CAPÍTULO 40 · Parte II · Materiais
DOI do capítulo: https://doi.org/10.67775/k7w24y24
Trabalho apresentado no CBPAT 2026 e publicado nos anais do evento: https://doi.org/10.67775/6wapd693

INFLUÊNCIA DA MÉTRICA DE SIMILARIDADE NO DESEMPENHO DE REDES ARTMAP NA PREVISÃO DA RESISTÊNCIA MECÂNICA DE CONCRETOS DE ULTRA ALTO DESEMPENHO COM METACAULIM

Murilo Henrique Lima de Souza[1]*, Reginaldo José da Silva[2]; Thays Aparecida de Abreu Santos[3]; Mara Lúcia Martins Lopes[3]
*Autor de contato:murilo.l.souza@unesp.br

[1] Departamento de Engenharia Civil, UNESP - FEIS, Ilha Solteira, Brasil
[2] Departamento de Engenharia Elétrica, UNESP - FEIS, Ilha Solteira, Brasil
[3] Departamento de Matemática, UNESP - FEIS, Ilha Solteira, Brasil

RESUMO

Atualmente, torna-se indispensável refletir sobre a interface ambiental da Construção Civil, em razão de seu protagonismo na emissão de poluentes atmosféricos. Diante dos avanços tecnológicos, modelos inteligentes foram aplicados a um banco de dados composto por 180 amostras de concretos de ultra alto desempenho (CUAD) com substituição parcial do cimento por metacaulim, com o objetivo de avaliar a resistência mecânica frente às solicitações estruturais. Dois cenários de modelagem foram investigados: o primeiro sem a variável teor de metacaulim como entrada, e o segundo com sua inclusão, permitindo analisar em que medida essa informação contribui para a qualidade das previsões. Os resultados foram comparados entre valores reais e estimados, considerando diferentes arquiteturas de Redes Neurais (ARTMAP-Fuzzy, ARTMAP Euclidiana e ARTMAP Manhattan) a fim de analisar o potencial preditivo e o desempenho de cada modelo frente às métricas adotadas.
Palavras-chave: Concretos; ARTMAP; Metacaulim. Substituições Parciais, Previsões.

ABSTRACT

Currently, it is essential to reflect on the environmental interface of the Construction Industry due to its significant role in atmospheric pollutant emissions. In light of technological advancements, intelligent models were applied to a database composed of 180 samples of ultra-high performance concrete (UHPC) with partial cement replacement by metakaolin, aiming to evaluate mechanical strength properties under structural loading conditions. Two modeling scenarios were investigated: the first without the metakaolin content as an input variable, and the second with its inclusion, allowing analysis of the extent to which this information contributes to prediction quality. The obtained results were compared between real and predicted values, considering different Neural Network architectures (Fuzzy ARTMAP, Euclidean ARTMAP and Manhattan ARTMAP), in order to analyze the predictive potential and performance of each model under the adopted metrics.
Keywords: Concrete; ARTMAP; Metakaolin; Partial Replacement; Predictions.

1. INTRODUÇÃO

Segundo estudos consolidados na literatura, “a indústria do cimento é responsável por aproximadamente 7-8% das emissões globais antropogênicas de CO_2” (SCRIVENER; JOHN; GARTNER, 2018). Esses dados indicam a necessidade de se desenvolver e empregar materiais capazes de substituir parcialmente os insumos convencionais, em especial o cimento Portland, ligante artificial produzido por meio da calcinação de matérias-primas como calcário, argila e, em menores proporções, minério de ferro.

Nesse cenário, relatórios técnicos recentes apontam que “em 2022, as emissões globais médias da produção de cimento situaram-se em aproximadamente 560 kg de CO_2 por tonelada de cimento produzido” (IEA, 2023), conforme dados da International Energy Agency. Essas evidências reforçam a importância da adoção de estratégias de mitigação, entre elas a incorporação de adições minerais e a redução do teor de clínquer, medidas associadas à diminuição da intensidade de carbono do setor.

Para que tais estratégias sejam tecnicamente viáveis, o concreto compósito não pode apresentar redução de sua resistência mecânica, propriedade diretamente relacionada à capacidade de resistir às tensões de compressão. Nesse contexto, a incorporação de metacaulim como material pozolânico pode contribuir para a manutenção ou até para o aprimoramento do desempenho mecânico, ao favorecer a formação de uma matriz cimentícia mais densa e coesa. A reação pozolânica do metacaulim com o hidróxido de cálcio promove a formação adicional de produtos cimentantes, o que resulta em melhor empacotamento das partículas e refinamento da microestrutura, com reflexos na qualidade e no desempenho mecânico do compósito.

