou trabalhabilidade do concreto que é influenciada por fatores como a relação água/cimento, teor de argamassa, características dos agregados além de fatores externos como condições de transporte, lançamento e adensamento (ISAIA; TUTIKIAN; HELENE, 2011). Esta propriedade é determinante, pois o concreto deve ser transportado, lançado e adensado, sem que haja segregação (YEH, 2007). O principal método para a determinação da consistência do concreto convencional fresco é o abatimento do tronco de cone, que nos dá um parâmetro chamado *slump* (ISAIA; TUTIKIAN; HELENE, 2011). O processo de determinação do *slump* é normatizado no Brasil pela ABNT NBR NM 67 (1998). Enquanto isso, para concretos com abatimento total, utilizam-se outros ensaios, como os de *Slump Flow*, Anel J, Caixa L, entre outros que são encontrados na ABNT NBR 15823 (2017). Os CAD e os CUAD costumam apresentar abatimento total principalmente os CUADs que são considerados por Torregrosa (2013) uma combinação de concreto de alto desempenho, concreto com fibra e concreto autoadensável.

4.1.2 Estado endurecido do concreto

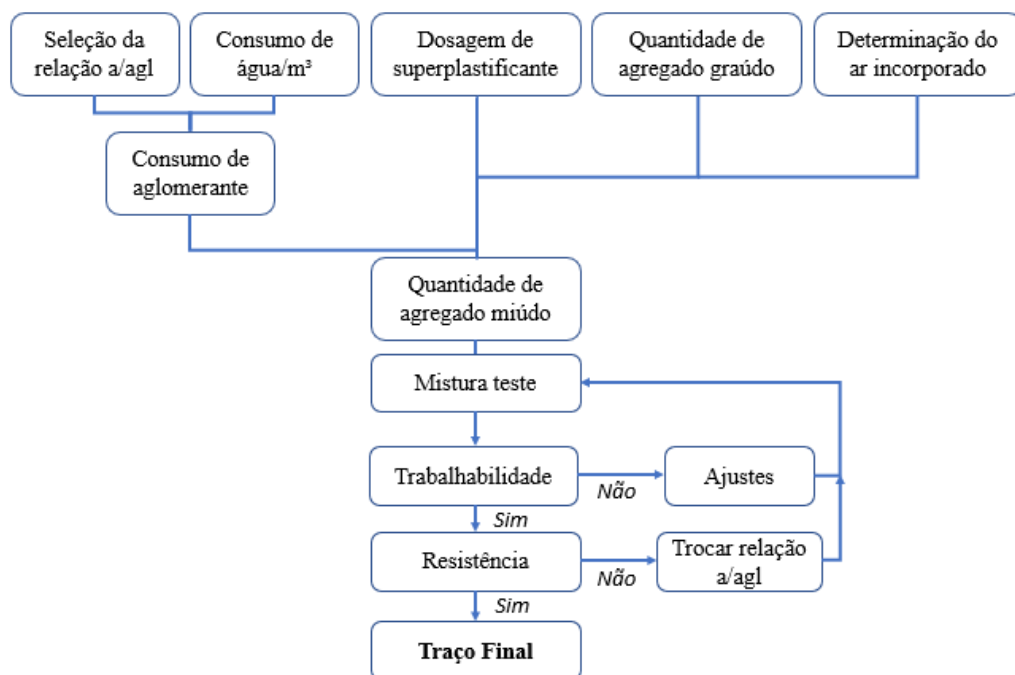
A outra fase do concreto é denominada estado endurecido e se inicia com a pega em consequência da hidratação da pasta de cimento, e ocorre depois de lançado e posteriormente endurecido permanentemente (ISAIA; TUTIKIAN; HELENE, 2011). A superfície exposta dos concretos está sujeita a ataques de agentes deteriorantes como temperatura, vento, sol, gases da atmosfera, entre outros fatores e é de vital importância focar nas propriedades do concreto nessas superfícies (WEE; SURYAVANSHI; TIN, 1999). Por isso

utilizam valores pré-estabelecidos de relação água/cimento ou do esqueleto granular para definir os valores de dosagem dos demais constituintes, baseando-se em experiência com concretos anteriores.

O método IBRACON é comentado por Tutikian e Helene (2011) como um método teórico-experimental que considera a relação água/cimento (a/c) como o parâmetro mais importante. Resumidamente o método procura a melhor proporção entre os agregados disponíveis como aquela que consome menos água para obter um abatimento pré-definido. Tal método utiliza de equações para a definição de 3 traços que são testados experimentalmente e ajustados quando necessário (TUTIKIAN; HELENE, 2011).

Já o método de Aïtcin (2000) é uma combinação de resultados empíricos e cálculos matemáticos. Segundo Isaia, Tutikian e Helene (2011) é um método simplificado que não garante a obtenção das propriedades com exatidão. Os passos do método Aïtcin (2000) são resumidos no esquema da Figura 3 onde inicialmente define-se a relação água/aglomerante (a/agl) e com isso encontramos o consumo de água, além disso utiliza-se de fórmulas matemáticas para encontrar as quantidades dos outros materiais formando um traço teste que será produzido e ajustado quando necessário.

Figura 3 – Representação do processo realizado ao utilizar o método de dosagem de Aïtcin (2000)



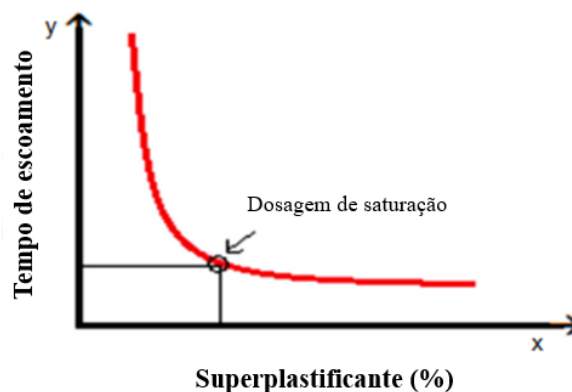
Fonte: Adaptado de Aïtcin (2000)

4.1.4 Aditivos

Existem diversos tipos de aditivos para concretos (ABNT NBR 10908:2008). A função dos aditivos plastificantes é melhorar a consistência do concreto sem aumentar a demanda de água, para assim ser possível aumentar as propriedades mecânicas e durabilidade da mistura, mantendo a consistência e sem aumento no consumo de cimento (ISAIA; TUTIKIAN; HELENE, 2011). Estes aditivos, quando utilizados em grande quantidade, podem retardar a pega do concreto e incorporar muito ar obtendo um comportamento contrário do esperado (HARTMANN; HELENE, 2003).

Segundo Yeh (2008), o superplastificante desflocula as partículas de cimento de modo que uma menor quantidade de água é suficiente para garantir uma consistência adequada. Todavia, como a quantidade de superplastificante é calculada pela quantidade de cimento haverá uma porcentagem ótima para cada mistura e acrescentar aditivo em quantidades maiores que esta produz efeitos negativos ou insignificantes, como se ilustra na Figura 4. Esse efeito é conhecido como o ponto de saturação do superplastificante (AITCIN, 1998).

Figura 4— Representação do ponto de saturação do superplastificante no decorrer do tempo de escoamento



Fonte: Adaptado de O. F. da Silva (2019)

4.2 Concreto de alto desempenho (CAD)

Parichatprecha e Nimityongskul (2009) dizem que o concreto com alta resistência e alta durabilidade é chamado concreto de alto desempenho (CAD) e seu uso vem aumentando em todo o mundo. Entende-se por alto desempenho não somente a resistência mecânica, mas também a trabalhabilidade, estética e principalmente a durabilidade (ISAIA; TUTIKIAN; HELENE, 2011). Este tipo de concreto, além de ter altas resistências, também se observa o

aumento no módulo de deformação e na durabilidade do concreto, que derivam da redução do volume de vazios (BARATA, 1998).

Kumbhar e Murnal (2014) acrescentam que o CAD se tornou muito popular, porém seu processo de dosagem é mais complicado que o processo de dosagem para o concreto convencional. Segundo Parichatprecha e Nimityongskul (2009), a essência do CAD enfatiza a utilização além dos materiais convencionais também a de materiais superplastificantes e adições minerais, o que acaba tornando seu processo de dosagem mais complicado devido ao aumento no número de materiais constituintes. O produto resultante dessas adições é um concreto que teoricamente poderia atender a qualquer solicitação de projeto, permitindo inclusive elevada esbeltez, durabilidade e segurança (ISAIA; TUTIKIAN; HELENE, 2011). Muitos modelos matemáticos foram sugeridos para explicar a relação entre os materiais e o comportamento do concreto convencional, porém não há uma solução boa o suficiente disponível para prever essas propriedades para o CAD (PARICHATPRECHA; NIMITYONGSKUL, 2009).

4.2.1 Aplicações de concreto de alto desempenho (CAD)

Segundo Lima (1997), temos várias aplicações de CAD, destacando seu uso na execução de pilares pela possibilidade de redução nas áreas de seção transversais. Além de ter sido estudado por Lima e Libório (2008) seu comportamento em baixas temperaturas, sendo um bom material para a construção de elementos para guardar e conservar alimentos.

Isaia, Tutikian e Helene (2011) trazem exemplos de obras que utilizaram CAD, entre elas temos a construção da Ponte *Stichtse*, próximo a Amsterdam com um vão principal de 160m. Ela foi inicialmente projetada com concreto convencional de classe C45 (resistência característica de 45MPa à compressão) e depois de testes foi recalculada para CAD C85 (resistência característica de 85MPa à compressão), e seu uso reduziu em 30% o volume de concreto, o peso da estrutura e o custo.

4.2.2 Classificação e características

Isaia, Tutikian e Helene (2011) afirmam que, para conseguir concretos duráveis, é necessário que na dosagem a relação água/aglomerante (a/ag) seja inferior a 0,40, porém sem prejudicar a trabalhabilidade da mistura. No Brasil não há uma classificação consolidada a respeito do CAD, mas a NBR 8953:2015 traz uma divisão em classes onde a Classe I abrange concretos com resistência até 50MPa, que poderia ser considerada a classe dos concretos

convencionais e a Classe II abrange concretos com resistência de 55 até 100MPa que poderia ser considerada a classificação para CAD, como se vê na Tabela 1.

Erro! Fonte de referência não encontrada.

Tabela 1 – Classificação de concretos de cimento Portland quanto a resistência dada pela ABNT NBR 8953:2015

Classe de resistência Grupo I	Resistência característica à compressão MPa	Classe de resistência Grupo II	Resistência característica à compressão MPa
C20	20	C55	55
C25	25	C60	60
C30	30	C70	70
C35	35	C80	80
C40	40	C90	90
C45	45	C100	100
C50	50		

Fonte: ABNT NBR 8953 (2015)

A classificação empregada para CAD muda de acordo com a região e o autor. O ACI (1997) reconhece que essa classificação depende de vários aspectos. Na Tabela 2 se veem as classificações utilizadas por alguns autores. Uma das principais características estudadas no CAD é a resistência à compressão que normalmente é maior que a resistência do concreto convencional (ISAIA; TUTIKIAN; HELENE, 2011).

Tabela 2 – Classificação de CAD pela resistência aos 28 dias de acordo com diversos pesquisadores

Autor	Resistência (MPa)
KUMBHAR e MURNAL (2014)	50 - 90
VANDERLEI (2004)	60 - 120
AYIRA (2013)	60 - 100
NBR 8953:2015	55 - 100

Fonte: Autora (2022)

4.2.3 Dosagem de concreto de alto desempenho

Considerando que temos um aumento na resistência do concreto do tipo CAD no geral, temos uma maior preocupação com os materiais, principalmente os agregados, já que, ao melhorar a pasta de cimento, eles podem se tornar o elo mais fraco da mistura (ISAIA; TUTIKIAN; HELENE, 2011). Barata (1998) discute a respeito de agregados com alta porosidade, que podem absorver muita água resultando em misturas com menor resistência. O ACI (1998) indica que o melhor tipo de agregado miúdo para CAD contém partículas arredondadas e textura suave e módulo de finura próximo de 3, e modo a proporcionar melhores resistência e trabalhabilidade. Além disso Rodrigues (1998) discute a relação entre os consumos de agregado miúdo e de água, por ter alta área específica o agregado miúdo precisa de grande quantidade de água de molhagem, então qualquer alteração no seu teor pode provocar alterações significativas no consumo de água e, conseqüentemente, na resistência à compressão. O agregado graúdo em CAD deve ter dimensões de no máximo 19mm sendo que misturas contendo agregados de 25.4mm também podem obter bons resultados, porém é recomendado que as dimensões dos agregados não sejam tão grandes pois isso aumenta a diferença entre os módulos de elasticidade dos agregados e pasta.

Além disso, segundo Isaia, Tutikian e Helene (2011), há um cuidado quanto ao tipo de cimento utilizado, sendo mais recomendados os tipos CP I e CP V ARI. Misturas com alto teor de cimento e baixo teor de água produzem concretos mais resistentes, mas nem sempre aumentar a quantidade de cimento implica o aumento da resistência já que ao aumentarmos a quantidade de materiais secos haverá maior demanda de água (ACI, 1998).

Lima e Libório (2008) atribuem o desenvolvimento do CAD à inclusão de dois tipos de materiais na mistura: (i) adições minerais para ganho de resistência, porque o tamanho dos grãos é bem menor que o grãos de cimento; e (ii) aditivos superplastificantes, que possibilitam a manutenção da trabalhabilidade e da consistência empregando uma menor relação água/cimento. Segundo Isaia, Tutikian e Helene (2011) aditivos químicos e adições minerais são os responsáveis pelo desenvolvimento acelerado do concreto nos últimos tempos.

Os mesmos métodos de dosagem são usualmente utilizados para CAD mesmo que isso implique numa grande necessidade de tempo e material por utilizar muitas iterações de tentativa e erro a fim de se encontrar uma mistura adequada (KUMBHAR; MURNAL, 2014).

4.3 Concreto de ultra alto desempenho (CUAD)

Barbosa (2021) diz que o CUAD foi desenvolvido como alternativa ao CAD e até mesmo ao aço por ser um material de alta tecnologia. Prem, Bharatkumar e Iyer (2012) afirmam que o CUAD é um tipo de concreto modificado. Os CUADs são produzidos para obter uma resistência à compressão tão elevada que a resistência e a durabilidade se assemelhem às de uma rocha, mas que apresente facilidade de ser moldado em qualquer dimensão ou forma (SILVA; GARCIA, 2020).

De acordo com Prem, Bharatkumar e Iyer (2012), os constituintes do CUAD são cimento, agregado miúdo, sílica ativa, pó de quartzo, superplastificante e pode haver inclusão de fibras de alta resistência. Alguns CUADs são submetidos a tratamento térmico. Segundo Biz (2001), a temperatura de cura do CUAD gira em torno de 90°C, mas pode-se aplicar temperaturas bem superiores em alguns casos. Esse tratamento térmico reduz efeitos de retração e fluência substancialmente, além de melhorar e muito a durabilidade (SHIN, 2016).

4.3.1 Classificação

Algumas características marcantes deste tipo de concreto são o emprego de partículas finas, muitas vezes não possuindo agregado graúdo e consumo elevado de adições minerais e aditivos superplastificantes (SILVA; GARCIA, 2020). Hassani, Khalil e Danha (2014) dizem que o tamanho máximo dos agregados fica entre 0,3 e 0,6 mm. O produto resultante permite que se trabalhe com a menor relação água/cimento possível, chegando à ordem de 0,10 a 0,20 em massa (ISAIA; TUTIKIAN; HELENE, 2011). Mesmo que a relação água/cimento seja muito pequena, o CUAD tem uma alta fluidez, sendo em sua maioria autoadensáveis, isso se devendo à adição dos agentes superplastificantes redutores de água (ZHENG *et al.*, 2022).

Barbosa (2021) frisa que a classificação destes materiais não se dá somente pela resistência à compressão, mas também por outras características e comportamentos que garantem funcionalidades superiores ao concreto convencional. Hassani, Khalil e Danha (2014) explicam que um dos princípios do CUAD é o tratamento térmico durante a cura que pode melhorar ainda mais as propriedades químicas e ajudar no aumento da resistência. Assim como acontece para CAD, no CUAD também há diferenças na classificação quanto à resistência em função das regiões e dos autores. Vê-se na Tabela 3 que o valor mais recorrente para CUAD é 150 MPa.

Tabela 3 - Classificação de CUAD pela resistência aos 28 dias de acordo com diversos pesquisadores

Autor	Resistência (MPa)
PREM, BHARATKUMAR e IYER (2012)	> 150
BARBOSA (2021)	150 - 800
VANDERLEI (2004)	200 - 800
PREM, BHARATKUMAR e MURTHY (2014)	> 150
AYIRA (2013)	180 - 200
ABUODEH, ABDALLA e HAWILEH (2020)	150 - 810

Fonte: Autora (2022)

4.3.2 Aplicações

Com a utilização do CUAD, é possível obter uma redução expressiva nas dimensões de elementos estruturais se comparado aos demais concretos, tornando possível a construção de estruturas bem mais leves com alta capacidade resistente (BARBOSA, 2021). Pensando em infraestrutura, as vantagens são muito evidentes quando falamos de CUAD por conta da sua durabilidade e ductilidade (SILVA; GARCIA, 2020).

Como dizem Wee, Suryavanshi e Tin (1999), estruturas de concreto submersas podem sofrer com corrosão das armaduras de reforço. Como o CUAD se destaca também pela sua baixíssima porosidade, ele consegue atingir uma maior resistência em ambientes agressivos, oferecendo inclusive maior proteção às armaduras existentes, o que melhora a durabilidade (BARBOSA, 2021).

Buttignol (2018) demonstrou o desempenho na utilização do CUAD em obras de reforço estrutural que levou a uma redução do custo global de reparação. Isaia, Tutikian e Helene (2011) trazem o exemplo de uma passarela de pedestres construída em Seoul (Figura 5) inaugurada em 2002 com vão livre de 120m e tabuleiro de 3cm.

Figura 5 - Passarela Seonyu, Coréia do Sul com um vão livre de 120m feito com CUAD



Fonte: Isaia, Tutikian e Helene (2011)

Muller, Koelle e Almeida (2017) trazem em seu trabalho a primeira obra no Brasil que utilizou CUAD na fabricação do painel da fachada do Escritório de Representação do Ministério das Relações Exteriores em São Paulo e foi concluída em 2016. O principal objetivo da obra era que a fachada gerasse o mínimo de cargas na estrutura do prédio para evitar a necessidade de reforço.

4.3.3 Dosagem

Assim como no CAD, Isaia, Tutikian e Helene (2011) trazem especificações sobre os materiais mais utilizados para o tipo de concreto CUAD. Considerando o constituinte cimento, os tipos mais utilizados são os mesmos do CAD, CP I e CP V ARI.

O conceito básico utilizado na confecção de CUAD é a homogeneidade e a compactidade granular e isso é trabalhado com a retirada do agradado graúdo da mistura (ISAIA; TUTIKIAN; HELENE, 2011). Apesar disso, alguns autores, como Smith e Xu (2021), trazem evidências da possibilidade de obter esse concreto utilizando agregado graúdo (basalto) com diâmetros menores que 10mm, o que, além de diminuir o custo, também permite boas características de módulo de elasticidade e de trabalhabilidade.

A mistura dos materiais no processo de fabricação de CUAD não é feito em betoneira já que isso prejudica a homogeneidade. Devido à retirada do agregado graúdo, a mistura por tombamento passa a ser ineficiente, o que torna o CUAD difícil de ser aplicado em concretos produzidos em canteiros de obra (ISAIA; TUTIKIAN; HELENE, 2011).

4.3.3 Cura

Ayira (2013) traz informações sobre os efeitos das curas com alta temperatura e alta pressão. Alguns resultados mostram que o aumento na temperatura acelera a hidratação do cimento, tendo um efeito positivo na resistência enquanto o aumento da pressão diminui a porosidade, que tem efeito na densidade. Na prática, os tratamentos de calor e pressão não são tão usados comercialmente já que demandam tempo e aumentam os custos na produção do CUAD.

Prem, Bharatkumar e Murthy (2014) estudaram os efeitos de diferentes tipos de cura para CUAD, cura com imersão em água, cura térmica com vapor e cura térmica com calor. Para a cura com água, mantiveram as amostras submersas até a idade de ruptura (3, 7, 14 e 28 dias). Para a cura com vapor, as amostras foram submetidas a uma temperatura de 100°C e umidade relativa de 95% por 18 horas e em seguida mantidas em água até o momento da ruptura. Além disso, também foram testadas amostras com cura térmica com calor utilizando uma câmara cíclica ultra térmica onde estas foram expostas a temperaturas em torno de 200°C por 48 horas e depois mantidas em água até o dia do teste de resistência. Os resultados de resistências à compressão obtidos estão na Tabela 4, onde se pode ver que a cura térmica teve grande impacto na resistência à compressão a partir dos 14 dias principalmente para a cura com calor.

Tabela 4 – Efeito de diferentes tipos de cura na resistência à compressão de CUAD

Idade (dias)	Resistência à compressão (MPa)		
	Cura com água	Cura com vapor	Cura com calor
3	53	53	53
7	64	120	160
14	111	128	185
28	144	142	196

Fonte: Adaptado de Prem, Bharatkumar e Murthy (2014)


4.4 Adições

Isaia, Tutikian e Helene (2011) trazem informações sobre a pasta cimentícia. Seu comportamento depende muito da presença das adições, que são muito comuns no processo de dosagem do CAD e CUAD. As principais adições a sílica ativa, o metacaulim, a cinza volante entre outros. Seus principais efeitos são melhorias nas características reológicas da pasta, como

coesão, fluidez, viscosidade e resistência à segregação, além de diminuir a exsudação e os vazios.

Li e Song (2022) trazem em seu estudo os efeitos da cinza volante e da sílica ativa na resistência à compressão de CAD em diferentes idades. Na Figura 6, vê-se que a resistência à compressão aumenta mais com a idade quando se usa cinza volante. Entretanto, não se vê grande influência na resistência quando a porcentagem de cinza volante é aumentada na mistura, tendo um efeito maior apenas nos 90 dias.