Concretos com baixa resistência mecânica apresentam maior suscetibilidade ao surgimento de fissuras, que podem evoluir para trincas e rachaduras. Essas manifestações patológicas comprometem o desempenho estrutural, afetando a estabilidade, a rigidez e o equilíbrio mecânico das edificações, além de reduzir potencialmente sua vida útil.

No campo da modelagem computacional, destacam-se as redes neurais ARTMAP, arquiteturas baseadas na Teoria da Ressonância Adaptativa (*Adaptive Resonance Theory*). Entre as principais variações encontram-se as redes ARTMAP Fuzzy, ARTMAP Euclidiana e ARTMAP Manhattan. Suas arquiteturas estruturais permanecem, em grande medida, semelhantes entre as versões.

Extensões métricas da ARTMAP permitem redefinir a função de similaridade por meio de normas L_p, incluindo as distâncias Euclidiana (L_2) e Manhattan (L_1), preservando a estrutura original da arquitetura e o mecanismo de ressonância adaptativa (CARPENTER; GROSSBERG, 1991; GROSSBERG, 2013; BRITO DA SILVA; ELNABARAWY; WUNSCH, 2019). Essas variações modificam a geometria das regiões de decisão no espaço de atributos, sem alterar a estrutura arquitetural e o mecanismo de funcionamento da rede.

O presente trabalho tem por objetivo avaliar a influência da métrica de similaridade no desempenho preditivo de redes ARTMAP aplicadas à previsão da resistência à compressão de concretos de ultra alto desempenho (CUAD) com substituição parcial do cimento por metacaulim. Para isso, dois cenários de modelagem são investigados: no primeiro, o teor de metacaulim é substituído pela variável slump como preditor; no segundo, o teor de metacaulim é incluído diretamente como variável de entrada, em detrimento do slump. Essa estrutura permite analisar em que medida a

disponibilidade de cada uma dessas variáveis altera o comportamento preditivo das diferentes arquiteturas.

2. REDES NEURAIS ARTMAP APLICADAS À ANÁLISE DA RESISTÊNCIA DO CONCRETO

As redes neurais da família ARTMAP são fundamentadas na Teoria da Ressonância Adaptativa (*Adaptive Resonance Theory* - ART), proposta por Stephen Grossberg (1976, 2013) e formalizada computacionalmente por Gail Carpenter e Grossberg (1987). Essa teoria foi desenvolvida para solucionar o chamado dilema estabilidade/plasticidade, permitindo que sistemas neurais artificiais aprendam continuamente novos padrões sem comprometer o conhecimento previamente adquirido.

A versão supervisionada da arquitetura, denominada ARTMAP, foi introduzida por Carpenter, Grossberg e Reynolds (1991), possibilitando o mapeamento entre categorias formadas no espaço de entrada e classes de saída. Posteriormente, foi proposta a arquitetura ARTMAP Fuzzy, que incorpora operadores da lógica fuzzy ao mecanismo ART original (CARPENTER; GROSSBERG, 1992).

2.1 Estrutura Geral da ARTMAP

A arquitetura ARTMAP é composta por dois módulos ART (ARTa e ARTb) interligados por um campo de mapeamento inter-art. O módulo ARTa processa os vetores de entrada, enquanto o ARTb representa as categorias de saída (classes). O sistema é estruturado a partir do campo de comparação (F1) e do campo de reconhecimento categórico (F2), além do parâmetro de vigilância (ρ), que controla a granularidade das categorias, e do mecanismo de *match tracking*, responsável pelo refinamento adaptativo durante o processo de aprendizagem. O aprendizado ocorre de forma incremental e supervisionada, característica que torna essa arquitetura especialmente adequada para bases de dados experimentais, como aquelas relacionadas à resistência à compressão do concreto, nas quais novas amostras podem ser continuamente incorporadas ao modelo.

2.2 ARTMAP Fuzzy

A rede ARTMAP Fuzzy utiliza operadores da teoria dos conjuntos fuzzy (CARPENTER et al., 1992). A similaridade entre o vetor de entrada I e o protótipo W_j é definida pela interseção fuzzy e pode ser expressa pela equação (1).

$$| I \wedge W_j | = \sum_i \min (I_i, W_{ji}) \tag{1}$$

As categorias formadas possuem geometria de hiper-retângulos no espaço de atributos. Esse tipo de representação geométrica é adequado para variáveis tecnológicas associadas ao concreto, como relação água/cimento, teor de agregado e idade de cura, que geralmente são normalizadas antes do treinamento da rede.

2.3 ARTMAP com Métrica Euclidiana

Na variante Euclidiana, a similaridade é definida pela distância L_2, dada pela equação (2):

$$d_j = \| I - W_j \|_2 \tag{2}$$

Nesse caso, as categorias assumem formato de hiper-esferas, proporcionando fronteiras de decisão isotrópicas no espaço de atributos. Essa configuração pode apresentar melhor desempenho em situações nas quais as variáveis apresentam distribuição aproximadamente contínua e homogênea.