Figura 6 – Efeito da cinza volante e sílica ativa na resistência à compressão de CAD

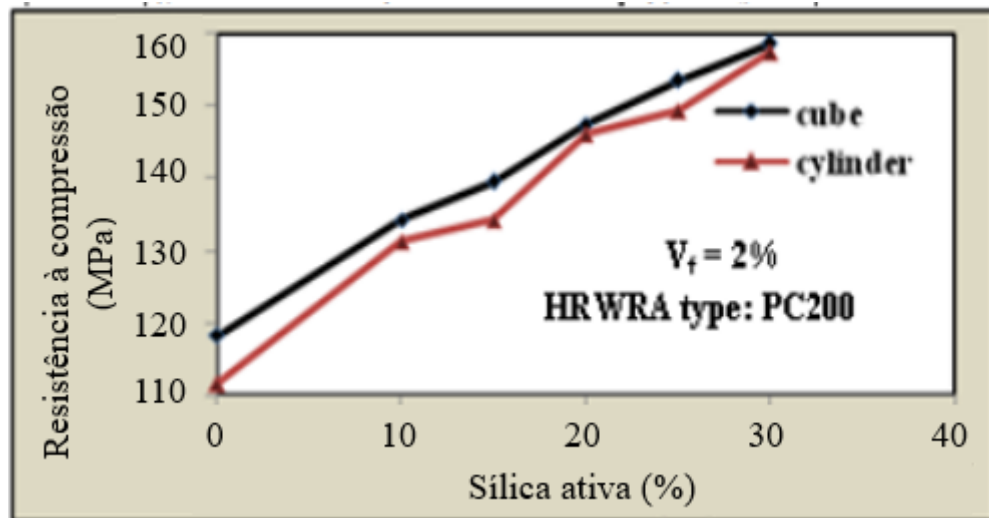


Fonte: Adaptado de Li e Song (2022)

A sílica ativa é uma adição muito recomendada e a mais utilizada principalmente para o CUAD devido a sua forma mais arredondada e tamanho muito pequeno, cerca de 100 vezes menor que o cimento (ISAIA; TUTIKIAN; HELENE, 2011). Shin (2016) enfatiza que este material constituinte tem um custo elevado, mas quando adicionado à mistura, auxilia na elevação da resistência, na redução do tamanho dos poros e na elevação da durabilidade.

Hassani, Khalil e Danha (2014) trabalharam a influência da adição da sílica em CUAD e seus estudos concluíram que a adição de sílica nas porcentagens de 10% a 30% causa um aumento considerável no valor da resistência à compressão. Tais resultados estão ilustrados na Figura 7.

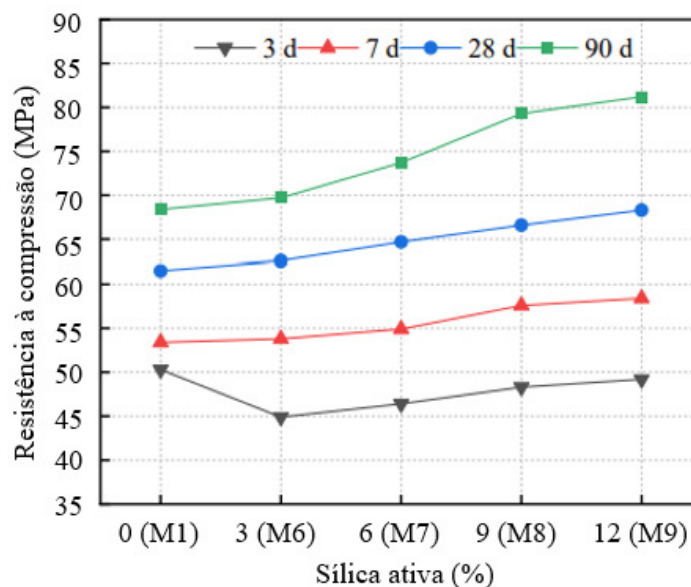
Figura 7 – Efeito da sílica ativa na resistência à compressão de CUAD



Fonte: Adaptado de Hassani, Khalil e Danha (2014)

Este efeito pode ser explicado pela ação pozolânica da sílica juntamente com o cimento, além de ajudar no empacotamento da matriz devido a sua dimensão (HASSANI; KHALIL; DANHA, 2014). Li e Song (2022) encontram resultado parecido em seu estudo com sílica ativa, ilustrado na Figura 8. Pode-se ver que há um aumento na resistência à compressão quando se aumenta a porcentagem de sílica na mistura. O mesmo efeito é observado com o aumento da idade testada.

Figura 8 – Efeito da Sílica Ativa na resistência à compressão de CAD




Fonte: Adaptado de Li e Song (2022)

Outro material muito aplicado é o pó de quartzo por ser um material muito resistente, com propriedades superiores à maioria dos materiais disponíveis para britagem (ISAIA; TUTIKIAN; HELENE, 2011). Este, quando adicionado ao CUAD, contribui com o fechamento do empilhamento granulométrico, fechando os vazios entre os grãos de areia (BIZ, 2001).

Aitcin (1998) comenta sobre os efeitos da escória, sendo que seus principais benefícios vêm da sua composição química que não varia tanto como outros materiais. O uso de escória costuma se dar conjuntamente com o uso de sílica ativa, obtendo classes de concreto com resistência até 125 MPa.

Também pode haver adição de fibras dos mais variados materiais, sendo as de aço as mais aplicadas para melhorar a ductilidade, o controle de fissuração (Figura 9) e melhorar as resistências à tração e à flexão. Isso permite em alguns casos eliminar armadura passiva (ISAIA; TUTIKIAN; HELENE, 2011).

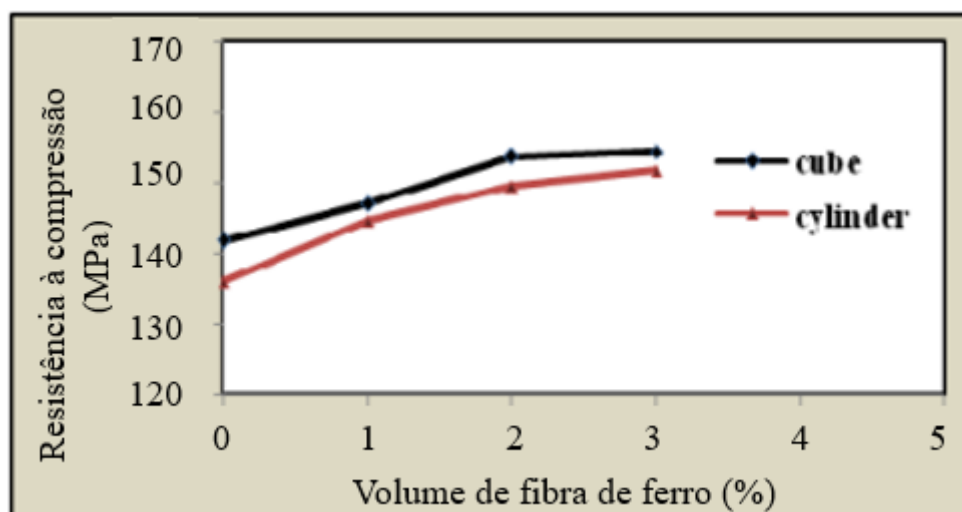
Figura 9 – Efeito das fibras no controle de fissuração do concreto



Fonte: Gaiofatto (2012)

No estudo de Hassani, Khalil e Danha (2014), foram analisados os efeitos da adição de fibras na dosagem de CUAD. Concluiu-se que a adição de fibras em 1%, 2% e 3% aumentaram a resistência à compressão em corpos de prova cilíndricos em 6,36%, 9,9% e 11,54% e 3,72%, 8,36% e 8,89%, respectivamente, e em corpos de prova em cubo como se pode ver na Figura 10.

Figura 10 - Efeito das fibras de aço na resistência à compressão de CUAD



Fonte: Adaptado de Hassani, Khalil e Danha (2014)

4.5 Inteligência artificial

Recentemente, vários pesquisadores vêm aplicando ferramentas de inteligência artificial para prever várias propriedades do concreto, sendo as principais resistência a compressão e trabalhabilidade (PARICHATPRECHA; NIMITYONGSKUL, 2009). Esta seção apresenta os principais tipos de modelos considerados neste trabalho.

4.5.1 Modelos

4.5.1.1 Regressão linear

O modelo de regressão linear determina a relação entre uma variável resposta e suas variáveis explicativas, trazendo o resultado em uma reta ou um plano com diferentes coeficientes para cada variável explicativa (MULIAUWAN *et al.*, 2020). A Equação 1 mostra o padrão para o modelo de regressão linear, onde β_i são os coeficientes de cada variável explicativa X e Y é a variável resposta.

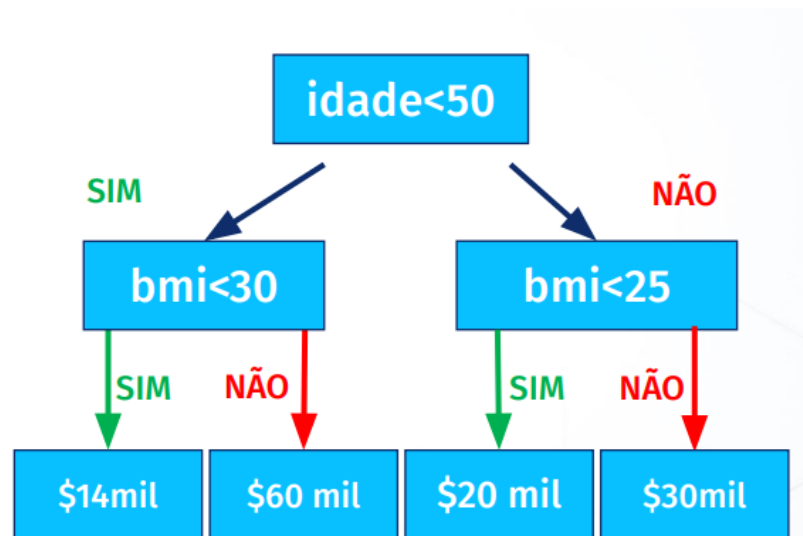
$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (\text{Equação 1})$$

Este tipo de modelo considera a existência de uma única combinação das variáveis independentes que explicam a variável resposta e nesta combinação cada variável tem o seu coeficiente que representa o quanto aquela variável influencia na variável a ser prevista. O resultado é uma equação com comportamento linear (CHOU; TSAI, 2012).

4.5.1.2 Árvore de regressão

Os modelos de árvore são utilizados tanto para problemas de classificação quanto de regressão sendo chamados de árvore de regressão quando utilizados para problema de regressão (FLAI, 2022). Segundo documentação própria da biblioteca *scikit-learn*, as árvores são modelos supervisionados não paramétricos onde o processo de predição acontece com o aprendizado de regras que segregam os dados até chegar em um valor aproximado. A principal vantagem desse tipo de modelo é que ele é facilmente interpretado já que estas árvores têm uma fácil visualização de tomada de decisão. Todavia, de acordo com o aumento da árvore, mais complexo fica seu entendimento e visualização, gerando modelos que não generalizam bem os dados. Na Figura 11, pode-se ver de forma simples o funcionamento de um modelo de árvore onde utilizando dados de idade e índice de massa corporal o modelo estima o valor a ser pago pelo plano de saúde do cliente. Vê-se que é um modelo limitado principalmente para problemas de regressão já que ao separar os dados em grupos ele acaba aproximando muitos valores.

Figura 11 – Ilustração do funcionamento de um modelo de árvore de regressão



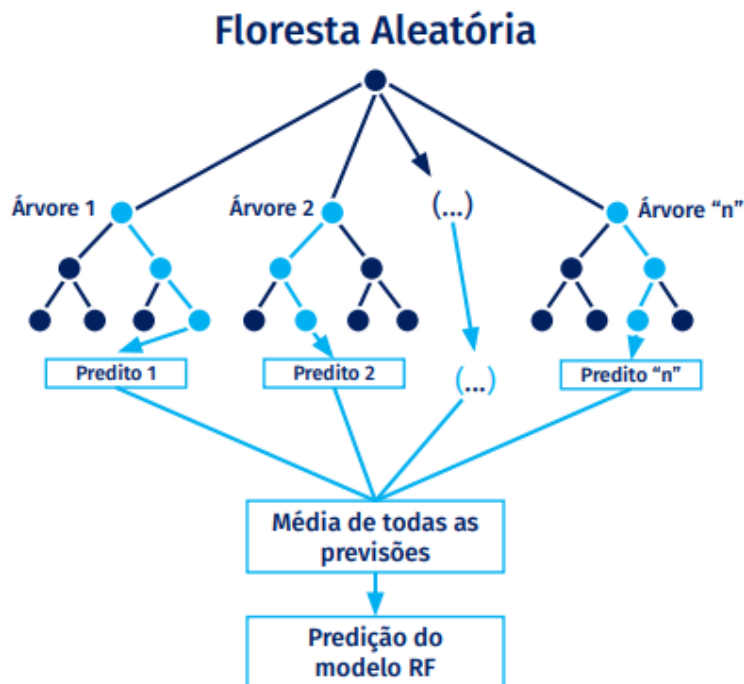
Fonte: Flai (2022)

Os principais parâmetros utilizados na criação de modelos de árvores são a profundidade máxima (*max_depth*) que diz quantas vezes a árvore pode fazer divisões e a amostra mínima para divisão (*min_samples_split*) que diz quantas amostras devem estar naquele nó para permitir a divisão da árvore (FLAI, 2022).

4.5.1.3 *Random forest*

O modelo *Random Forest* (Floresta Aleatória) é um algoritmo de aprendizagem de máquina desenvolvido por Breiman que combina métodos de classificação e regressão fazendo uma combinação de árvores (Figura 12) no processo de predição e ainda faz um *ranking* das variáveis na ordem de importância para a variável de saída sendo também uma boa ferramenta de escolha dos melhores parâmetros de entrada nos modelos (CHEN *et al.*, 2022). Marani, Jamali e Nehdi (2020) falam que a ideia fundamental desse tipo de modelo é dividir o problema de previsão em processos menos complicados, sendo eles capazes de ter uma alta acurácia no modelo de previsão além de diminuir chances de *overfitting*. Seus principais hiperparâmetros apresentados na documentação oficial do *scikit-learn* traz a profundidade máxima (*max_depth*) que diz quantas vezes a árvore pode fazer divisões, a amostra mínima para divisão (*min_samples_split*) que diz quantas amostras devem estar naquele nó para permitir a divisão da árvore, o número de árvores na estrutura (*n_estimators*) e o número de variáveis consideradas (*max_features*) (FLAI, 2022).

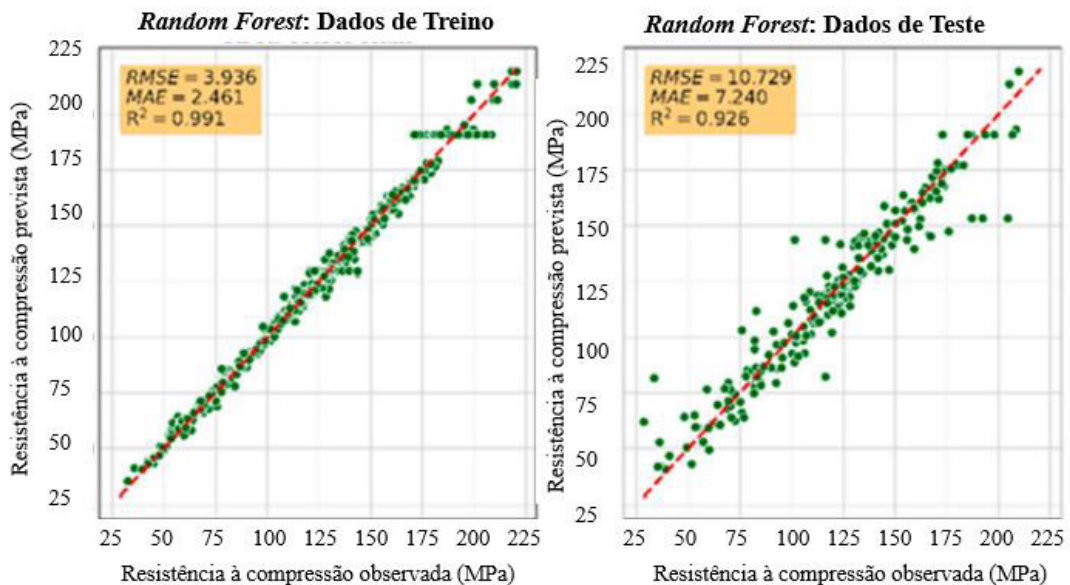
Figura 12 – Ilustração esquemática do funcionamento de um modelo de *Random Forest*



Fonte: Flai (2022)

Chen *et al.* (2022) utilizaram o modelo para otimizar o desenvolvimento de concretos de alto desempenho mais duráveis com baixo custo estudando dados dos ensaios de permeabilidade com íon cloreto. Já Marani, Jamali e Nehdi (2020) utilizaram este tipo de modelo para a previsão da resistência à compressão de CUAD. Em seu trabalho eles também utilizaram um modelo de redes geradores tabulares para criar uma base de dados plausível de acordo com os dados reais de entrada. Seu modelo de Floresta aleatória utiliza os seguintes hiperparâmetros: profundidade máxima = 22, amostra mínima para divisão = 3, número de árvores = 90 e número de variáveis consideradas = 4. Esta estrutura obteve bons resultados que podem ser vistos na Figura 13. Além disso, os dados utilizados no estudo de Marani, Jamali e Nehdi (2020) foram também utilizados neste trabalho.

Figura 13 – Comparação da resistência à compressão observada e prevista de CUAD utilizando um modelo de *Random Forest*



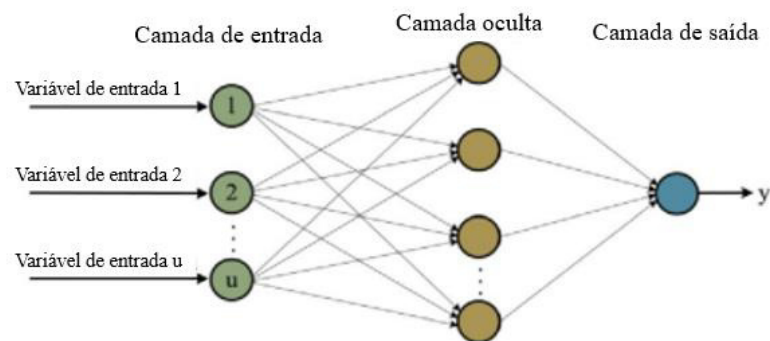
Fonte: Adaptado de Marani, Jamali e Nehdi (2020)

4.5.1.4 Redes neurais artificiais

Rede neural artificial (RNA) é um sistema computacional que simula o sistema neural biológico do ser humano como um modelo simplificado. Este modelo tenta imitar funções como aprender, pensar, lembrar e resolver problemas (PARICHATPRECHA; NIMITYONGSKUL, 2009). Hakim *et al.* (2011) trazem como definição de RNA como um sistema de processamento de dados com processos altamente conectados e uma arquitetura inspirada pela estrutura do córtex central do cérebro humano.

RNAs podem resolver problemas desafiadores de classificação, categorização, aproximação, previsão entre outros (PARICHATPRECHA; NIMITYONGSKUL, 2009). A arquitetura típica de uma RNA é composta de neurônios de entrada, onde vão as variáveis de entrada, camada oculta onde temos os neurônios ocultos que vão mapear os pesos das variáveis e a camada de saída que é a variável que queremos prever (ABUODEH; ABDALLA; HAWILEH, 2020). Na Figura 14 podemos ver a representação de uma RNA.

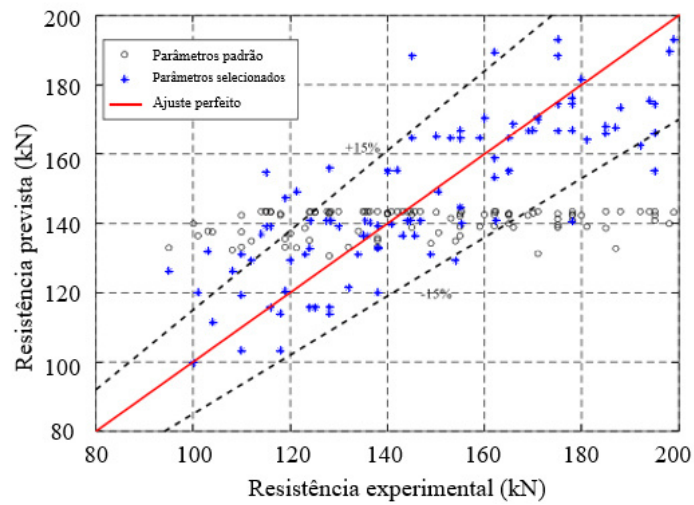
Figura 14 – Estrutura de uma Rede Neural Artificial



Fonte: Muliauwan *et al.* (2020)

O processo de aprendizagem da RNA primeiramente envolve a determinação de pesos que conectam e representam as relações entre os dados (YEH, 2009). Abuodeh, Abdalla e Hawileh (2020) estudaram os efeitos que alguns materiais têm na resistência à compressão do CUAD utilizando um modelo de RNA, chegando a ótimos resultados de previsão que são apresentados na Figura 15. Os dados de Abuodeh, Abdalla e Hawileh (2020) também foram adicionados na base de dados criada por este trabalho. Seu modelo utilizou um método de seleção sequencial de variáveis e um diagrama de interpretação neural onde estes vão auxiliar no processo de seleção das variáveis a serem consideradas no processo de previsão e tentar aumentar a acurácia do modelo criado. O modelo final utilizou 8 variáveis de entrada para a previsão da resistência à compressão e obteve um R^2 igual a 0,801.

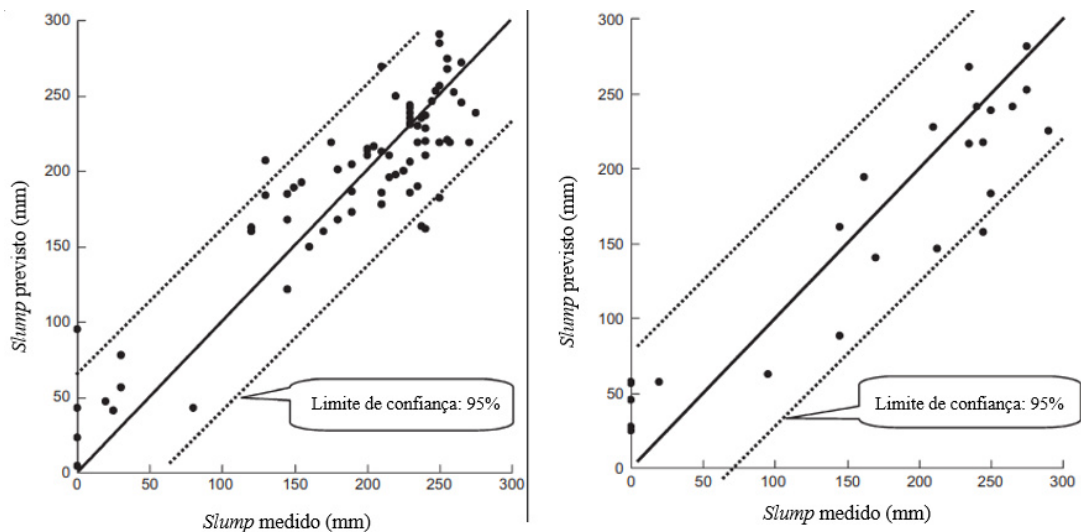
Figura 15 – Comparação da resistência experimental e prevista de CUAD utilizando um modelo de RNA



Fonte: Adaptado de Abuodeh, Abdalla e Hawileh, 2020

Yeh (1998a, 1998b, 1999, 2006, 2007a, 2007b, 2008, 2009a, 2009b) é dos autores que mais trabalhou com modelos de RNA aplicados a concretos. Em 2008, ele utilizou um modelo de RNA para a previsão de *slump* no estudo da consistência do CAD com seus resultados na Figura 16. Vê-se que a utilização destes modelos é promissora.

Figura 16 – Comparação do *slump* medido e previsto de CAD utilizando um modelo de RNA



Fonte: Adaptado de Yeh (2008)

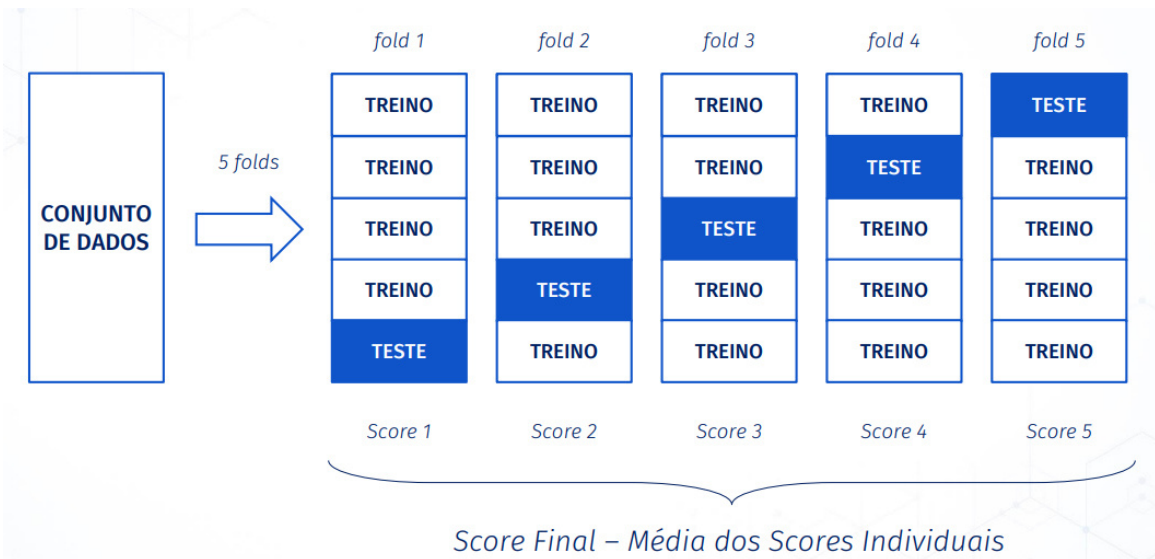
O modelo de Rede neural artificial é aplicado pelo *scikit-learn* com o código de perceptron multicamada (*MLPRegressor*) que utiliza como principais parâmetros a função de

ativação (*activation*), número de camadas, número de neurônios e número máximo de interações (*max_iter*) (FLAI, 2022).

4.5.2 Método de validação cruzada

Nos métodos de validação dos modelos de *machine learning*, o usual é separar o banco de dados aleatoriamente em dados de treino e dados de teste. Porém, pesquisadores, como Chou e Tsai (2012), vêm usando o método *K-Fold* de validação cruzada que divide a base de dados em K grupos e para cada um destes grupos são divididos aleatoriamente os dados que vão para treino e teste. A Figura 17 mostra um exemplo com a divisão em 5 grupos (FLAI, 2022).

Figura 17 – Ilustração do funcionamento do método *K-Fold* de validação cruzada

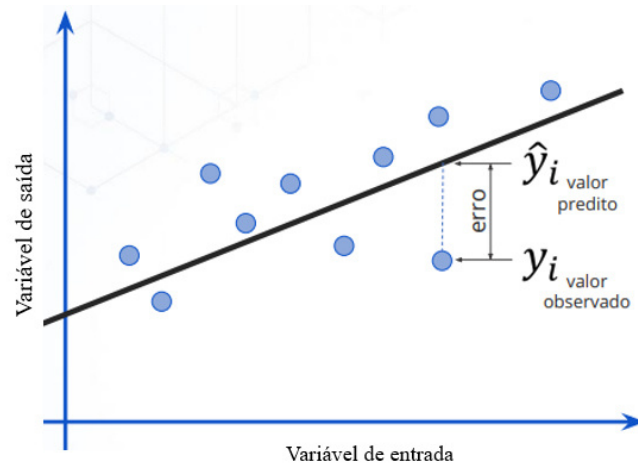


Fonte: Flai (2022)

4.5.3 Métricas

Diferentes métricas podem ser utilizadas no processo de escolha dos modelos, em que se avalia o poder de predição de cada modelo de acordo com os erros que estes cometem. As métricas utilizadas neste trabalho comparam os valores reais observados e os valores previstos. Na Figura 18, pode-se ver como acontece essa comparação e por meio dela serão calculadas as métricas utilizadas.

Figura 18 – Representação ilustrativa dos erros de predição



Fonte: Flai (2022)

4.5.3.1 Erro quadrático médio (MSE)

O erro quadrático médio (Equação 2) corresponde à média do erro quadrático analisando a distância média de um ponto previsto até a reta de ajuste como representado na Figura 18 (CHOU *et al.*, 2011). Chai e Draxler (2014) comentam que o MSE personaliza a variação do erro dando maior peso a erros com um valor absoluto maior.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (\text{Equação 2})$$

4.5.3.2 Erro absoluto quadrático (MAE)

Assim como o MSE, o MAE também analisa a diferença entre o valor real e o valor previsto, porém, diferentemente do MSE, o MAE dá o mesmo peso para todos os erros (CHAI; DRAXLER, 2014). A fórmula do MAE pode ser visualizada Equação 3.

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (\text{Equação 3})$$

4.5.3.3 Coeficiente de determinação (R^2)

O coeficiente de determinação (R^2) é a medida de quão bem as variáveis independentes explicam a variável resposta, quanto maior seu valor melhor a capacidade de predição do modelo (CHOU *et al.*, 2011), com intervalo entre 0 e 1. Pode-se calcular seu valor com a fórmula presente na Equação 4.

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (\text{Equação 4})$$

Onde \hat{y}_i é o valor predito e y_i é o valor real observado para as equações apresentadas como podemos ver na Figura 18 já apresentada.

4.6 Trabalhos relacionados

As ferramentas de inteligência artificial já vêm sendo desenvolvidas para os mais diversos tipos de problemas. Na engenharia civil e tecnologia do concreto temos vários exemplos que trazem soluções de previsão da resistência à compressão de vários tipos de concreto.

Muliauwan *et al.* (2020) utilizou modelos de Rede neural artificial (RNA), máquina de suporte de vetor (MSV) e regressão linear (LR) na previsão da resistência à compressão. Em seu estudo além de utilizar cada modelo separadamente ele testa várias combinações de modelos a fim de encontrar o melhor modelo preditivo. As métricas se encontram na Tabela 5 onde vemos que o melhor modelo é o de RNA.

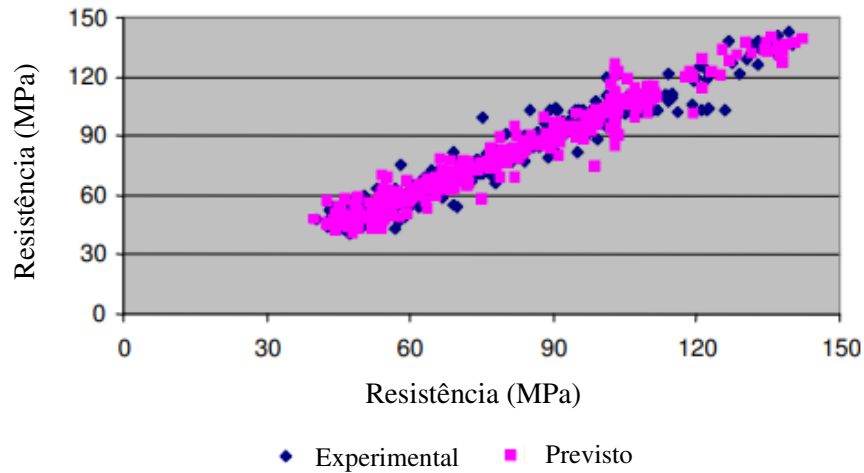
Tabela 5 – Métricas dos modelos utilizados por Muliauwan *et al.*

Métodos	R ²	MAE
RNA	0,909	5,550
MSV	0,779	8,687
LR	0,768	8,634
RNA + MSV + LR	0,855	7,103
RNA + MSV	0,883	6,622
RNA + LR	0,876	6,504
MSV + LR	0,774	8,607

Fonte: Adaptado de Muliauwan *et al.* (2020)

Outro exemplo de ferramenta foi desenvolvido por Hakim *et al.* (2011) na previsão de resistência à compressão de concreto de alta resistência utilizando um modelo de RNA. Foram utilizadas 8 variáveis independentes que formaram a camada de entrada, além disso a estrutura da rede neural contava com duas camadas intermediárias, sendo a primeira com 10 neurônios e a segunda com 6 neurônios e por fim um neurônio de saída. Trazendo um bom ajuste como podemos ver na Figura 19.

Figura 19 – Ajuste do modelo de RNA desenvolvido por Hakim *et al.*

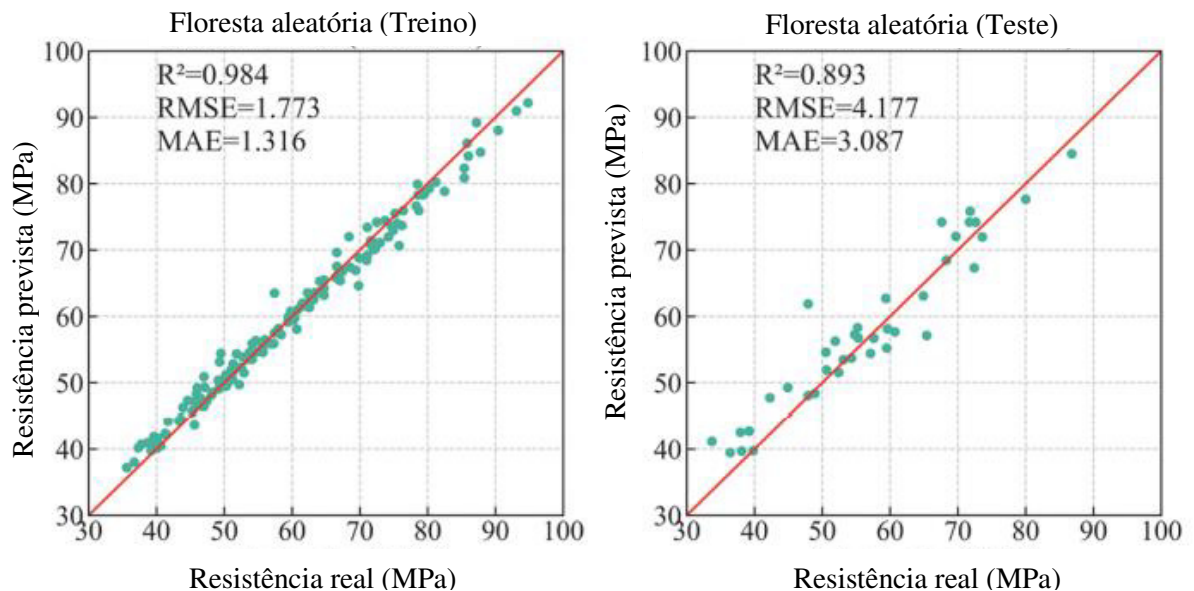


Fonte: Adaptado de Hakim *et al.* (2011)

Já Li e Song (2022) trazem modelos diversos em especial um modelo de Floresta aleatória trazendo bons ajustes como vemos na

Figura 20, com valores de R^2 de treino igual a 0,984 e R^2 de teste igual a 0,893. A estrutura utilizada tinha número de árvores igual a 100 e dimensão máxima igual a 12.

Figura 20 – Resultados modelo de Floresta aleatória em treino e teste



Fonte: Adaptado de Li e Song (2022)

Uma pesquisa feita no Brasil por Moretti (2010) traz modelos de RNA com até 4 camadas como vemos na Tabela 6.


Tabela 6 – Estruturas de RNA testadas por Moretti (2010)

Número de Neurônios da Rede Neural				
RNA	Camada 1	Camada 2	Camada 3	Camada 4
Rede 1	7	10	1	0
Rede 2	7	14	7	1

Fonte: Moretti (2010)

Além disso vemos na Figura 21 que as duas redes neurais utilizadas na definição da resistência obtiveram resultados similares e eficientes.

Figura 21 – Comparação da resistência real com as previstas pelos modelos de RNA de Moretti (2010)

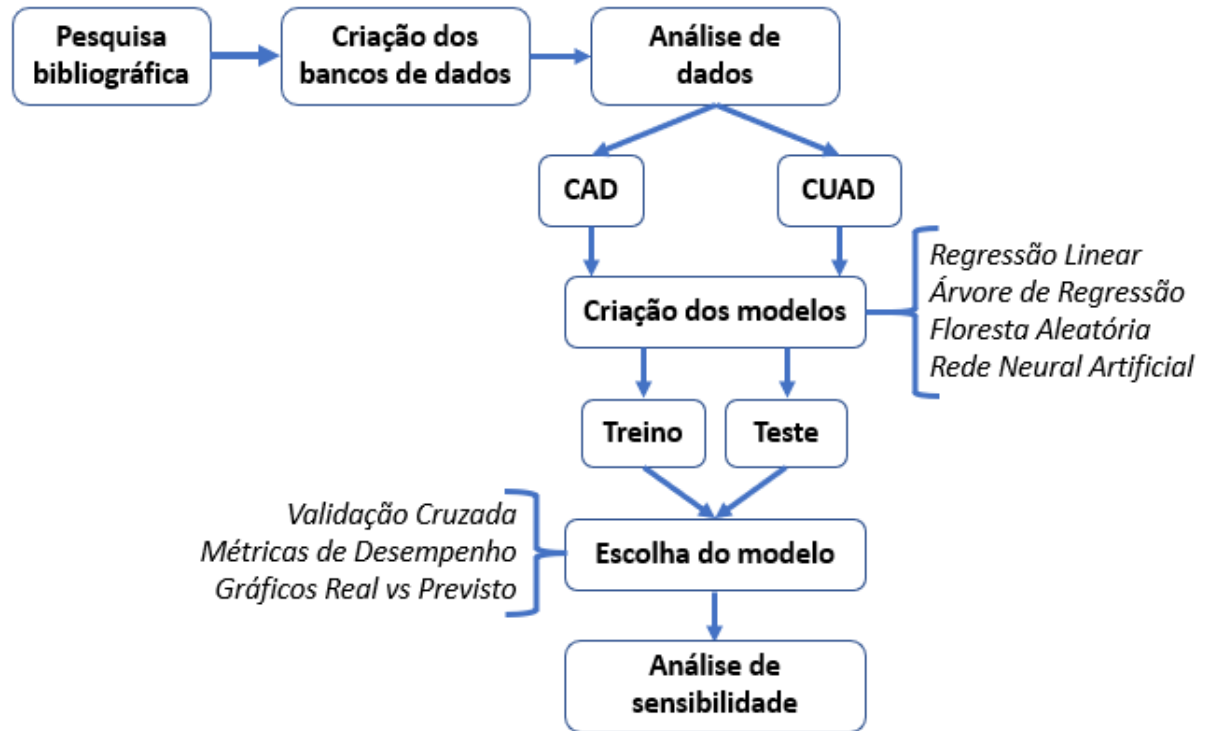


Fonte: Moretti (2010)

5 METODOLOGIA

O processo metodológico se encontra representado na Figura 22.

Figura 22 – Representação da Metodologia Aplicada neste trabalho



Fonte: Autora (2022)

5.1 Atualização da base de dados

A coleta de dados se deu por meio de pesquisa bibliográfica de estudos já realizados em peças de concretos de alto desempenho (CAD) e de ultra alto desempenho (CUAD), sendo feita uma análise inicial para seleção dos dados relevantes para a pesquisa em periódicos nacionais e internacionais. A maior dificuldade encontrada no processo de montagem dos bancos de dados é a falta dos dados necessários, grande parte dos estudos trazem apenas informações sobre as quantidades de material utilizados nas misturas e a resistência obtida. Sendo assim, dados considerados importantes como abatimento de cone (*slump*) de CAD, temperatura de cura térmica em CUAD e características dos materiais (dimensão, forma e composição química) não foram consideradas neste estudo.

A organização dos bancos de dados foi feita com o auxílio de ferramentas de planilhas eletrônicas como *Google Sheets* e *Microsoft Excel*, onde foram organizadas duas

bases de dados, sendo uma para cada tipo de concreto estudado (CAD e CUAD). Estes bancos de dados foram utilizados no desenvolvimento da ferramenta de dosagem para treinamento, validação e testes a serem realizados para análise da eficiência do método. Além disso, ficará disponibilizado em plataformas públicas, o que constitui em si uma contribuição para futuras pesquisas que investiguem esses materiais.

Os dados obtidos são de estudiosos internacionais, sendo que a maioria dos dados vem de pesquisadores da China e Canadá. Com isso temos tipos diversos de materiais já que alguns materiais têm características diferentes de acordo com o local, como por exemplo, os agregados. Na Figura 23 temos um gráfico que mostra de onde vieram os dados que compõem as duas bases de dados que foi desenvolvido com o auxílio do *Power BI*.

Figura 23 – Mapa da origem dos dados utilizados nos bancos de dados



Fonte: Autora (2022)

5.1.1 Base de dados de concreto de alto desempenho

A coleta de instâncias para a base de dados de CAD se deu por meio de pesquisa bibliográfica que trazem estudos feitos em peças de CAD. Encontrou-se uma base de dados criada por Yeh (1998) reunindo dados de vários estudos e que já foi utilizada várias vezes pelo autor e outros estudiosos, considerando esta uma base de dados consolidada que haveria necessidade de atualização. Sendo assim, foram acrescentadas instâncias de outros artigos encontrados. Os artigos utilizados como referência são apresentados na Tabela 7.

Tabela 7 – Resumo de referências que compõem a base de dados de CAD

Ref	Número de instâncias	Autor
1	12	(CHINDAPRASIRT <i>et al.</i> , 2007)
2	68	(LI; GONG, 2022)
3	16	(SOBOLEV, 2004)
4	4	(SOSA <i>et al.</i> , 2022)
5	5	(YEH, 2009)
6	103	(YEH, 2007)
7	1030	(YEH, 1998)
	1238	

Fonte: Autora (2022)

Nesta base de dados construída para o presente trabalho, tem-se as principais informações sobre as dosagens investigadas, sendo elas informações sobre os materiais utilizados e suas quantidades, além de valores de resistência à compressão. A Tabela 8 apresenta as informações encontradas na base de dados e suas unidades de medida.

Tabela 8 – Informações incluídas na base de dados de CAD e suas unidades de medida

Informação	Unidade de medida
Consumo de Cimento	kg/m ³
Consumo de Escória	kg/m ³
Consumo de Cinza volante	kg/m ³
Consumo de Silica ativa	kg/m ³
Consumo de Água	kg/m ³
Consumo de Superplastificante	kg/m ³
Consumo de Agregado graúdo	kg/m ³
Consumo de Agregado miúdo	kg/m ³
Consumo de Fibra	kg/m ³
Idade	dias
Resistência à compressão	MPa

Fonte: Autora (2022)

Na pesquisa por instâncias para a base dados, é comum a dificuldade de encontrar informações detalhadas sobre as características dos materiais utilizados. Em sua maioria foi utilizado cimento Portland comum e uma cura normal. Em relação ao superplastificante, foram utilizadas marcas variadas com diferentes formulações, podendo-se afirmar apenas que a maioria é de redutores de água de segunda geração. Os autores Li e Gong (2022) e Chindaprasirt *et al.* (2007) trazem mais informações quanto aos materiais utilizados e estes são apresentados na Tabela 9.

Tabela 9 – Informações sobre os materiais utilizados nas pesquisas de CAD

(CHINDAPRASIRT <i>et al.</i> , 2007)	
Cimento	ASTM Classe I
Cinza Volante	ASTM Classe F
Agregado	ASTM C33
Superplastificante	ASTM Tipo F
(LI; GONG, 2022)	
Cimento	Cimento de silicato comum
Cinza Volante	Classe I
Silica Fume	Composição: 92% de SiO ₂
Agregado graúdo	Faixa granulométrica: 4,75 - 19,5 mm
Agregado Miúdo	Areia natural de rio (Módulo de finura: 2,8)
Superplastificante	Redutor de água HJXS-A com polifosfato
Fibra	Material: Polipropileno

Fonte: Autora (2022)

5.1.2 Base de dados de concreto de ultra alto desempenho

Para a base de dados de CUAD foi utilizado o mesmo método de busca por instâncias em artigos publicados com estudos feitos em peças de concreto. Na Tabela 10, temos as referências utilizadas para a construção dessa base de dados:

Tabela 10 – Resumo de referências que compõem a base de dados de CUAD

Ref	Número de instâncias	Autor
1	110	(ABUODEH; ABDALLA; HAWILEH, 2020)
2	12	(HASSANI; KHALIL; DANHA, 2014)
3	72	(AYIRA, 2013)
4	1	(LU; SHEN; ALI; POON, 2022)
5	800	(MARANI; JAMALI; NEHDI, 2020)
6	20	(PREM; BHARATKUMAR; MURTHY, 2015)
7	8	(ZHENG <i>et al.</i> , 2022)
	1023	

Fonte: Autora (2022)

Nesta base de dados, tem-se informações adicionais que não temos na base de dados de CAD, isto devido às diferentes adições utilizadas e métodos de cura. Na Tabela 11, podem-se ver as informações apresentadas na base de dados de CUAD.

Tabela 11 – Informações incluídas na base de dados de CUAD e suas unidades de medida

Informação	Unidade de medida
Consumo de Cimento	kg/m ³
Consumo de Escória	kg/m ³
Consumo de Sílica ativa	kg/m ³
Consumo de Pó de calcário	kg/m ³
Consumo de Pó de quartzo	kg/m ³
Consumo de Cinza volante	kg/m ³
Consumo de Nano sílica	kg/m ³
Consumo de Água	kg/m ³
Consumo de Agregado Miúdo	kg/m ³
Consumo de Agregado graúdo	kg/m ³
Consumo de Fibra	kg/m ³
Consumo de Superplastificante	kg/m ³
Idade	dias
Resistência à compressão	MPa

Fonte: Autora (2022)

Alguns dos estudos feitos em CUAD trazem detalhes sobre os materiais utilizados. A Tabela 12 traz um resumo destes materiais e suas características. Porém, não são todos os artigos que trazem estas informações, de forma que não foi possível utilizar diretamente dados que tratam das características dos materiais na ferramenta de previsão.