2.4 ARTMAP com Métrica Manhattan

A adoção da métrica L_1 pode ser interpretada como uma extensão métrica das arquiteturas baseadas na Teoria da Ressonância Adaptativa, nas quais diferentes funções de distância podem ser utilizadas na avaliação da similaridade entre padrões. A versão baseada na norma L_1 é definida pela equação (3):

$$d_j = \sum_i | I_i - W_{ji} | \tag{3}$$

Nessa configuração, as categorias apresentam geometria de hiper-losangos. A métrica Manhattan tende a ser menos sensível a variações extremas em uma única dimensão, podendo apresentar maior tolerância a ruídos experimentais. Assim como na versão Euclidiana, a arquitetura da rede permanece inalterada. A modificação ocorre na função de similaridade utilizada na comparação entre vetores, o que influencia o cálculo da função de escolha e o processo de seleção da categoria vencedora.

3. BASE DE DADOS E PROCEDIMENTO DE MODELAGEM

A base de dados utilizada é composta por 180 amostras de concretos CUAD com substituição parcial do cimento por metacaulim, coletadas de estudos experimentais disponíveis na literatura. Esses concretos caracterizam-se por microestrutura densificada, baixa relação água/cimento e incorporação de adições minerais pozolânicas, o que resulta em elevados níveis de resistência à compressão, compatíveis com a faixa observada entre 100 e 260 MPa. A variável de saída corresponde à resistência à compressão (MPa).

Dois cenários de modelagem foram estruturados a partir desse conjunto, diferenciados pela composição das variáveis de entrada, de modo a simular condições distintas de disponibilidade de informações em contextos práticos de projeto. No Cenário 1, foram adotadas as variáveis relação água/cimento (a/c), consumo de cimento (kg/m³), idade de cura (dias) e abatimento (slump, em mm), sem a inclusão do teor de metacaulim, representando situações em que essa informação não está diretamente disponível ao modelo. No Cenário 2, o slump foi removido e o teor de metacaulim (MK, em %) foi incorporado como preditor, compondo o conjunto: MK (%), a/c, cimento (kg/m³) e idade de cura (dias). Essa estrutura permite investigar em que medida a disponibilidade do teor de metacaulim como variável preditora altera o desempenho de cada arquitetura, e se a métrica de similaridade adotada interage com essa escolha.

Vale destacar que as redes ARTMAP são especialmente adequadas para bases de dados de tamanho moderado. Ao contrário de arquiteturas profundas que exigem grandes volumes de dados para generalização satisfatória, o mecanismo de aprendizagem incremental e supervisionada da ARTMAP permite que o modelo forme categorias estáveis mesmo com conjuntos reduzidos de amostras, sem comprometer o conhecimento previamente adquirido (CARPENTER; GROSSBERG, 1992; GROSSBERG, 2013).

Antes do treinamento, todas as variáveis foram normalizadas pelo método min-max, tanto as entradas quanto a saída, garantindo que os valores ficassem no intervalo [0, 1]. O particionamento dos dados seguiu a abordagem de *hold-out* estratificado pela idade de cura, com 80% das amostras destinadas ao treinamento e 20% ao teste, utilizando semente aleatória fixa (*random_state* = 42) para garantir reprodutibilidade dos resultados.

A seleção dos hiperparâmetros foi realizada exclusivamente sobre o conjunto de treinamento, por meio de otimização bayesiana com 100 tentativas por modelo. O desempenho de cada configuração foi avaliado internamente por validação cruzada K-*fold* com cinco partições (K = 5), tendo como métrica de otimização o RMSE negativo. O conjunto de teste permaneceu isolado durante todo esse processo, sendo utilizado apenas para a avaliação final dos modelos já ajustados. Os indicadores finais de desempenho foram calculados sobre esse conjunto. As métricas adotadas para comparação entre os modelos foram o erro quadrático médio (RMSE), o erro absoluto médio (MAE), o erro quadrático médio (MSE), o coeficiente de determinação (R^2) e o erro percentual absoluto médio (MAPE). Todas as etapas de pré-processamento, treinamento e avaliação foram implementadas em linguagem Python, com o suporte das bibliotecas Scikit-learn, para os procedimentos de normalização, particionamento e validação cruzada, e Optuna, para a otimização bayesiana dos hiperparâmetros.

4. RESULTADOS E DISCUSSÃO

4.1 Cenário 1 - Previsão sem a variável teor de metacaulim

O Cenário 1 foi estruturado com as variáveis a/c, cimento (kg/m³), idade de cura (dias) e slump (mm) como preditores, excluindo o teor de metacaulim do conjunto de entrada. Essa configuração representa uma situação prática em que o teor de substituição não está disponível como informação direta ao modelo, mas o comportamento de trabalhabilidade da mistura, expresso pelo slump, está presente.