Tabela 12 – Informações sobre os materiais utilizados nas pesquisas de CUAD

(ZHENG et al., 2022)	
Cimento	Cimento Portland P II 52,5
Superplastificante	Superplastificante de ácido de policarboxílico com 40% de sólidos
Agregado Miúdo	Areia de rio com tamanho em torno de 1,25mm e densidade aparente de 2650 kg/m ³
(PREM; BHARATKUMAR; MURTHY, 2015)	
Cimento	Cimento Portland normal
Sílica Fumê	ASTM C1240 (ASTM, 2014)
Superplastificante	Superplastificante poliacrílico
Fibras	Feitas de metal
(AYIRA, 2013)	
Cimento	Cimento Portland I
Sílica Fumê	ASTM C1240 – 97b
Superplastificante	Sika Viscocrete 2044
Fibras	Feitas de metal
(HASSANI; KHALIL; DANHA, 2014)	
Cimento	Cimento Portland V
Agregado Miúdo	Grãos com no máximo 600 µm
Sílica Fumê	ASTM C1240
Superplastificante	Polímero de naftaleno formaldeído sulfonato e Polímero de éter policarboxilato
Fibras	Feitas de metal
(LU; SHEN; ALI; POON, 2022)	
Cimento	Cimento Portland CEM I 52,5
Superplastificante	Polímero de éter policarboxilato
Fibras	Feitas de metal

Fonte: Autora (2022)

5.2 Análise preliminar dos dados

Na primeira parte deste trabalho, foi uma análise exploratória para entender os dados e seus comportamentos, visualizando correlações e dimensões além das relações entre as variáveis, principalmente com relação à resistência à compressão. Essa análise inclui tratamento de dados, análise dos principais dados estatísticos, visualização da distribuição dos dados com histogramas, estudos de correlação com mapa de calor (*heatmap*) e gráficos de dispersão (*pairplots e scatterplot*) para uma melhor análise do comportamento dos dados.

Essa análise foi feita primeiramente nas bases de dados mescladas para a verificação do comportamento e decisão quanto ao tratamento final para modelagem ou com ambos os concretos (CAD e CUAD) analisados concomitantemente ou em ferramentas separadas. Posteriormente, foi feita uma separação nas bases de dados para comparação, verificação e modelagem.

5.3 Desenvolvimento da ferramenta

No processo de criação da ferramenta as variáveis de entrada foram escolhidas entre os materiais utilizados e suas características. Estes dados foram divididos aleatoriamente em dois conjuntos sendo 75% deles dados de treino que são utilizados no treinamento dos modelos e 25% de dados de teste que são utilizados na avaliação do desempenho preditivo de cada modelo. Foram utilizados vários modelos de *machine learning*, sendo eles Regressão Linear (*linear regression*), Árvore de Regressão (*regression tree*), Floresta Aleatória (*random forest*) e Redes Neurais Artificiais (*artificial neural network*) que foram utilizados na previsão da resistência à compressão. Todos os modelos foram criados no ambiente do *Google Colab* e programados em linguagem *Python* utilizando as funções da biblioteca *scikit-learn*.

O processo de criação dos modelos envolve a definição dos hiperparâmetros que são as principais configurações e propriedades dos modelos. A otimização destes hiperparâmetros é importante para buscar uma combinação de parâmetros que melhorem o desempenho do modelo em suas predições. O método de otimização de hiperparâmetros utilizado foi o algoritmo *GridSearchCV* da biblioteca *Scikit-learn*, onde o algoritmo busca a melhor combinação de parâmetros utilizando o método de validação cruzada *K-Fold* com divisão em 10 subgrupos. Na Tabela 13 temos a seleção de hiperparâmetros após otimização para cada um dos modelos utilizados para cada tipo de concreto. Além disso o modelo de RNA desenvolvido para CUAD foi otimizado manualmente com um loop de teste para diferentes quantidades de neurônios o que melhorou a sua performance final.

Tabela 13 – Hiperparâmetros utilizados em cada modelo de previsão

CAD			CUAD		
Modelo	Hiperparâmetros	Valores	Modelo	Hiperparâmetros	Valores
Regressão linear	todos	padrão	Regressão linear	todos	padrão
Árvore de regressão	profundidade máxima	10	Árvore de regressão	profundidade máxima	5
	amostra mínima para divisão	100		amostra mínima para divisão	150
Floresta aleatória	profundidade máxima	100	Floresta aleatória	profundidade máxima	25
	número de árvores	250		número de árvores	250
Rede neural artificial	função de ativação	<i>relu</i>	Rede neural artificial	função de ativação	<i>relu</i>
	número de camadas	1		número de camadas	1
	número de neurônios	64		número de neurônios	500
	número máximo de interações	5000		número máximo de interações	5000

Fonte: Autora (2022)

5.4 Análise dos modelos

A validação foi feita com o método *K-Fold* com 10 subgrupos utilizando validação cruzada por meio da função ‘*cross_validate*’ disponibilizado pela biblioteca *scikit-learn*. Este método dividiu a base de dados em 10 subgrupos. Dentro de cada subgrupo uma parte dos dados é utilizada em teste enquanto os outros vão treinar a ferramenta e isso se repete até completar 10 interações, sendo que há variação de quais dados são usados em treino e teste. O método de validação cruzada diminui a aleatoriedade e variabilidade nos resultados da predição já que as métricas são calculadas para cada um dos 10 subgrupos e as métricas finais são definidas pela média das métricas calculadas.

Tendo os modelos treinados e testados podemos fazer uma análise da capacidade preditiva de cada modelo utilizando as métricas de avaliação que vão comparar os valores previstos com os valores reais e calcular o erro. As métricas utilizadas para avaliação dos modelos foram o erro quadrático médio ou *mean squared error* (MSE), erro absoluto médio ou *mean absolute error* (MAE) e o coeficiente de determinação (R^2), onde os dois primeiros calculam valores de erro então quanto menor seus valores, melhor o modelo e o último traz o ajuste do modelo aos valores reais, então quanto maior este coeficiente (no intervalo de 0 a 1) melhor o ajuste do modelo aos dados.

5.4.1 Análise de sensibilidade

Escolhido o melhor modelo, este foi estudado com análises de sensibilidade e dependência de variáveis, onde os parâmetros com maior correlação e influência foram variados com o intuito de estudar a variação da resistência à compressão em função de cada um desses parâmetros de entrada e como eles se influenciam entre si.

Para a análise de sensibilidade, faz-se necessário a definição de um traço padrão que será modificado e variado para encontrarmos padrões de comportamento dos concretos estudados. O traço de referência utilizado considerou valores médios encontrados nas bases de dados para cada tipo de material que se encontra na Tabela 14.

Tabela 14 – Traços de referência de CAD e CUAD usados nas análises de sensibilidade

CAD		CUAD	
Material	Quantidade (kg/m³)	Material	Quantidade (kg/m³)
Cimento	600,00	Cimento	800,00
Escória	69,00	Sílica Ativa	250,00
Cinza volante	62,00	Água	180,00
Água	200,00	Agregado miúdo	1.000,00
Superplastificante	6,00	Fibra	50,00
Agregado graúdo	900,00	Superplastificante	30,00
Agregado miúdo	750,00	Resistência à compressão	134,20 MPa
Resistência à compressão	87,24 MPa		

Fonte: Autora (2022)

5.4.2 Análise paramétrica

Para as variações realizadas no traço padrão definido, também foi necessária uma análise paramétrica a fim de se manter sempre o volume constante ao modificar os valores de massa de um dado constituinte. Sendo assim, ao adicionar uma quantidade de um material os outros devem ser retirados respeitando alguma regra de proporcionamento de maneira que o volume continue o mesmo, senão se incluirá material onde possivelmente não há espaço para tal. Então, caso seja acrescentada uma quantidade de massa de cimento para manter as mesmas proporções as massas dos outros materiais devem ser diminuídas.

Para as quantidades de material definidos, tem-se que os seus volumes representados na Equação 5 onde V_m é o volume do material, m é a massa em kg/m^3 e ρ_m é a massa específica do material.

$$V_m = \frac{m}{\rho_m} \quad (\text{Equação 5})$$

Analisando a variação de massa de cimento, por exemplo, ao acrescentar uma massa m em kg haverá a necessidade de diminuir as quantidades dos outros materiais para termos o mesmo volume e respeitarmos o traço especificado. Assim determina-se primeiramente quanto de volume está sendo acrescentado com a massa m utilizando a Equação 5 já apresentada e este será o volume (V_m) a ser retirado dos outros materiais. Sabendo que o traço é dado em função do consumo de cimento os volumes de cada material são calculados como na Equação 6 onde C é o consumo de cimento em kg/m^3 , V_c , V_{am} , V_{ag} e V_a são os volumes de cimento, agregado miúdo, agregado graúdo e água respectivamente e ρ_c , ρ_{am} , ρ_{ag} e ρ_a são as massas específicas do cimento, agregado miúdo, agregado graúdo e água respectivamente.

$$\left\{ \begin{array}{l} V_c = \frac{1}{\rho_c} C \\ V_{am} = \frac{a}{\rho_{am}} C \\ V_{ag} = \frac{b}{\rho_{ag}} C \\ V_a = \frac{a/c}{\rho_a} C \end{array} \right. \quad (\text{Equação 6})$$

Quando aumentamos a quantidade de um material e retiramos dos outros mantendo a proporção, o material que está sendo aumentado não participa do rateio. Um exemplo é quando queremos adicionar uma massa m de cimento, sendo assim temos que retirar agregados miúdo e graúdo e água como na Equação 7.

$$\left\{ \begin{array}{l} V_a' = \left(\frac{a/c}{a/c+a+b} \right) Vm \\ V_{am}' = \left(\frac{am}{a/c+a+b} \right) Vm \\ V_{ag}' = \left(\frac{b}{a/c+a+b} \right) Vm \end{array} \right. \quad (\text{Equação 7})$$

Onde V_a' , V_{am}' e V_{ag}' são os volumes a serem retirados de cada material sendo a e b os coeficientes de agregado miúdo e graúdo no traço respectivamente segundo a representação na Figura 2. Com os volumes e massas específicas usamos a Equação 5 para encontrar a massa a ser retirada.

Outra situação é quando queremos substituir cimento por adições, neste caso o processo de balanceamento é o mesmo, porém consideramos a massa de cimento e adição como uma só. Existe também a possibilidade de fixar a quantidade de um material e variar a quantidade de outro, por exemplo caso mantenhemos fixa a quantidade de cimento e variamos a quantidade de agregado miúdo (V_{am}) nenhum destes dois materiais participam do rateio de volume sobrando apenas agregado graúdo (ag) e água (a) que tem seus volumes de rateio demonstrados na Equação 8 onde V_a' é o volume a ser retirado de água e V_{ag}' é o volume a ser retirado de agregado graúdo.

$$\left\{ \begin{array}{l} V_a' = \left(\frac{a/c}{a/c+b} \right) V_{am} \\ V_{ag}' = \left(\frac{b}{a/c+b} \right) V_{am} \end{array} \right. \quad (\text{Equação 8})$$

As massas específicas utilizadas foram retiradas da literatura e padronizadas para efeito de simplificação. A Tabela 15 traz os valores utilizados para cada material analisado.

Tabela 15 – Massas específicas utilizadas no estudo paramétrico

Material	Massa específica (kg/dm³)
Cimento	3,10
Água	1,00
Agregado graúdo	2,70
Agregado miúdo	2,60
Sílica Ativa	2,18
Nanossílica	1,08

Fonte: Autora (2022)

6 RESULTADOS

6.1 Análise preliminar com as bases de dados mescladas

6.1.1 Tratamento dos dados

Por mais que o referencial teórico aponte para a análise separadamente de CAD e CUAD os dois bancos de dados foram mesclados para análise conjunta a fim de constatar as diferenças expostas na literatura e analisar com os dados quais as principais diferenças.

Com as bases de dados mescladas ficamos com uma base de dados única com 2245 instâncias em 14 colunas, as variáveis utilizadas na análise são apresentadas na Tabela 16.

Tabela 16 - Variáveis utilizadas no processo de previsão

Variáveis	Mín	Max	Média
Cimento (kg/m ³)	102,00	1.600,00	507,11
Escória (kg/m ³)	0,00	375,00	47,20
Sílica Fumê (kg/m ³)	0,00	605,00	70,69
Pó de calcário (kg/m ³)	0,00	486,20	10,92
Pó de quartzo (kg/m ³)	0,00	397,00	15,59
Cinza Volante (kg/m ³)	0,00	377,00	46,86
Nanosílica (kg/m ³)	0,00	47,50	1,27
Água (kg/m ³)	90,00	334,50	184,39
Agregado Miúdo (kg/m ³)	0,00	1.898,00	866,61
Agregado Graúdo (kg/m ³)	0,00	1.195,00	594,21
Fibra (kg/m ³)	0,00	234,00	22,99
Superplastificante (kg/m ³)	0,00	104,50	16,98
Idade (dias)	1,00	365,00	39,29
Resistência à Compressão (MPa)	2,33	240,00	77,34

Fonte: Autora (2022)

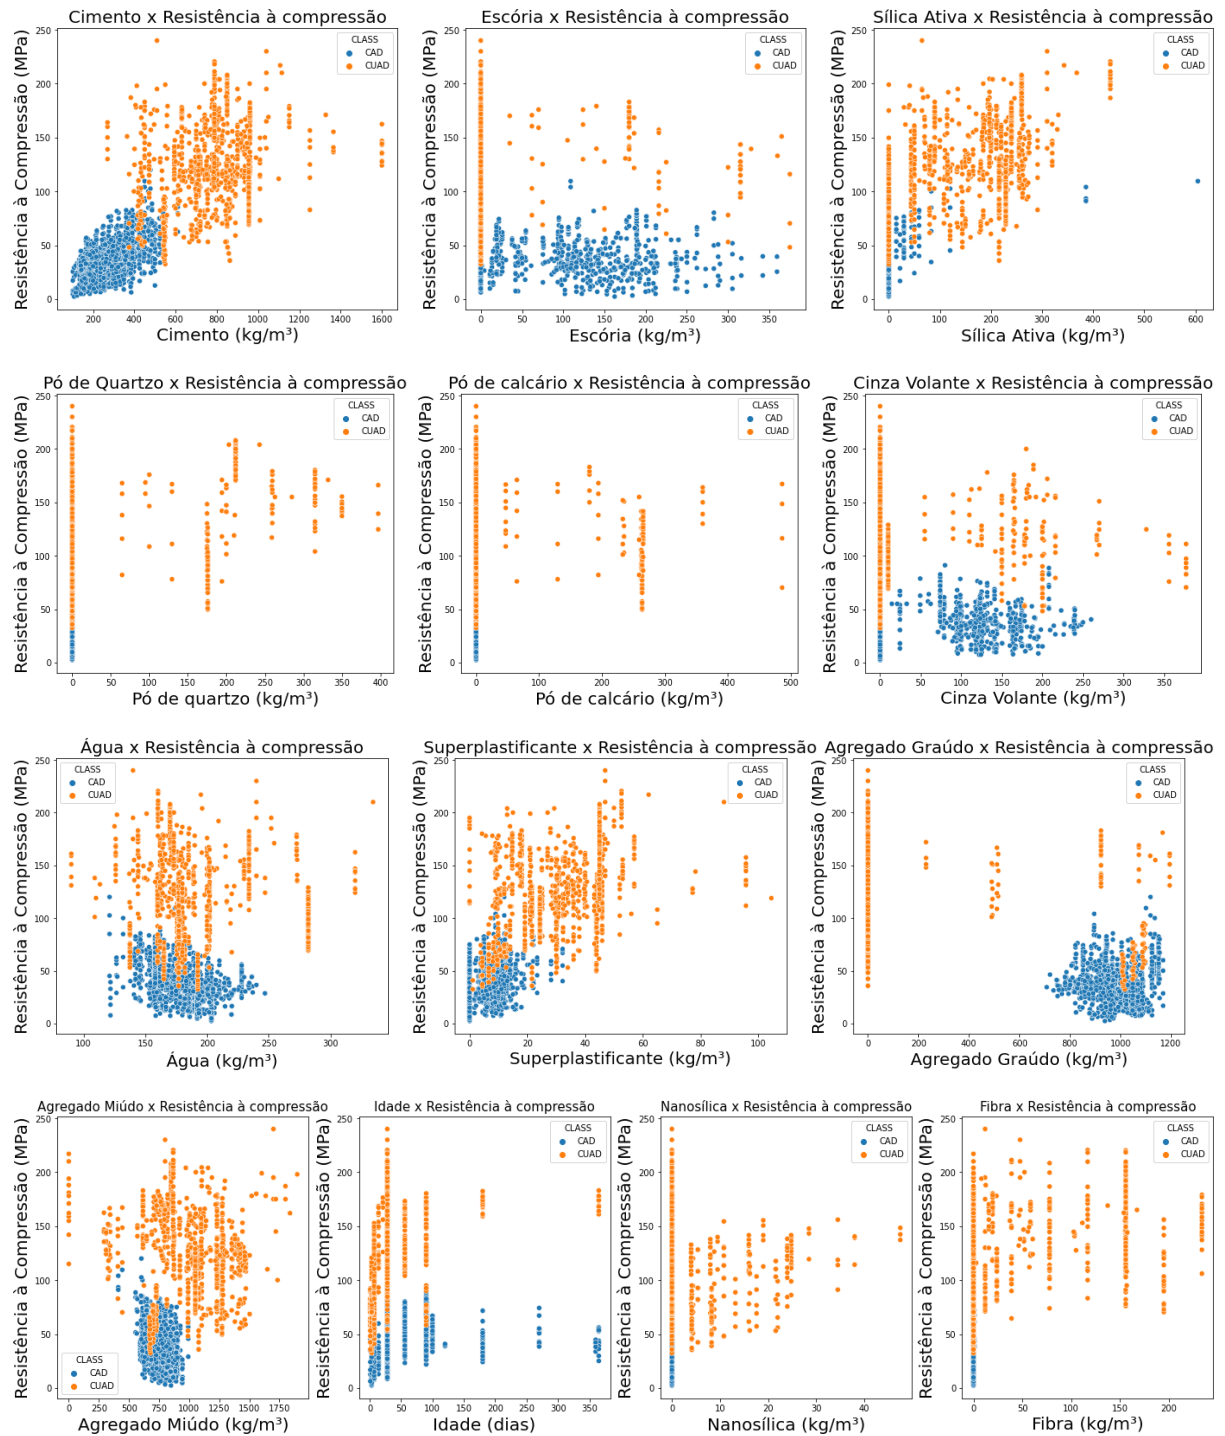
6.1.2 Análise preliminar dos dados

Para uma análise mais clara da diferença de comportamento entre as duas bases de dados, na Figura 24, apresentam-se gráficos *pairplot* com a correlação dos materiais e a resistência à compressão coloridos por tipo de concreto. Vê-se sistematicamente duas nuvens de comportamentos diferentes (em azul para CAD e em laranja para CUAD). Com a formação de nuvens de pontos bem distintas para cada tipo de concreto. Isso traz uma das principais diferenças entre CAD e CUAD que é a quantidade de materiais.

Além disso, eles não têm características tão similares quanto esperado ao iniciar pelas quantidades utilizadas de cada material e os tratamentos diferenciados de cura utilizados no

CUAD, como já comentado no referencial teórico (PREM; BHARATKUMAR; MURTHY, 2014).

Figura 24 – *Pairplot* de correlação entre os materiais e a resistência à compressão

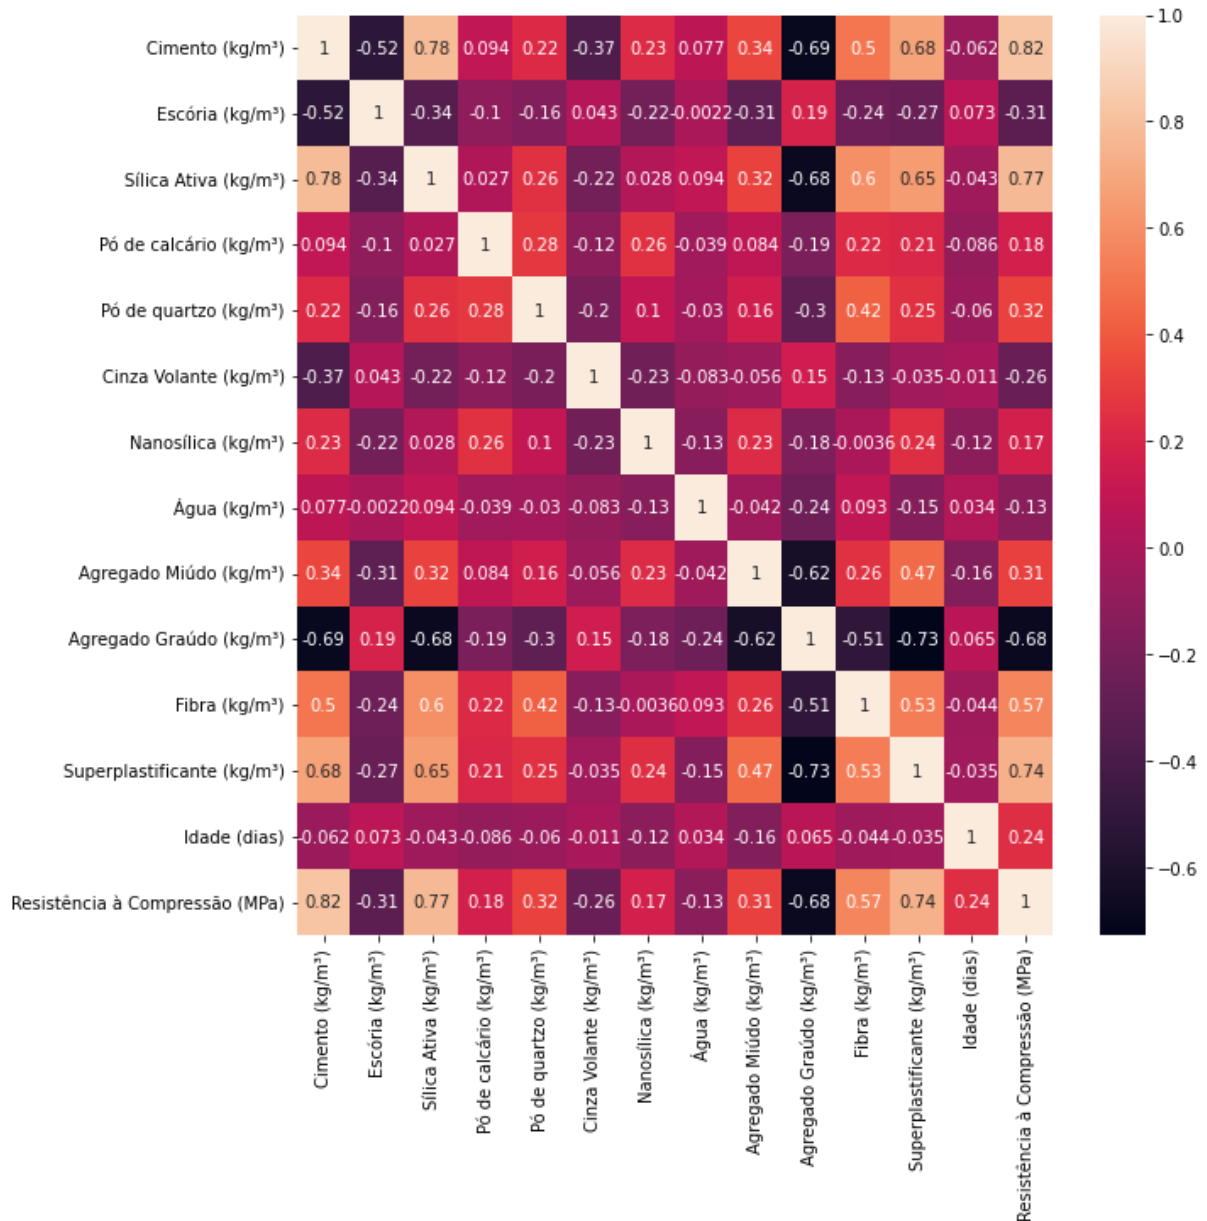


Fonte: Autora (2022)

Analisando as influências na resistência à compressão por meio de mapa de calor de correlação (Figura 25), é possível observar as maiores correlações positivas para os consumos

de cimento (0,82), sílica ativa (0,77) e superplastificante (0,74), comportamento que está de acordo com estudos apresentados na seção 4.4. Enquanto isso, as maiores correlações negativas foram observadas para os consumos de agregado graúdo (-0,68), escória (-0,31) e cinza volante (-0,26).

Figura 25 – Mapa de calor de correlação entre atributos com as bases de dados mescladas



Fonte: Autora (2022)

O mesmo mapa de calor foi obtido para as duas bases de dados de CAD (Figura 28) e de CUAD (Figura 38) separadamente e é observado que a correlação de agregado graúdo difere bastante com as bases de dados mescladas e separadas. Enquanto trabalhamos com as bases de

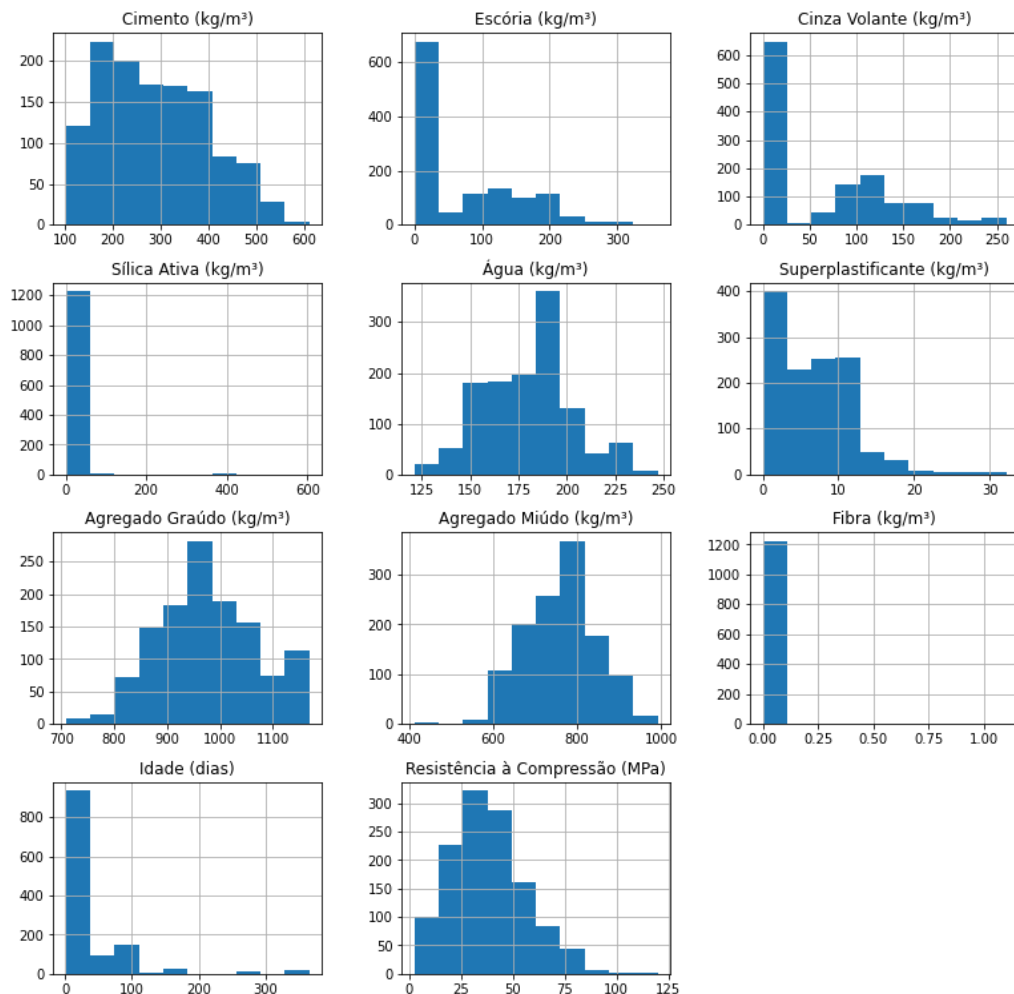
dados juntamente encontramos alta correlação negativa e com as bases de dados separadas nenhuma apresenta alta correlação entre agregado graúdo e resistência à compressão. Isso é um indício de que ao juntar as bases de dados alguns valores acabam sendo mascarados, de forma que, o agregado graúdo passa a ter uma alta correlação negativa. Tal ocorrência se deve ao fato de que o CUAD é desenvolvido para ter altos valores de resistência (maiores que os de CAD) e não utiliza agregado graúdo na sua mistura.

6.2 Análise da base de dados de concreto de alto desempenho

6.2.1 Visualização dos dados

A Figura 26 traz a distribuição das observações nas variáveis da base de dados de CAD. Onde podemos ver que grande parte dos dados não possuem adição de escória, cinza volante, sílica ativa e fibras então temos em sua maioria instâncias com valores zerados.

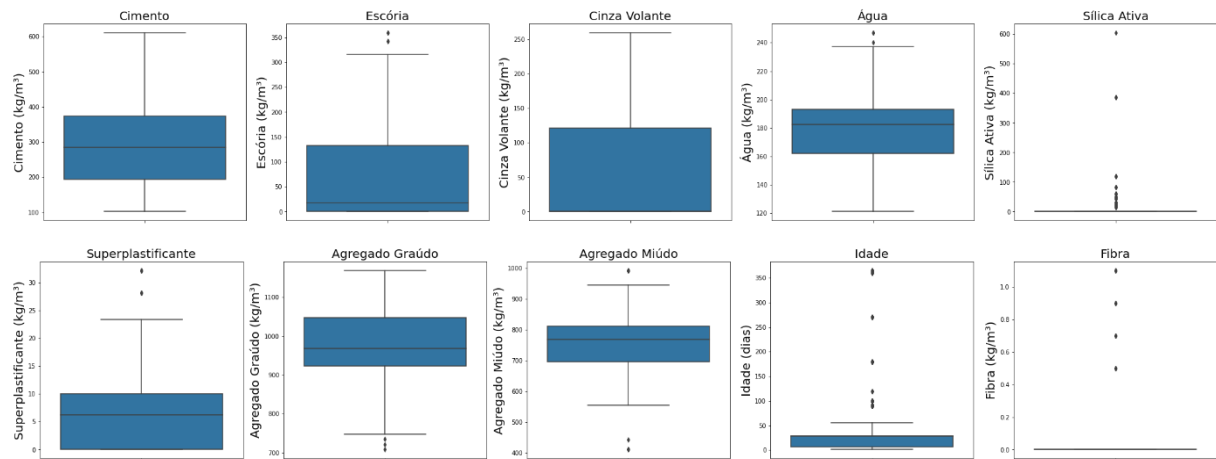
Figura 26 – Distribuição dos dados para a base de dados de CAD em histograma



Fonte: Autora (2022)

Além disso, vê-se na Figura 27 os gráficos *boxplot* de cada variável que foram utilizados para observação e tratamento de *outliers*. Eles também auxiliaram na criação de intervalos para análises de sensibilidade onde alguns materiais foram variados nestes intervalos definidos de acordo com a base de dados estudada e a literatura.


Figura 27 – *Boxplots* e identificação de *outliers* nas variáveis na base de dados de CAD



Fonte: Autora (2022)

6.2.2 Análise preliminar dos dados

Figura 28 – Mapa de calor de correlação entre atributos da base de dados de CAD



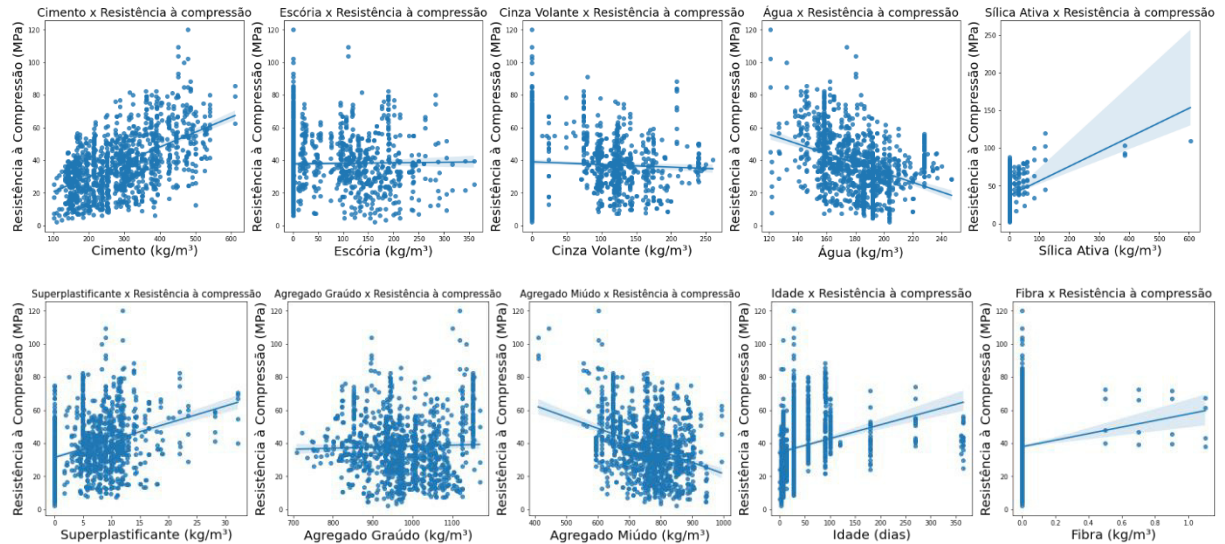
Fonte: Autora (2022)

Na Figura 28, que traz o *heatmap* de correlação dos dados da base de dados de CAD, vê-se que as principais influências positivas na resistência à compressão vêm do consumo de cimento (0,53), da idade (0,5) e do superplastificante (0,31), enquanto as principais influências negativas são do consumo de água (-0,39) e de agregado miúdo (-0,29).

Esses comportamentos são confirmados nos gráficos *pairplot* de cada variável apresentados na Figura 29. Nela vemos que o cimento, a idade e o superplastificante têm uma

influência positiva na resistência à compressão, enquanto que os consumos de água e de agregado miúdo têm o efeito contrário.

Figura 29 – Gráficos *pairplot* da influência das variáveis na resistência à compressão de CAD



Fonte: Autora (2022)

6.2.3 Modelos de previsão

Após testes com os modelos tratados neste trabalho (regressão linear, árvore de regressão, floresta aleatória e redes neurais artificiais), e com a busca dos melhores hiperparâmetros para cada um deles, os resultados obtidos foram conforme apresentado na Tabela 17. Os melhores resultados foram obtidos com os modelos de floresta aleatória (*Random Forest*) e redes neurais, conforme valores de MSE, MAE e R^2 . Em trabalhos apresentados vemos métricas próximas como o modelo de Floresta aleatória de Li e Song (2022) que utilizam uma estrutura diferente e conseguem um valor de R^2 de teste igual a 0,893.

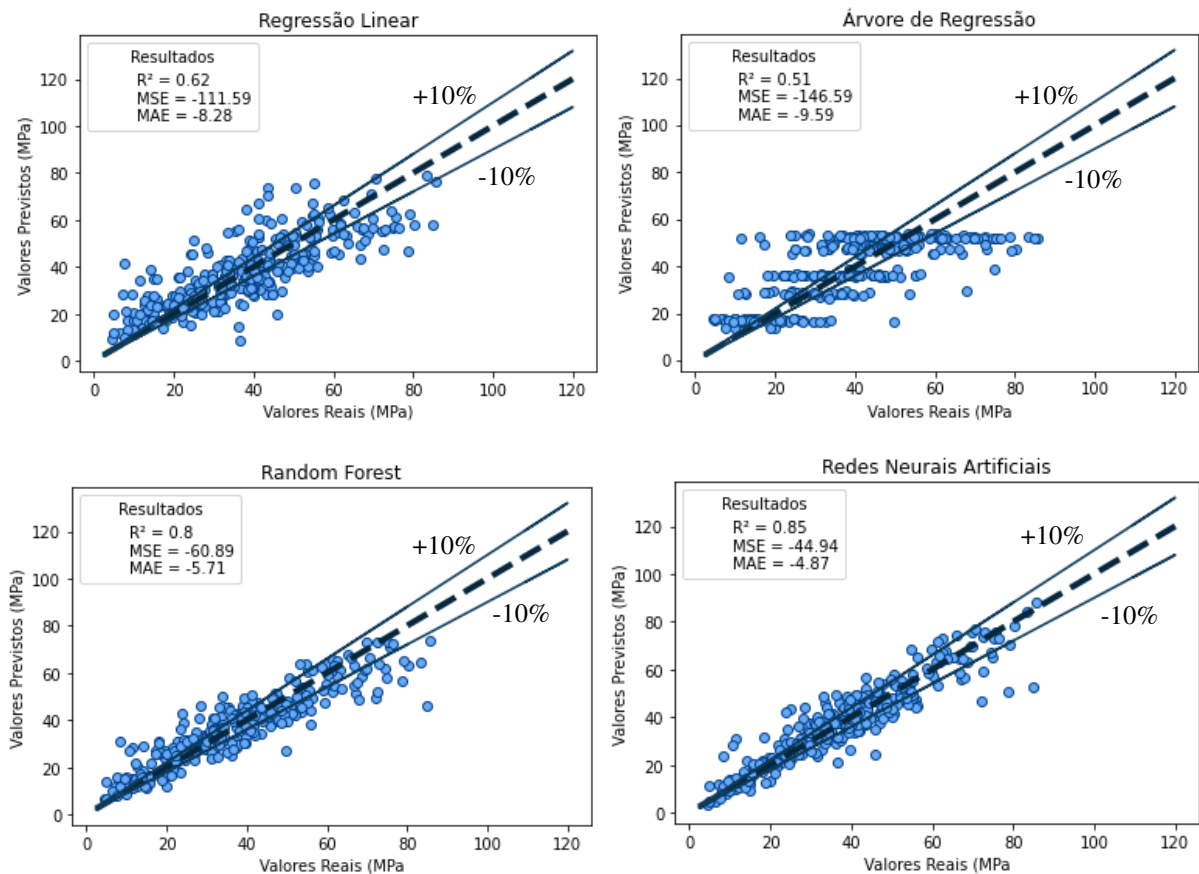
Tabela 17 – Métricas de desempenho de cada modelo utilizado na previsão da resistência à compressão de CAD

Modelo	MSE	MAE	R^2
Regressão Linear	111,59	8,28	0,62
Árvore de Regressão	146,59	9,59	0,51
Floresta Aleatória	60,89	5,71	0,80
Redes Neurais Artificiais	44,94	4,87	0,85

Fonte: Autora (2022)

Além disso, para melhor visualização, apresentam-se na Figura 30 os gráficos que comparam os valores reais e os valores previstos para cada um dos modelos e suas respectivas métricas. A partir desses dados, pode-se concluir que o modelo de redes neurais tem uma performance melhor se comparado aos outros. No gráfico de ajuste da RNA a maioria dos dados se encontra dentro dos limites de 10% diferentemente dos outros modelos. Além disso, considerando que ao utilizar o método *K-Fold* estamos trazendo médias das métricas faz-se importante evidenciar que o modelo de RNA escolhido apresenta desvio padrão igual a 0,09.

Figura 30 – Comparação valores reais e valores previstos de resistência à compressão de CAD para os modelos de previsão testados



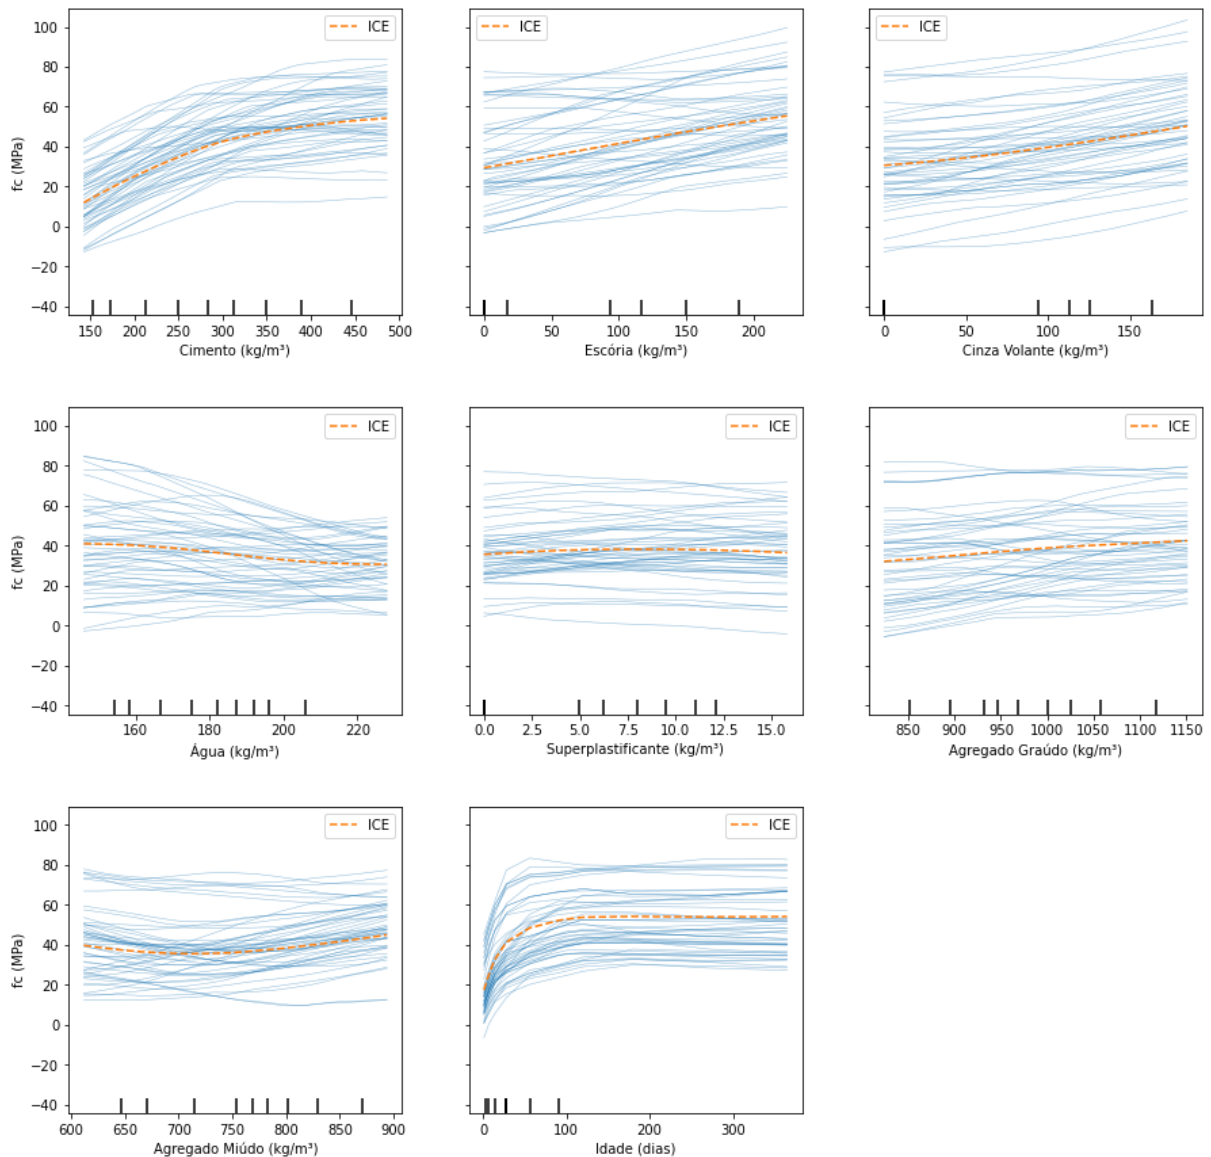
Fonte: Autora (2022)

6.2.4 Análise de sensibilidade

Com o modelo de RNA ajustado, considerado o melhor entre as opções, várias análises foram feitas a fim de se avaliar se os comportamentos interpretados pelo modelo estão de acordo com o esperado conforme estudos já realizados em CAD. Uma das análises feitas foi por meio dos gráficos de dependência parcial (Figura 31), que trazem a influência que cada variável tem

na resistência à compressão. Este gráfico traz um comportamento geral de cada variável que confirma os comportamentos encontrados na análise preliminar, entre eles influências positivas de materiais como cimento e adições e influência negativa ou neutra em materiais como água e agregado miúdo. Sublinha-se que essa técnica não considera a possível interdependência entre os consumos de materiais, algo tratado mais à frente das análises paramétricas.

Figura 31 – Gráficos de dependência parcial entre as variáveis da base de dados de CAD e a resistência à compressão

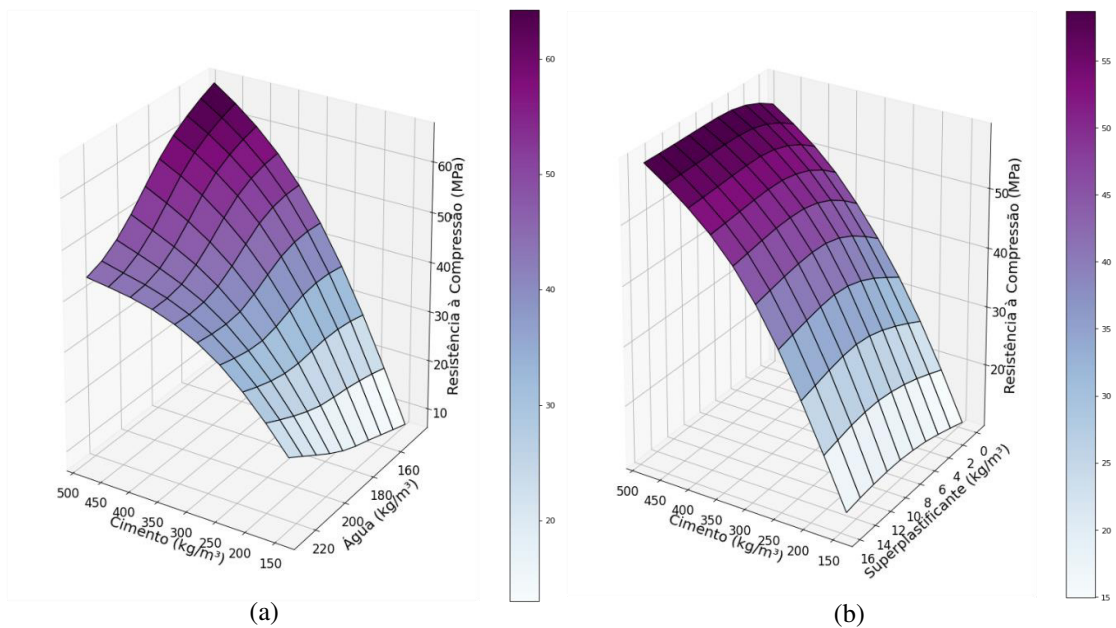


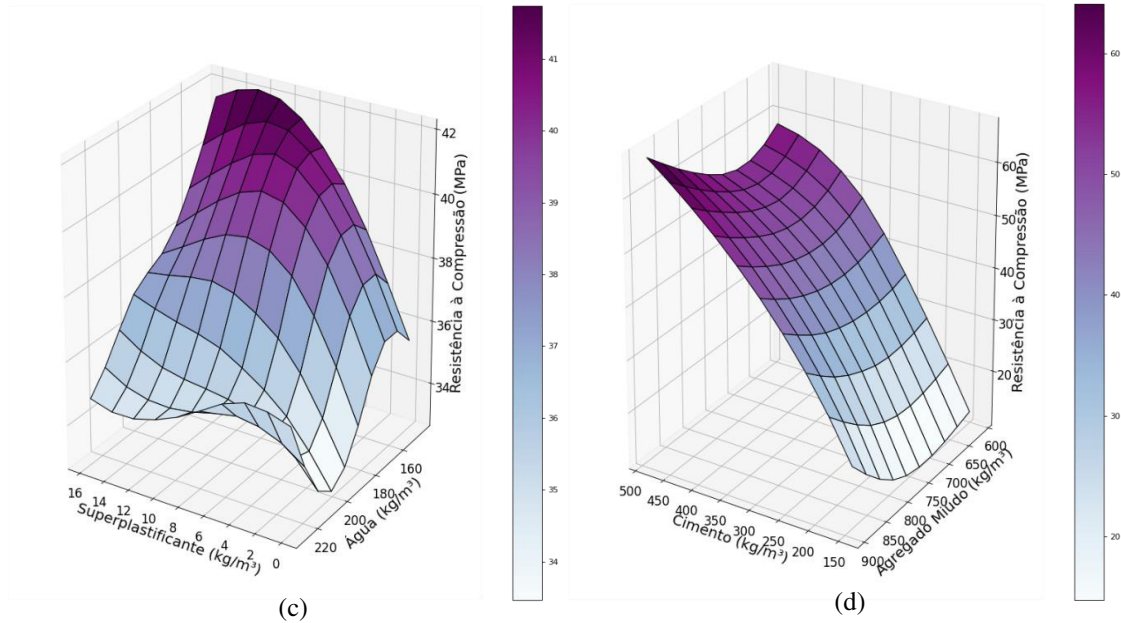
Fonte: Autora (2022)

O efeito dos consumos de materiais que apresentaram maior influência separadamente ou em conjunto é apresentado na Figura 32. Na Figura 32(a), avalia-se a influência de cimento e água conjuntamente, chegando a conclusão que quanto mais cimento e menos água maior será

a resistência do concreto. Na Figura 32(b), tem-se o comportamento do cimento e do superplastificante juntos e se vê que, para todos os valores de superplastificante, a resistência aumenta quando aumentamos a quantidade de cimento. Na Figura 32(c), tem-se as influências de água e superplastificante, novamente ilustrando a influência negativa da água no valor da resistência. Porém, para o superplastificante as maiores resistências são encontradas em um valor médio, que pode ter relação com o ponto de saturação dos aditivos comentado na seção 4.1.4. Na Figura 32(d), segue o comportamento usual de aumento na resistência com o aumento da quantidade de cimento. Porém, quando se observa o efeito do agregado miúdo, tem-se uma variação na curva. Mesmo que os maiores valores de resistência sejam observados para as maiores quantidades de agregado miúdo, vê-se que para certas quantidades de cimento têm-se resistências maiores para quantidades menores de agregado miúdo.

Figura 32 – Influência de diferentes materiais na resistência à compressão do CAD






Fonte: Autora (2022)

Por último, foram gerados gráficos 2D dos materiais com maiores influências na resistência à compressão do CAD. Desta vez, isso foi feito variando alguns valores de cada material e obedecendo a análise paramétrica apresentada na seção 5.4.2 a fim de se manter sempre o volume constante do concreto ao variar as massas dos materiais.

A Figura 33 traz a influência da água para diferentes quantidades de cimento e superplastificante. A tendência que encontramos é que quanto menor a quantidade de água maior a resistência à compressão e isso se segue para todas as quantidades de cimento na Figura 33(a) e grande parte dos valores de superplastificantes na Figura 33(b). Evidenciam-se ainda mais os comportamentos encontrados desde a análise exploratória, onde a água tem uma influência negativa considerável na resistência à compressão, fato que já foi confirmado por vários estudiosos para todos os tipos de concreto com exceção dos concretos secos.

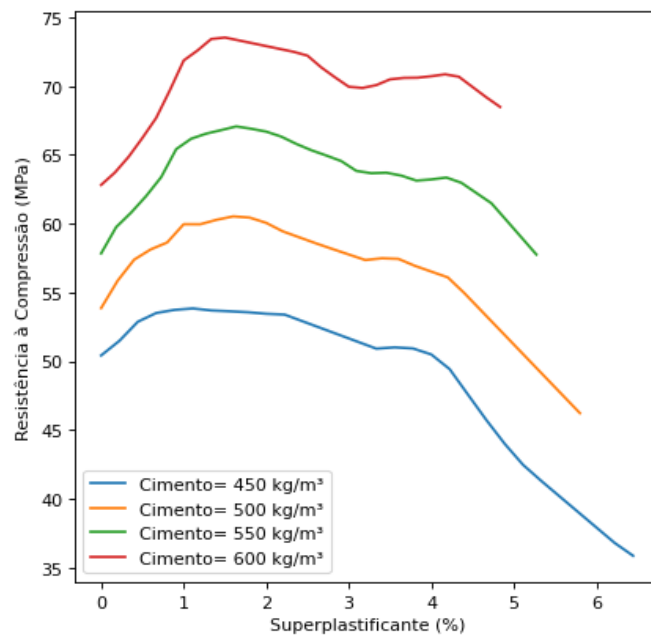
Figura 33 – Influência do consumo de água para diferentes quantidades de cimento e superplastificante na resistência de CAD



Fonte: Autora (2022)

Na Figura 33(b), a curva que representa ausência de superplastificante obteve os menores valores de resistência, as maiores resistência foram observadas para a maior quantidade de aditivo e menores de água, porém a curva de consumo médio (10kg/m³) traz um comportamento diferente, trazendo um pico na resistência para valores médios de água. Este pico pôde ser observado também na Figura 34, onde se vê a influência do superplastificante na resistência à compressão para diferentes quantidades de cimento. O mesmo comportamento se repete para todas as quantidades de cimento analisadas (entre 450 e 600 kg/m³) onde há um pico na resistência e depois ela decai. Isso pode se dever ao efeito do ponto de saturação do superplastificante que é o ponto de ao aumentar o teor do aditivo seus efeitos são neutros ou negativos implicando na perda de resistência (AITCIN, 1998).

Figura 34 – Influência do consumo de superplastificante para diferentes quantidades de cimento na resistência à compressão de CAD




Fonte: Autora (2022)

Na Figura 35, estuda-se a influência do agregado miúdo na resistência à compressão para diversas quantidades de cimento e água. A Figura 35(a) mostra que ao aumentar a quantidade de agregado miúdo a resistência diminui até ficar quase constante. Já Figura 35(b) para os valores pré-estabelecidos de água ao aumentarmos a quantidade de agregado miúdo temos em um primeiro momento um decréscimo na resistência e logo depois um acréscimo significativo.

As conclusões gerais são que para maiores quantidades de cimento e menores quantidades de água, maiores as resistências. Mas como se sabe quanto menor a dimensão do grão maior a sua superfície específica. Devido à superfície específica elevada do agregado miúdo, este precisa de uma quantidade maior de água para lubrificação, de maneira que é de se esperar que quando se adiciona agregado miúdo também se tenha que adicionar água, e isso implica em uma queda na resistência à compressão caso o consumo de cimento seja mantido (RODRIGUES, 1998).

Figura 35 – Influência do consumo de agregado miúdo na resistência de à compressão de CAD



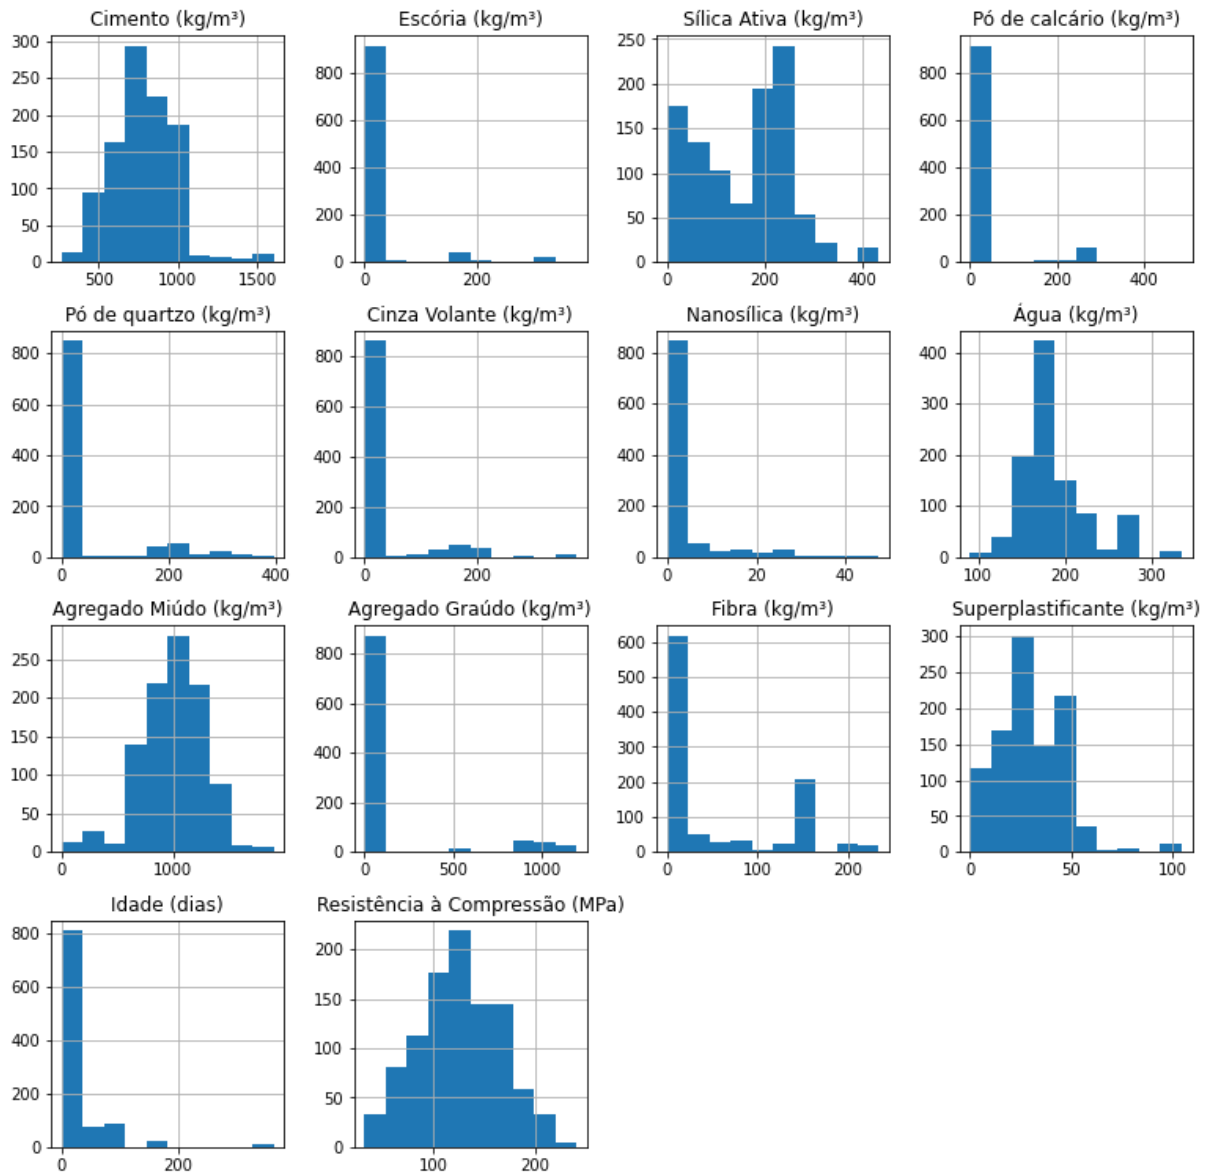
Fonte: Autora (2022)

6.3 Análise da base de dados de concreto de ultra alto desempenho

6.3.1 Tratamento dos dados

Assim como para os dados de CAD, procedeu-se com a análise em separado para os dados de CUAD, evidenciando que a análise individual de cada tipo de concreto é a melhor opção. As distribuições das variáveis observadas estão na Figura 36 em forma de histogramas. Nela, podem-se observar muitos valores nulos nas adições como observado na base de dados de CAD. Novamente, é incomum o uso de mais de duas adições. Também foram observadas muitas instâncias com valor nulo de consumo de agregado graúdo, já que na maioria dos CUAD não se utiliza esse material constituinte, sendo ele substituído no volume de concreto por pó de quartzo ou calcário, que auxilia no empacotamento das frações finas além de terem alta resistência.

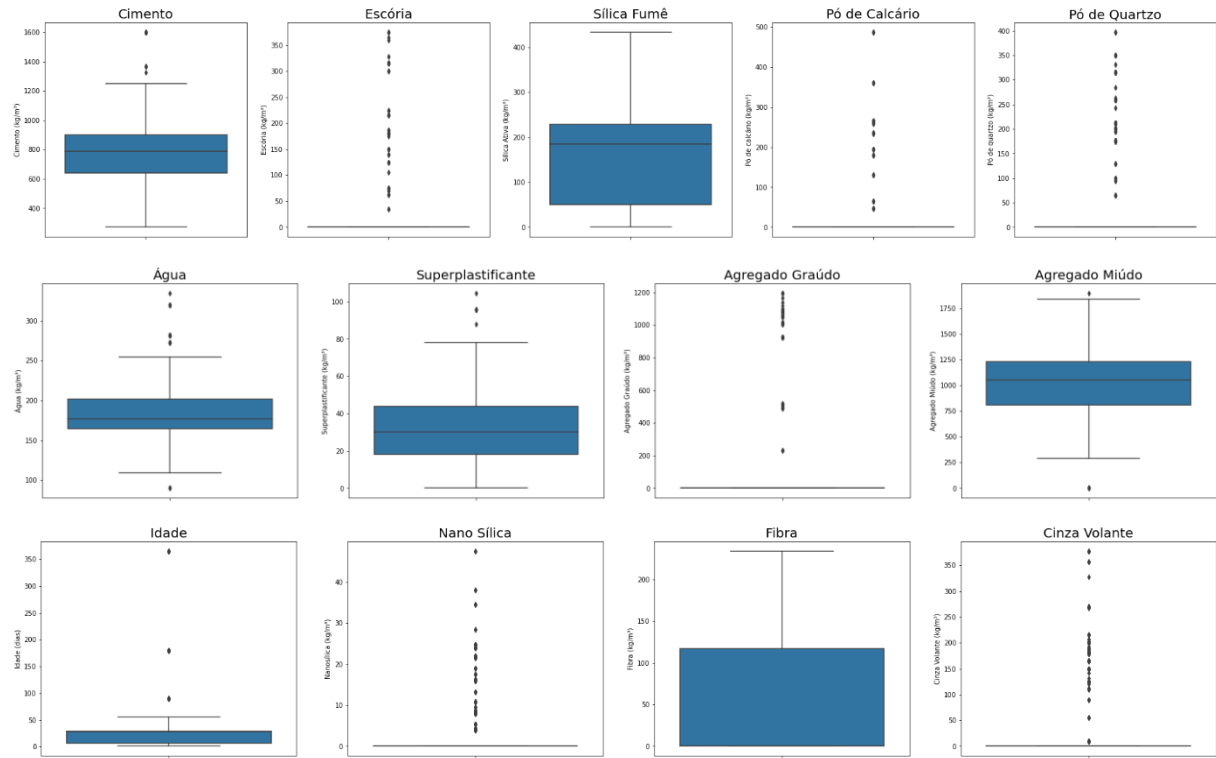
Figura 36 – Distribuição das variáveis da base de dados de CUAD em histograma



Fonte: Autora (2022)

Na Figura 37, vê-se a distribuição de *outliers* das variáveis constituintes da base de dados de CUAD. Os gráficos *boxplot* auxiliaram na definição dos intervalos de variância dos materiais na análise de sensibilidade.


Figura 37 – *Boxplots* e identificação de *outliers* nas variáveis da base de dados de CUAD



Fonte: Autora (2022)

6.3.2 Análise preliminar dos dados

Figura 38 – Mapa de calor de correlação das variáveis da base de dados de CUAD



Fonte: Autora (2022)

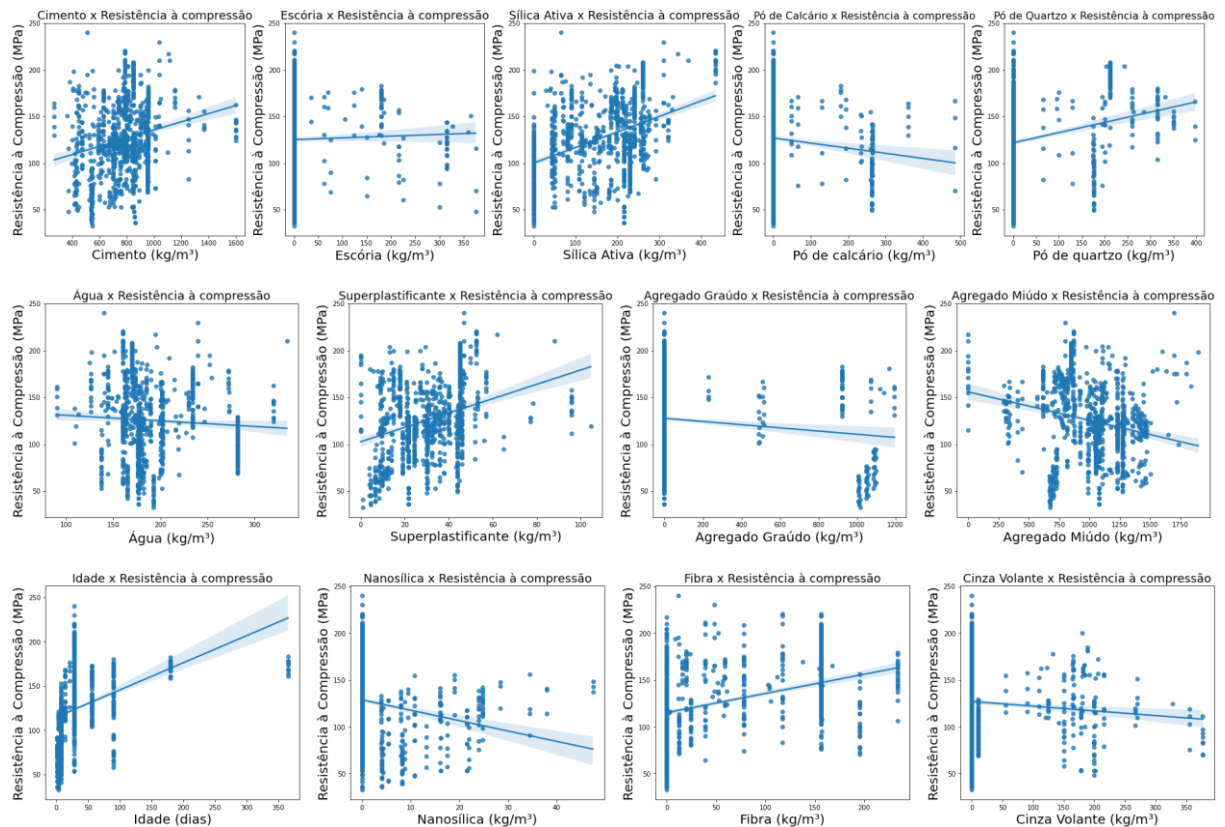
A Figura 38 traz o *heatmap* de correlação dos dados da base de dados de CUAD onde se pode ver que as principais influências positivas na resistência à compressão vêm da idade (0,63), da sílica ativa (0,4) e da fibra (0,39) comportamentos já comentados na seção 4.4 onde são discutidos os resultados de Hassani, Khalil e Danha (2014) em seu estudo com sílica ativa e fibras no CUAD.

Enquanto as principais influências negativas são da nanosílica (-0,34) e do agregado miúdo (-0,27). Najigivi *et al.* (2013) comenta sobre o uso de materiais como nanosílica com o

intuito de aumentar a resistência do concreto o que difere dos resultados de correlação encontrados. O efeito negativo do agregado miúdo se dá pela necessidade de grande quantidade de água de molhagem como comenta Rodrigues (1998).

Para complementar esses resultados, a Figura 39 traz as influências de cada material constituinte em gráficos *pairplot*, onde se vê que, além dos citados anteriormente, o cimento, o pó de quartzo e o superplastificante têm uma influência positiva na resistência à compressão, enquanto que a água e o agregado graúdo têm influência negativa.

Figura 39 – Gráficos *pairplot* com a influência das variáveis na resistência à compressão de CUAD



Fonte: Autora (2022)

6.3.3 Modelos de previsão

Os mesmos modelos utilizados para CAD foram utilizados para CUAD e novamente os de floresta aleatória (*Random Forest*) e de redes neurais obtiveram os melhores resultados. Sendo que inicialmente o modelo de floresta aleatória apresentou melhor desempenho, sendo necessário para a RNA um processo de otimização manual aumentando o número de neurônios na camada oculta para que ela performe melhor. Com isso, novamente, optou-se por continuar as análises utilizando RNA pelas melhores métricas mostradas na Tabela 18.

Comparando os modelos aqui desenvolvidos com trabalhos apresentados na seção 5.4 vemos que a principal diferença são algumas ferramentas adicionais utilizadas pelos pesquisadores. Ferramentas de seleção de variáveis e otimização que podem ter auxiliado no melhor desempenho destes modelos.

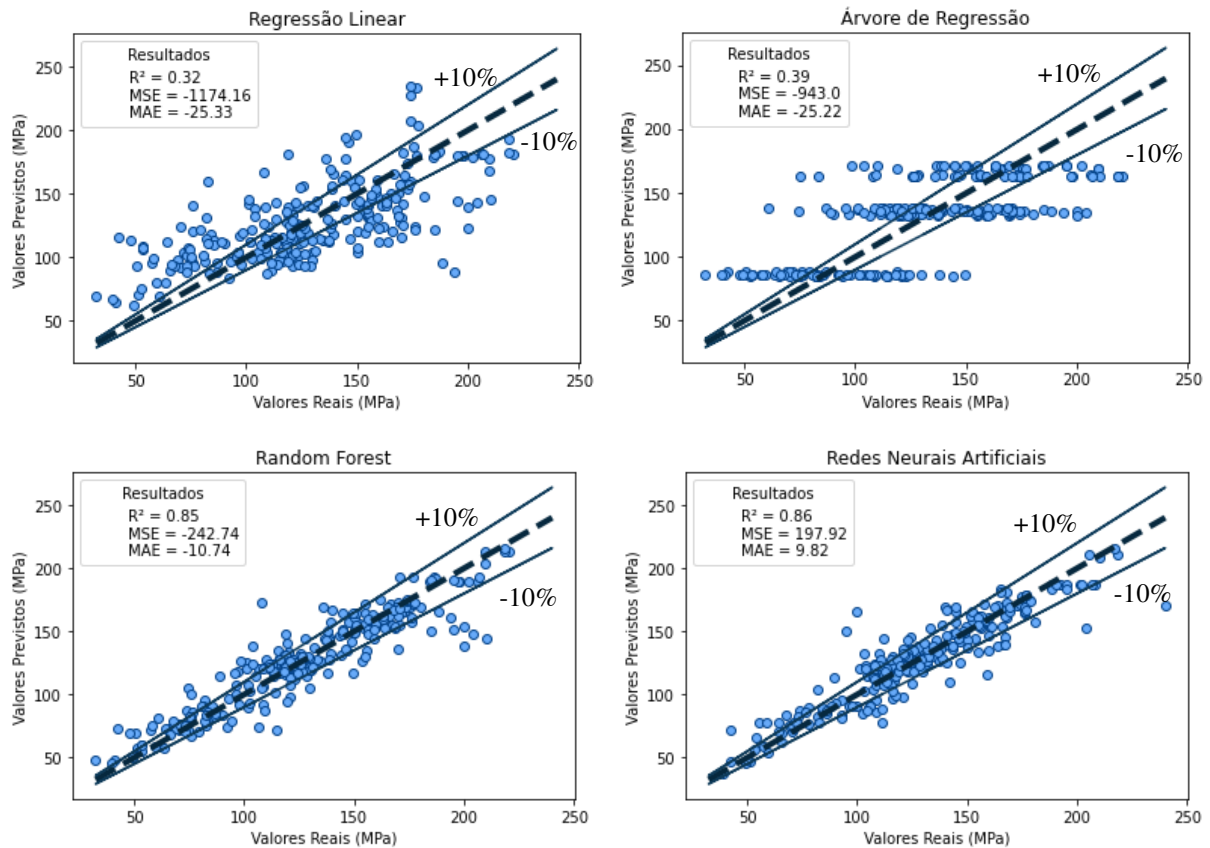
Tabela 18 - Métricas de desempenho de cada modelo utilizado na previsão da resistência à compressão de CUAD

Modelo	MSE	MAE	R ²
Regressão Linear	1.174,16	25,33	0,32
Árvore de Regressão	943,00	25,22	0,39
Floresta Aleatória	242,74	10,74	0,85
Redes Neurais Artificiais	197,92	9,82	0,86

Fonte: Autora (2022)

De maneira complementar às métricas já apresentadas, a Figura 40 apresenta os gráficos de ajuste de cada modelo que evidenciam o melhor desempenho do modelo de redes neurais já que seus pontos estão bem próximos à reta de igualdade e quase todos dentro do intervalo das retas de 10%. Os valores analisados são médias devido ao uso do método *K-Fold* que possui desvio padrão igual a 0,09.

Figura 40 – Comparação valores reais e valores previstos de resistência à compressão de CUAD para os modelos de previsão testados

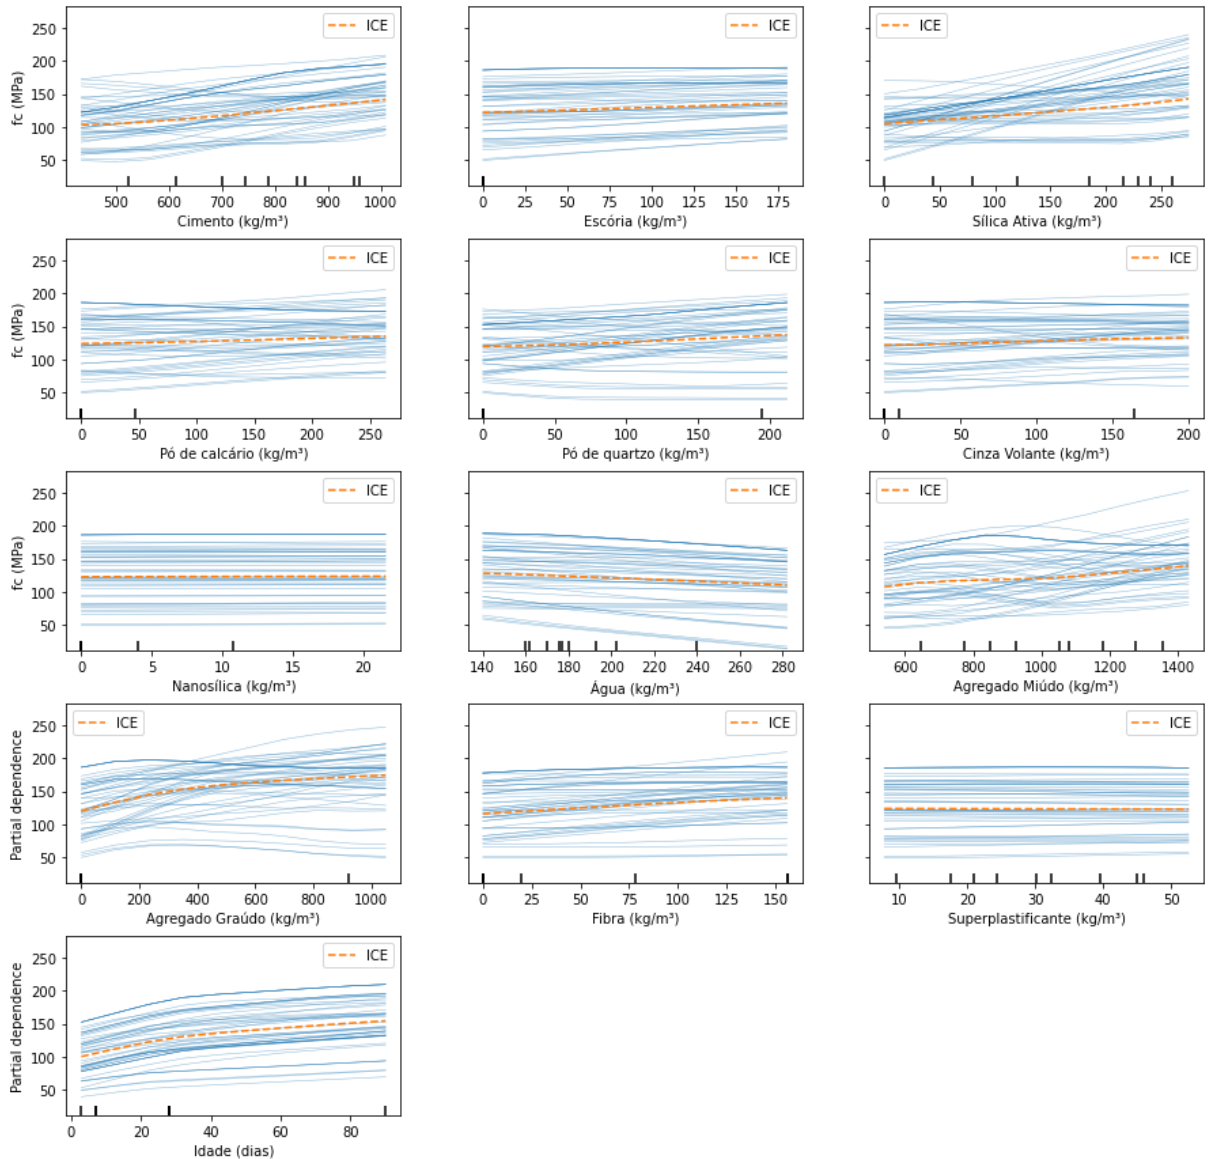


Fonte: Autora (2022)

6.3.4 Análise de sensibilidade

As análises feitas com os dados no modelo de redes neurais servem para confirmar que o modelo e os dados interpretam comportamentos que estão de acordo com o esperado para o tipo de concreto CUAD. Nos gráficos de dependência parcial da Figura 41, observa-se a influência e comportamento geral de cada variável na resistência à compressão. Sublinha-se que essa técnica não considera a possível interdependência entre os consumos de materiais, algo tratado mais à frente das análises paramétricas.

Figura 41 – Dependência parcial entre as variáveis da base de dados de CUAD e a resistência à compressão



Fonte: Autora (2022)

Em combinação aos gráficos de dependência parcial, outros tipos de análises como o que se apresenta na Figura 42, que traz gráficos 3D com duas variáveis, são fornecidos. Na Figura 42(a), têm-se as influências conjuntas do cimento e da sílica ativa. Ambos materiais constituintes têm efeitos positivos na resistência à compressão como visto nos estudos de Hassani, Khalil e Danha (2014) e Li e Song (2022), que foram apresentados no referencial teórico. A Figura 42(b) traz a influência do cimento e do superplastificante e pode-se observar que, para todas as quantidades de superplastificante, quanto mais cimento maior será a resistência, comportamento já consolidado para os tipos de concreto estudados. Além disso, nota-se uma pequena melhora na resistência com o aumento de superplastificante, o que pode

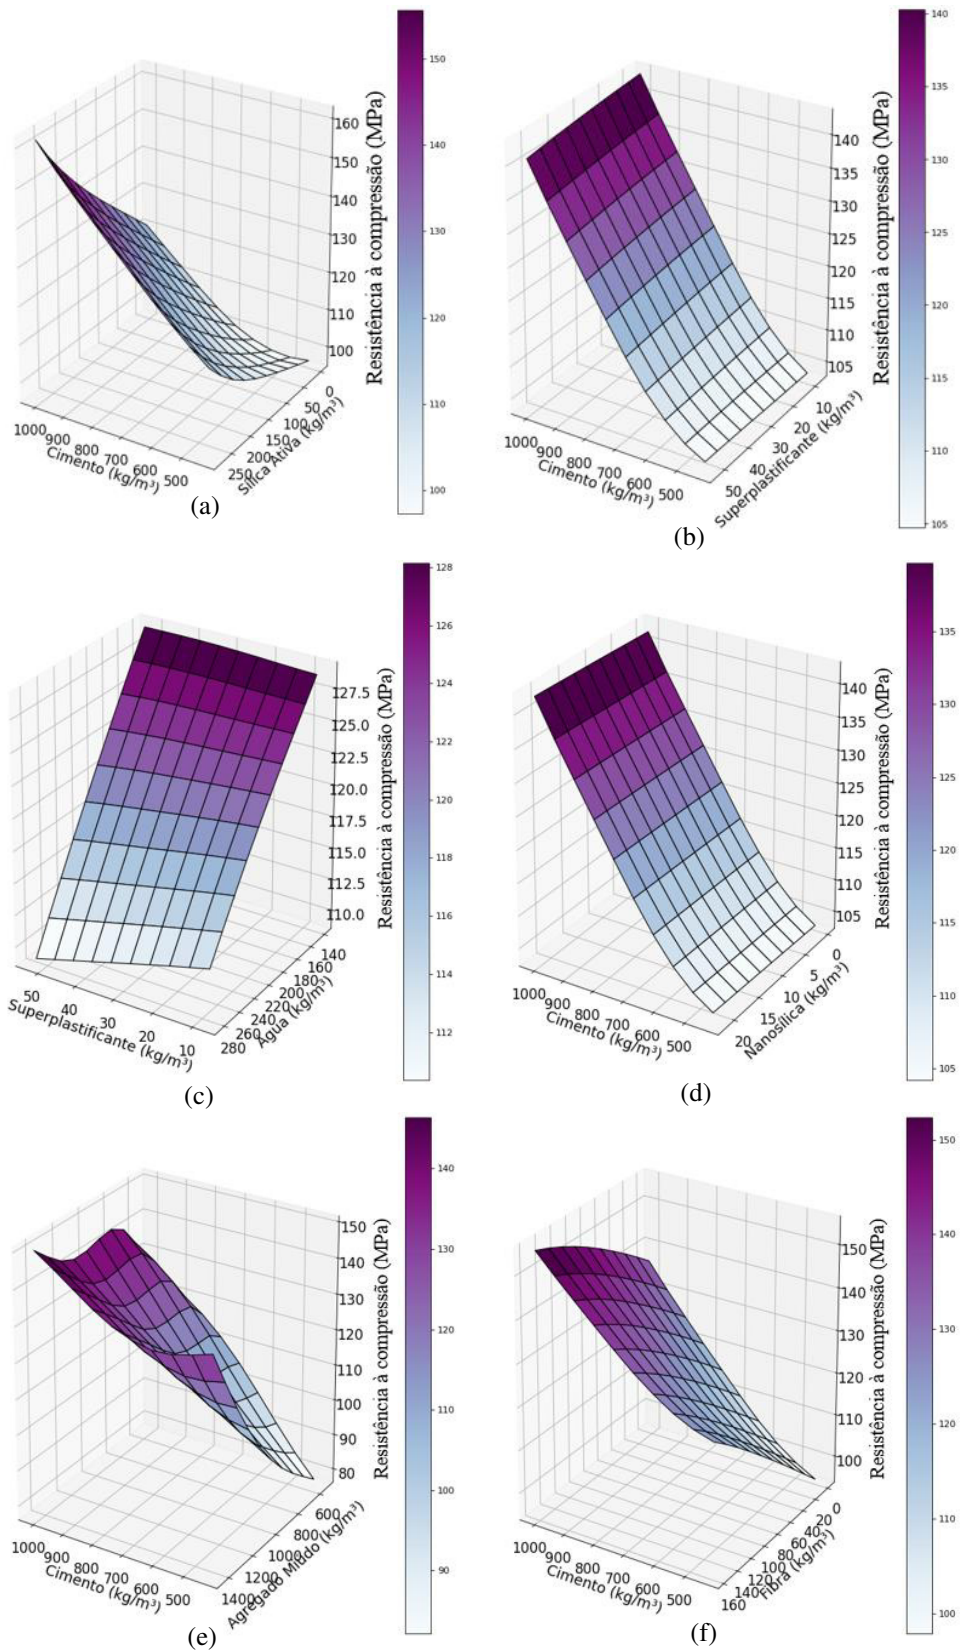
ser explicado pelo fato de que o uso de superplastificante auxilia na diminuição do uso de água, fazendo possível resistências cada vez maiores sem a necessidade de grandes quantidades de água. Este comportamento é confirmado na Figura 42(c), onde os maiores valores de resistência são observados em valores médios de superplastificante e água. Isso pode se dever a um efeito de ponto de saturação do superplastificante (AITCIN, 1998).

Os efeitos da nanosílica na resistência à compressão (Figura 42(d)) são positivos mesmo que não sejam tão significantes, diferentemente do que foi observado apenas na análise de correlação. Quando se analisa a influência da nanosílica juntamente com os efeitos do aumento do consumo de cimento, são percebidos grandes aumentos de resistência com o aumento da quantidade de cimento na mistura.

O CUAD, por normalmente não utilizar agregado graúdo, tem como principal agregado o miúdo, que, na Figura 42(e), tem boa influência positiva, aumentando a resistência juntamente com o cimento. Porém, esse comportamento não é linear, havendo quantidades de agregado miúdo para as quais na verdade há diminuição correspondente na resistência do concreto.

Analisando o comportamento do CUAD com fibras, a Figura 42(f) mostra que a adição de fibras ajuda no aumento da resistência à compressão. É sabido que a adição de fibras tem como principal objetivo melhorar a capacidade do concreto de conter esforços de tração e flexão principalmente, especialmente quanto à ductilidade e à tenacidade dos materiais. Porém, como apresentado na imagem de Gaiofatto (2012) e estudos de Hassani, Khalil e Danha (2014), as fibras acabam por agir no controle de fissuração e isso tem um impacto positivo também na resistência à compressão do concreto.

Figura 42 – Influência de diferentes materiais na resistência à compressão de CUAD

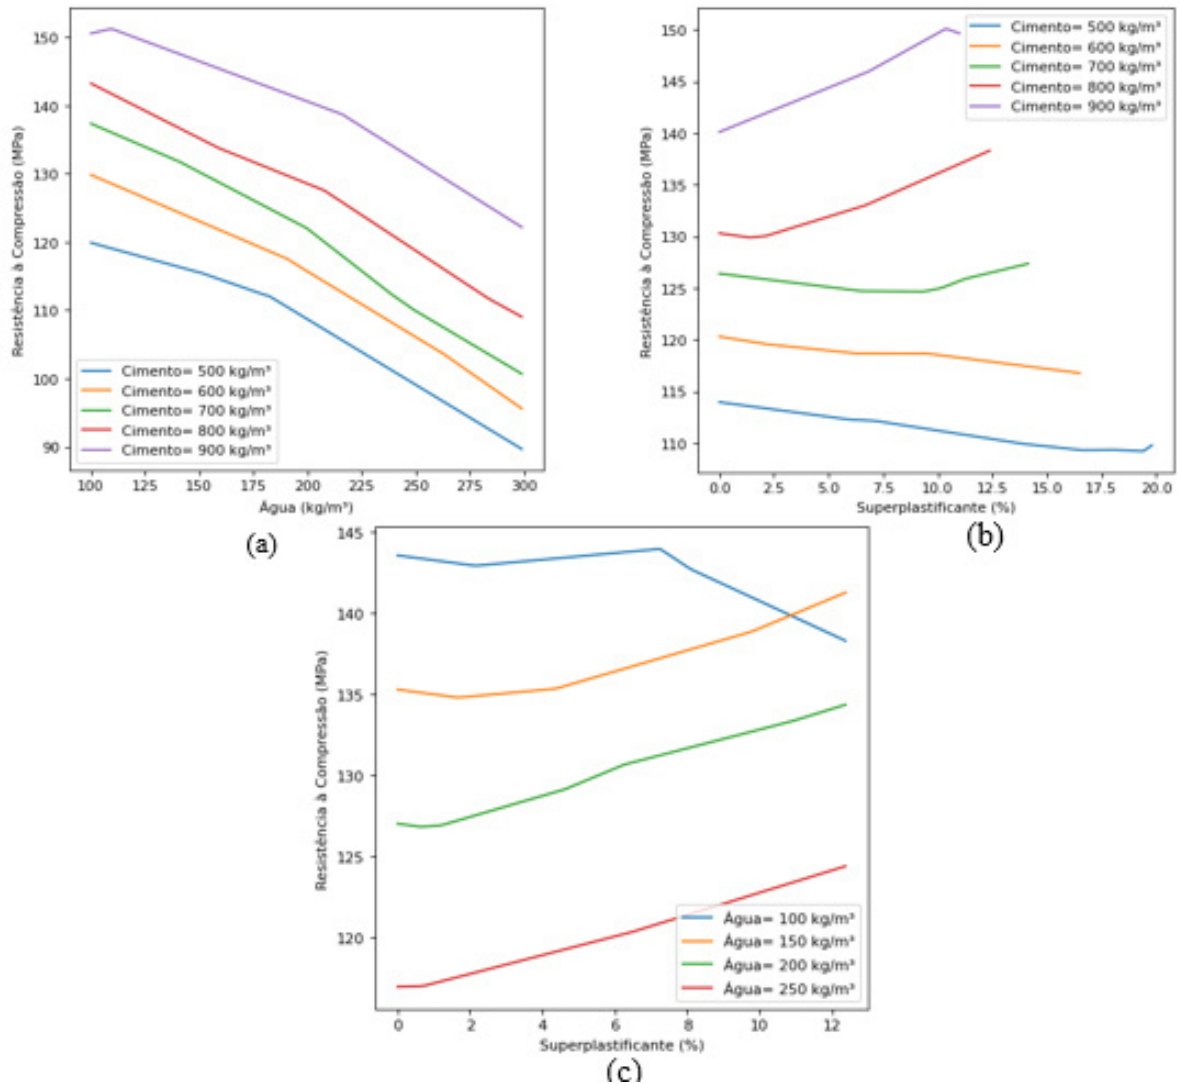


Fonte: Autora (2022)

De maneira complementar à visualização 3D já apresentada, apresentam-se análises onde são variadas as quantidades de alguns materiais constituintes respeitando a análise paramétrica do volume e massas utilizadas (cf. seção 5.4.2). Na Figura 43(a), novamente o efeito do consumo de cimento é positivo como esperado para todos os tipos de concreto. Ao aumentar a quantidade de água na mistura, temos valores menores de resistência, o que é igualmente esperado. Esse comportamento se confirma na Figura 43(b). Nela, vê-se que para consumos de cimento abaixo de 700 kg/m^3 , o efeito do consumo de superplastificante é pequeno na resistência. Porém, para consumos maiores, o aumento do teor de superplastificante aumentou a resistência.

Por fim, é analisada a variação de consumo de superplastificante para diferentes quantidades de água (Figura 43(c)), chegando-se à conclusão de que, no geral, o superplastificante aumenta a resistência à compressão para certos valores de consumo de água (da ordem de mais de 150 L/m^3). Porém, pode-se observar que, para o menor valor de consumo de água (de 100 L/m^3), ao se aumentar a quantidade de superplastificante, baixa-se a resistência. Com essas pequenas quantidades de água, o superplastificante pode não estar surtindo o efeito esperado.

Figura 43 – Influência do consumo de água e superplastificante na resistência à compressão de CUAD



Fonte: Autora (2022)


Na Figura 44, analisa-se a resistência à compressão do concreto de acordo com a variação de consumo das adições. Para ambas as análises, as adições substituíram certa massa de cimento, conforme análise paramétrica proposta na seção 5.4.2.

Na Figura 44(a) temos fixados os valores de cimento + sílica e ao aumentarmos a quantidade de sílica a resistência aumenta. Em certo ponto os valores de resistência passam a decair quando aumentamos o teor de sílica, pois ao aumentarmos a quantidade sílica estamos diminuindo a quantidade de cimento que é o material que mais proporciona efeitos positivos na resistência à compressão do concreto.

Este comportamento é mais evidente na menor quantidade analisada (500kg/m^3), onde, a resistência passa a decair quando as quantidades de sílica ativa e cimento se aproximam.

Enquanto isso, na Figura 44(b), vê-se que a nanosílica tem influência positiva até certo ponto (por volta de 15kg/m^3), ao aumentar a sua quantidade sua influência passa a não ser tão significativa, apresentando retas quase que constantes. Esta é uma característica da base de dados onde a quantidade máxima de nanosílica utilizada foi em torno de 40kg/m^3 , enquanto a sílica ativa teve quantidades próximas a 400kg/m^3 .


Figura 44 – Influência da substituição de cimento por adições na resistência à compressão de CUAD



Fonte: Autora (2022)

A influência do consumo de agregado miúdo na resistência do CUAD (Figura 45) é substancialmente positiva para os menores consumos de cimento (500 e 600kg/m^3), enquanto para os outros consumos a influência é essencialmente negativa ao aumentamos a quantidade de agregado miúdo. Considerando que o CUAD usualmente não utiliza agregado graúdo, o agregado miúdo terá as partículas com maiores dimensões. O ponto de inflexão nas curvas vai mais à direita (maiores consumos de agregado miúdo) quando se aumenta a quantidade de cimento, isso se explica pela maior quantidade de água necessária na mistura, já que ao aumentar os consumos de cimento e agregados (materiais secos) precisa-se de uma maior quantidade de água para atingir uma dada trabalhabilidade.

Figura 45 – Influência de agregado miúdo na resistência à compressão de CUAD



Fonte: Autora (2022)

7 CONCLUSÃO E RECOMENDAÇÕES

Por meio deste estudo, foi possível analisar as influências dos principais materiais constituintes utilizados na produção de concretos de tipos CAD e CUAD e evidenciar algumas das diferenças entre eles. Por mais que se utilizem os mesmos tipos de materiais constituintes, ou similares, foram observadas diferenças (como em dosagem, produção e cura) que produziram comportamentos bem diferentes, de maneira que as ferramentas desenvolvidas precisaram tratar separadamente os bancos de dados de CAD e de CUAD. Esta constatação foi possível com o auxílio dos dois bancos de dados atualizados de CAD com 1238 dados de dosagem e CUAD com 1023. Estes serão disponibilizados em plataformas públicas de tal maneira a ser útil para futuros trabalhos.

As análises preliminares seguiram, então, de forma separada entre os dois bancos de dados, onde as influências de cada material constituinte foi novamente analisada. Em geral, as influências são semelhantes para ambos concretos, trazendo como principal diferença seus teores dentro da mistura. Enquanto CADs utilizam quantidades de cimento em torno de 600kg/m^3 , os CUADs utilizam quantidades variando em torno de 1000 kg/m^3 . Isso é observado para a maioria dos materiais, tendo maiores diferenças: nos teores de agregado graúdo, que é ausente na maioria das misturas de CUAD; e na relação água cimento, que, para CAD, é encontrada até 0,4 e CUAD não ultrapassa 0,2. Além disso, o CUAD utiliza mais tipos de adições que o CAD, devido à retirada do agregado graúdo, passam a ser utilizados vários tipos de pó como quartzo e calcário que possuem alta resistência, com o intuito de melhorar o empacotamento.

As análises preliminares auxiliaram na escolha das variáveis utilizadas na criação dos modelos de aprendizagem de máquina. Dos modelos utilizados, a Regressão Linear e Árvore de regressão não obtiveram bom desempenho. Considerando que os modelos tinham grande número de variáveis que influenciam de maneira distinta, passou-se a não mais ter um problema linear justificando a performance prejudicada destes dois tipos de modelo. A árvore de regressão por ser um modelo originalmente de classificação trabalha separando os dados até certo ponto, e isso limita os valores de saída e resulta em um modelo com baixo desempenho. Os modelos de *Random Forest* e Redes Neurais Artificiais (RNA) tiveram resultados bons e muito próximos, sendo o de RNA o que obteve maior desempenho ao se comparar as métricas de erro (MSE, MAE e R^2), posteriormente utilizado para produzir análises paramétricas e interpretação.

Sabendo que valores de erros isolados não são suficientes para a validação de um modelo, testou-se a capacidade de interpretação dos modelos de RNA por meio de análises de sensibilidade. Essas análises produziram resultados coerentes com o esperado em função do conhecimento atual de tecnologia do concreto. Os comportamentos encontrados na literatura e nas análises iniciais, desde os valores de correlação até os gráficos de *pairplot*, são compatíveis e evidenciam que as ferramentas criadas têm uma boa capacidade de aprendizagem e predição.

Os principais comportamentos encontrados foram a influência positiva do cimento na resistência à compressão e a influência negativa da água que foi confirmada em todos os tipos de análise e condiz com os vários estudos realizados por pesquisadores da área. Outro comportamento observado foi o ponto de saturação do superplastificante, cujo efeito foi observado nos gráficos de CAD. Os gráficos de CUAD trouxeram em sua maioria para as adições e agregado miúdo que eles ajudam no acréscimo da resistência, mas apenas até certo ponto, de maneira que valores maiores resultam em menor resistência. Esse comportamento pode ser explicado pelo aumento da quantidade de materiais secos, visto que quanto mais materiais secos mais água será necessária para permitir as condições de adensamento. Então, outras características como teor de vazios e incremento de ar resultam na diminuição da resistência.

Sendo assim, o modelo de RNA, por trazer valores mínimos de erro e boa capacidade de predição, respeitando os comportamentos esperados para cada tipo de concreto, foi a ferramenta de *Machine Learning* mais indicada dentre as ferramentas testadas neste trabalho.

Com base nas principais dificuldades encontradas neste trabalho são trazidas sugestões para trabalhos futuros:

- a) **Acrescentar nas bases de dados informações a respeito das características dos materiais constituintes:** Por ser um trabalho realizado com dados, a maior limitação encontrada foi a falta de informações. Então, a descrição dos materiais constituintes utilizados nas misturas de concreto é de suma importância pois estes têm composições diferentes a depender do local e estes têm grande influência no comportamento final do concreto. As principais informações que podem ser implementadas em futuras análises são:
 - Composição do cimento: Alguns tipos de cimento contêm adições porém, são contabilizadas apenas como cimento, um estudo da composição do cimento pode trazer valores mais reais a respeito dos materiais cimentícios e pozolânicos utilizados.

- Características dos agregados: Apenas a quantidade utilizada de agregados não é suficiente para estudar suas influências já que outras características influenciam mais na resistência. Aqui cito algumas características que podem ser implementadas em modelos futuros: faixa granulométrica, formato dos grãos, tipo de agregado, módulo de finura.

- Tipo de superplastificante: Existem diferentes classes de superplastificante utilizados, sendo utilizado em CADs e CUADs principalmente os de terceira geração. Mesmo que estes tenham características bem similares entre si, considerar o tipo de superplastificante utilizado também pode trazer benefícios na ferramenta de previsão.

- b) Buscar e considerar em estudos e ferramentas futuras dados sobre tratamentos de cura térmica em CUAD:** Por ser uma das principais características que difere CAD e CUAD esta é uma informação muito importante já que é um procedimento essencial com comprovações de que traz benefícios significativos nos valores de resistência e ao não considerar estas individualidades pode-se produzir modelos pouco eficazes. Esta informação não foi analisada neste trabalho devido à pouca quantidade de dados encontrados de controle de cura térmica, mas a busca deste tipo de dado é recomendada para implementar em melhorias da ferramenta. A principal informação necessária quanto a cura térmica é a temperatura utilizada.
- c) Adotar uma classificação mais aprofundada para CAD e CUAD que evidencie suas diferenças:** As classificações destes tipos de concreto são usualmente dadas quanto à resistência à compressão e foi observado que estas variam de acordo com o local e o pesquisador. O ideal seria um meio de classificação que considere além das características mecânicas as características de trabalhabilidade e processos utilizados na produção do concreto. E então por meio de ferramentas de análise de dados propor uma classificação para cada um destes tipos de concreto.
- d) Utilizar diferentes processos de otimização:** Além dos processos aqui utilizados outros métodos podem ser testados de forma a melhorar o desempenho das ferramentas. Um processo a ser testado é o método de otimização gaussiana.

- e) **Validar a ferramenta em campo com dados regionais:** Sabendo que os materiais são diferentes em cada local, a ferramenta aqui desenvolvida se mostra eficiente para os dados coletados. Porém, faz-se necessário uma validação com dados de dosagens regionais a fim de verificar quão boas são as previsões de resistência aplicadas em concretos feitos no Brasil, mais especificamente no Ceará. Uma parceria com concreteiras da região é de grande necessidade para aprimorar a ferramenta e introduzir o método no mercado.

O código utilizado na criação das ferramentas juntamente com as bases de dados atualizadas se encontram neste [link](#).

REFERÊNCIAS

- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 8953: Concreto para fins estruturais – Classificação pela massa específica, por grupos de resistência e consistência**. Rio de Janeiro. 2015.
- ABUODEH, O. R.; ABDALLA, J. A.; HAWILEH, R. A. Assessment of Compressive Strength of Ultra-high performance concrete using deep machine learning Techniques. **Applied Soft Computing Journal**, v. 95, 2020
- AITCIN, P.C. Concreto de alto desempenho. 1. ed. São Paulo: PINI, 2000. _____. Binders for durable and sustainable concrete. Abingdon: Taylor & Francis, 2008 (Modern Concrete Technology, 16)
- AKKURT, S, OZDEMIR, S, TAYFUR, G e AKYOL, B. The use of GA-ANNs in the modelling of compressive strength of cement mortar. **Cement and Concrete Research**, v. 33, p. 973 – 979. 2003.
- AMERICAN CONCRETE INSTITUTE. Committee 363R-92 (Reapproved 1997). State of the art report on high strength concrete. **ACI Manual of Concrete Practice**, part 1. Farmington Hills: ACI, 1998.
- AYIRA, O. J. F. **Investigating the Properties of Reactive Powder Concrete (RPC) – Compressive and Flexural Strength**. Trabalho de conclusão de curso (Bacharelado em Engenharia Civil). Universiti Teknologi Petronas. Malaysia. 2013.
- BARATA, M. S. **Concreto de alto desempenho do estado do Pará: Estudo de viabilidade técnica e econômica de produção de concreto de alto desempenho com os materiais disponíveis em Belém através do emprego de adições de sílica ativa e metacaulin**. 1998. 188f. Dissertação (Mestrado em engenharia civil) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 1998.
- BARBOSA, J. S. **Aplicação do Concreto de Ultra Alto Desempenho em Viga Pré moldada protendida para Pontes**. 2021. 263f. Dissertação (Mestrado em Engenharia Civil) Universidade Federal de São Carlos. São Carlos, 2021.
- BIZ, C.E. **Concreto de pós reativos**. Campinas: UEC, 2001. Dissertação (Mestrado em Engenharia Civil), Universidade Estadual de Campinas, Campinas, 2001.
- BUTTIGNOL, T. E. T.; FERNANDES, J. F.; SOUSA, J. L. A. O.; BITTENCOURT, T. N. **Aplicações do Concreto de Ultra Alto Desempenho (CUAD) em obras de reforço e recuperação de estruturas**. In. ANAIS DO 60º CONGRESSO BRASILEIRO DO CONCRETO - CBC2018 – 60CBC, 2018.
- CHAI, T. e DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geosci. Model Dev**, Vol. 7. 2014.

- CHEN, H., DENG, T., DU, T., CHEN, B., SKIBNIEWSKI, M. J. e ZHANG, L. An RF and LSSVM–NSGA-II method for the multi-objective optimization of high-performance concrete durability. **Cement and Concrete Composites**. v. 129. 2022.
- CHENG, M.-Y., CHOU, J.-S., ROY, A. F. V. e WU, Y.-W. High-performance Concrete Compressive Strength Prediction using Time-Weighted Evolutionary Fuzzy Support Vector Machines Inference Model. **Automation in Construction**, v. 28. 2012
- CHINDAPRASIRT, P., CHOTITHANORM, C., CAO, H. T. e SIRIVIVATNANON, V. N. Influence of fly ash fineness on the chloride penetration of concrete. **Construction and Building Materials**, v. 21, 356-361, 2007.
- CHOU, J.-S., CHIU, C.-K. FARFOURA, M. e AI-TAHARWA, I. Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on a Comparison of Data-Mining Techniques. **Journal of computing in civil engineering**. 2011.
- CHOU, J.-S. e TSAI, C.-F. Concrete compressive strength analysis using a combined classification and regression technique. **Automation in Construction**, Vol. 24, p. 52-60. 2012.
- FLAI. **Dominando Data Science 3.0**. Disponível em: <www.flai.com.br/dds/>. Acesso em 13/05/2022.
- FENG, N., FENG, X., HAO, T. e XING, F. Effect of ultrafine mineral powder on the charge passed of the concrete. **Cement and Concrete Research**, v. 32, 623-627, 2002.
- GAIOFATTO, R. L.; DA SILVA, T. L. C. DESENVOLVIMENTO DE CONCRETO DE PÓS REATIVOS (RPC) COM FIBRAS SINTÉTICAS. **Revista de Engenharia da Universidade Católica de Petrópolis**, v. 7, n. 1, 2012.
- HAKIM, S. J. S., NOORZAEI, J., JAAFAR, M. S., JAMEEL, M. e MOHAMMADHASSANI, M. Application of artificial neural networks to predict compressive strength of high strength concrete. **International Journal of the Physical Sciences**. v. 6, p. 975-981, 2011.
- HARTMANN, C. T. e HELENE, P. R. L. Avaliação de aditivos superplastificantes base policarboxilatos destinados a concretos de cimento portland. **Boletim Técnico da Escola Politécnica da USP**, Departamento de Engenharia de Construção Civil, BT/PCC/330. São Paulo. 2003.
- HASSANI, H. M. AL, KHALIL, W. I. e DANHA, L. S. Mechanical properties of reactive powder concrete with various steel fiber and silica fume contents. **ACTA TEHNICA CORVINIENSIS – Bulletin of Engineering**. Tome VII [2014], Fascicule 1.
- HOANG, N. D., PHAM, A. D., HGUYEN, Q. L., PHAM, Q. N. Estimating Compressive Strength of High Performance Concrete with Gaussian Process Regression Model. **Hindawi Publishing Corporation**. 2016.
- ISAIA, G. C., TUTIKIAN, B. F. e HELENE, P. **Concreto de Alto Desempenho e Ultra-Alto Desempenho**. In. ISAIA, G. C., TUTIKIAN, B. F. e HELENE, P. **Concreto: Ciência e Tecnologia**. IBRACON, 2011.

ISAIA, G. C., TUTIKIAN, B. F. e HELENE, P. **Materiais de Construção Civil e Princípios de Ciência e Engenharia de Materiais**. IBRACON, 2ed. v. 2. São Paulo, 2010.

KASPERKIEWICZ, J., RACZ, J., DUBRAWSKI, A. HPC Strength Prediction Using Artificial Neural Network. **Journal of Computing in Civil Engineering**, v. 9, 279-284, 1995.

KHAN, S. U., AYUB, T. e RAFEEQI, S. F. A. Prediction of Compressive Strength of Plain Concrete Confined with Ferrocement using Artificial Neural Network (ANN) and Comparison with Existing Mathematical Models. **American Journal of Civil Engineering and Architecture**, Vol. 1, 2013.

KONSTANTIN, S. The development of a new method for the proportioning of high-performance concrete mixtures. **Cement & Concrete Composites**, v. 26, p. 901-907, 2004.

KUMBHAR, P. D. e MURNAL, P. B. A new mix design method for high performance concrete under tropical conditions. **Asian Journal of Civil Engineering (BHRC)**, v. 15, NO.3 p. 467 – 483, 2014.

LARRARD, F., SEDRAN, T. Mixture-proportioning of high-performance concrete. **Cement and Concrete Research**, v. 32, 1699-1704, 2002.

LI, Q-F e SONG, Z-M. High-performance concrete strength prediction based on ensemble learning. **Construction and Building Materials**, v. 324, 2022.

LIMA, F. B. **Pilares de concreto de alto desempenho: fundamentos e experimentação**. 227 f. 1997. Tese (Doutorado em Engenharia) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 1997.

LIMA, S. M.; LIBÓRIO, J. B. L. Concreto de alto desempenho em ambientes com baixas temperaturas. **Cadernos de Engenharia de Estruturas**, v. 10, n. 43, p. 55-73, 2008.

LU, J-X., SHEN, P., ASAD Ali, H., SUN POON, C., Mix design and performance of lightweight ultra high-performance concrete, **Materials & Design**, 2022.

MARANI, A., JAMALI, A., NEHDI. M. L. Predicting Ultra-High-Performance Concrete Compressive Strength Using Tabular Generative Adversarial Networks. **Materials**, v. 13, 2020.

MORETTI, J. F. **Sistema Inteligente Baseado na Redes Neurais Artificiais para Dosagem do Concreto**. 2010. Tese (Doutorado em Engenharia Elétrica). Faculdade de Engenharia – UNESP. SP. 2010.

MULIAUWAN, H. N., PRAYOGO, D., GABY, G. e HARSONO, K. Prediction of Concrete Compressive Strength Using Artificial Intelligence Methods. **Journal of Physics: Conference Series**. 2020.

MULLER, R. M; KOELLE, P; ALMEIDA, C. N. A utilização de UHPC em obras no Brasil. **Concreto & Construções**, São Paulo, n. 87, p. 57-62, 2017.

NAJIGIVI, A. KHALOO, A., ZAD, A. I. e RASHID, S. A. An Artificial Neural Networks Model for Predicting Permeability Properties of Nano Silica–Rice Husk Ash Ternary Blended

Concrete. **International Journal of Concrete Structures and Materials**, v. 7, p. 225-238, 2013.

PARICHATPRECHA, R. e NIMITYONGSKUL, P. Analysis of durability of high performance concrete using artificial neural networks. **Construction and Building Materials**, v. 23, 910-917, 2009.

PREM, R. R., BHARATKUMAR, B. H. e IYER, N. R. Mechanical properties of Ultra High Performance Concrete. World Academy of Science, **Engineering and Technology International Journal of Civil and Environmental Engineering**. v:6, No:8, 2012.

PREM, P. R., BHARATKUMAR, B. H. e MURTHY, A. R. Influence of curing regime and steel fibers on the mechanical properties of UHPC. **Magazine of Concrete Research**, 2014.

RODRIGUES, P. P. F. **Parâmetros de dosagem do concreto**. 3ed. São Paulo, ABCP, 1998. 32p.

SCIKIT-LEARN. **Scikit-learn 1.2.dev0: User Guide**. Disponível em: < scikit-learn.org/dev/supervised_learning.html#supervised-learning > Acesso em: 22/04/2022.

SHIN, J. **Ultra-high performance concrete (UHCP) precast segmental bridges**. 2016. Doctoral thesis. University Library of Technical University Hamburg-Harburg, Seoul, Korea, 2016.

SILVA, I. S. **Concreto de Alta Resistência: composição, propriedades e dimensionamento**. 128 f. Dissertação (Mestrado em Engenharia) – Escola de Engenharia de São Carlos, Universidade de São Paulo, 1995.

SILVA, O. F., GOMES, P. C. C. e MORAIS, K. A. M. Analytical method for determining the saturation point of superplasticizers in cement pastes using the Marsh cone. **Cerâmica**, v. 65, p. 252-260. 2019.

SILVA, W. K. D., RUBENS, T. D. M., FREITAS, I. L. B., BABADOPULOS, L. F. A. L. CABRAL, A. E. B., MURTA, A. H. F. **Desenvolvimento de Ferramenta a partir de Rede Neural Artificial para Previsão do Coeficiente de Atenuação Linear em Concretos Pesados**. Anais do 62º Congresso Brasileiro de Concreto (CBC), IBRACOM, 2020.

SILVA, Wellington Cesar Teles. GARCIA, Gustavo Pereira. **APLICAÇÃO DE CONCRETOS DE ALTA RESISTÊNCIA, ALTO E ULTRA-ALTO DESEMPENHO**. **Revista Científica Semana Acadêmica**. Fortaleza, 2020.

SMITH, A. S. J. e XU, G. Classification of Ultra-high Performance Concrete (UHPC). **European Journal of Engineering and Technology Research**. v. 6, 2021.

SOSA, I., THOMAS, C., POLANCO, J.A., SETIÉN, J., SAINZ-AJA, J.A. e TAMAYO, P. Durability of high-performance self -compacted concrete using electric arc furnace slag aggregate and cupola slag powder. **Cement and Concrete Composites**, v. 127, 2022.

TORREGROSA, E. C. **Dosage optimization and bolted connections for UHPFRC ties**. 2013. Tese (Doutorado em Engenharia civil), Universitat Politècnica de València. Spain. 2013.

TUTIKIAN, F. B e HELENE, P. Dosagem dos Concretos de Cimento Portland. . *In.*
TUTIKIAN, B. F. e HELENE, P. Concreto: Ciência e Tecnologia. IBRACON, 2011.

VANDERLEI, R. D. **Análise experimental do concreto de pós reativos: dosagem e propriedades mecânicas**. Tese de Doutorado. USP-Universidade de São Paulo. São Carlos, São Paulo, 2004.

UNIVERSIDADE FEDERAL DO CEARÁ. Biblioteca Universitária. Comissão de Normalização. **Guia de normalização para elaboração de referências da Universidade Federal do Ceará**. Fortaleza, 2020.

UNIVERSIDADE FEDERAL DO CEARÁ. Biblioteca Universitária. Comissão de Normalização. **Guia de normalização para elaboração de citações da Universidade Federal do Ceará**. Fortaleza, 2019.

WEE, T. H., SURYAVANSHI, A. K. e TIN, S. S. Influence of aggregate fraction in the mix on the reliability of the rapid chloride permeability test. **Cement and Concrete Composites** v. 21, 59 – 72, 1999.

YEH, I.-C. Computer-aided design for optimum concrete mixtures. **Cement & Concrete Composites**, v. 29, 193-202, 2007.

YEH, I.-C. Design of High-Performance Concrete Mixture Using Neural Networks and Nonlinear Programming. **Journal of Computing in Civil Engineering**, v. 13, 36-42, 1999.

YEH, I.-C. Exploring Concrete Slump Model Using Artificial Neural Networks. **Journal of Computing in Civil Engineering**, v. 20, 217-221, 2006.

YEH, I.-C. e LIEN, L.-C. Knowledge discovery of concrete materials using Genetic Operation Trees. **Expert Systems with Applications**, v. 36, 5807-5812, 2009.

YEH, I.-C. Modeling Concrete Strength with Augment-Neuron Networks. **Journal of Materials in Civil Engineering**, v. 10, 263-268, 1998.

YEH, I.-C. Modeling of Strength of High-Performance Concrete using Artificial Neural Networks. **Cement and Concrete Research**, v. 28. China, 1998.

YEH, I.-C. Modeling slump flow of concrete using second-order regressions and artificial neural networks. **Cement & Concrete Composites**, v. 29, 474-480, 2007.

YEH, I.-C. Optimization of concrete mix proportion using a flattened simplex-centroid mixture design and neural networks. **Engineering with Computers**. V. 25, 179–190, 2009.

YEH, I.-C. Simulation of concrete slump using neural networks. **Construction Materials**, v. 162. 2008.

ZHANG, J., ZHAO, Y. e LI, H. Experimental Investigation and Prediction of Compressive Strength of Ultra-High Performance Concrete Containing Supplementary Cementitious Materials. **Hindawi. Advances in Materials Science and Engineering**. 2017

ZHENG, Y., ZHOU, Y., HUANG, X., MIN, Y., LUO, H., CHEN, Y. e LI, W. Study on performance improvement of ultra-high performance concrete by vibration mixing. **Construction and Building Materials**, v. 327, 2022.