A Tabela 1 apresenta os hiperparâmetros ótimos obtidos para cada arquitetura ARTMAP nesse cenário, após otimização bayesiana com validação cruzada K-*fold* de cinco partições.

Tabela 1 - Hiperparâmetros ótimos dos modelos ARTMAP (Cenário 1)

Modelo	Parâmetro	Símbolo	Valor
ARTMAP Fuzzy	Taxa de aprendizagem	β	0,9993
	Vigilância - entrada	ρ_a	0,5163
	Vigilância - saída	ρ_b	0,9919
	Parâmetro de escolha	α	0,7103
ARTMAP Euclidiana	Taxa de aprendizagem	β	0,8773
	Vigilância - entrada	ρ_a	0,2276
	Vigilância - saída	ρ_b	0,0230
ARTMAP Manhattan	Taxa de aprendizagem	β	0,2704
	Vigilância - entrada	ρ_a	0,5227
	Vigilância - saída	ρ_b	0,0116

Fonte: os autores.

No modelo ARTMAP Fuzzy, o valor elevado de β ($\approx 0{,}999$) indica aprendizado rápido, com atualização quase imediata dos protótipos a cada padrão apresentado. Os valores de ρ_a e ρ_b, situados em patamares intermediário e alto, respectivamente, resultam em categorização com grau

moderado de seletividade na entrada e alta exigência de correspondência na saída. O parâmetro α contribui para a estabilidade do processo de escolha competitiva entre categorias.

Para a rede ARTMAP Euclidiana, os baixos valores de ρ_a e ρ_b indicam maior rigor no critério de correspondência entre os padrões de entrada e as categorias existentes. Em métricas baseadas em distância, valores menores de vigilância exigem maior proximidade entre vetor de entrada e protótipo para que ocorra ressonância, o que tende a favorecer a criação de um número maior de categorias e maior detalhamento na representação dos padrões. A rede ARTMAP Manhattan apresentou configuração intermediária, com ρ_a elevado e ρ_b bastante reduzido, indicando maior tolerância no módulo de entrada e critério mais restritivo no módulo de saída.

Quando se utilizam as métricas Euclidiana ou Manhattan, a interpretação dos valores de ρ difere daquela adotada na versão Fuzzy, pois nessas métricas a análise é baseada na distância entre os dados, e não no grau de similaridade entre eles. De maneira geral, as diferenças nos hiperparâmetros refletem a influência da métrica adotada na dinâmica de categorização da rede.

A Tabela 2 apresenta os indicadores de desempenho obtidos no conjunto de teste para cada arquitetura.

Tabela 2 - Desempenho dos modelos ARTMAP (Cenário 1)

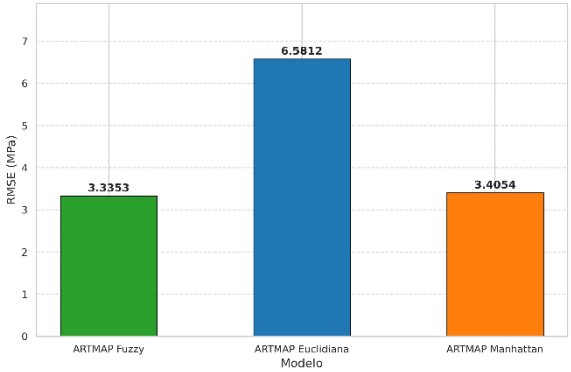
Modelo	RMSE	MAE	MSE	R^2	MAPE (%)
ARTMAP Fuzzy	3,3354	2,7834	11,1250	0,9949	1,6981
ARTMAP Euclidiana	6,5812	4,4236	43,3123	0,9801	2,4524
ARTMAP Manhattan	3,4053	2,9804	11,5964	0,9947	1,8339

Fonte: os autores.

O modelo ARTMAP Fuzzy apresentou o menor RMSE (3,3354), o maior coeficiente de determinação (R^2 = 0,9949) e o menor MAPE (1,6981%), indicando maior proximidade entre os valores previstos e os valores experimentais, bem como menor dispersão dos erros de previsão. O modelo ARTMAP Manhattan apresentou desempenho semelhante, com ligeiro aumento nos erros (RMSE = 3,4053; MAPE = 1,8339%) e redução discreta do coeficiente de determinação (R^2 = 0,9947), mantendo elevada capacidade explicativa. O modelo ARTMAP Euclidiana registrou os maiores valores de erro (RMSE = 6,5812; MAPE = 2,4524%) e o menor coeficiente de determinação (R^2 = 0,9801), indicando maior variabilidade nas previsões geradas.

A Figura 1 apresenta a comparação dos valores de RMSE entre os três modelos.

Figura 1 - Comparação do RMSE entre os modelos ARTMAP (Cenário 1)

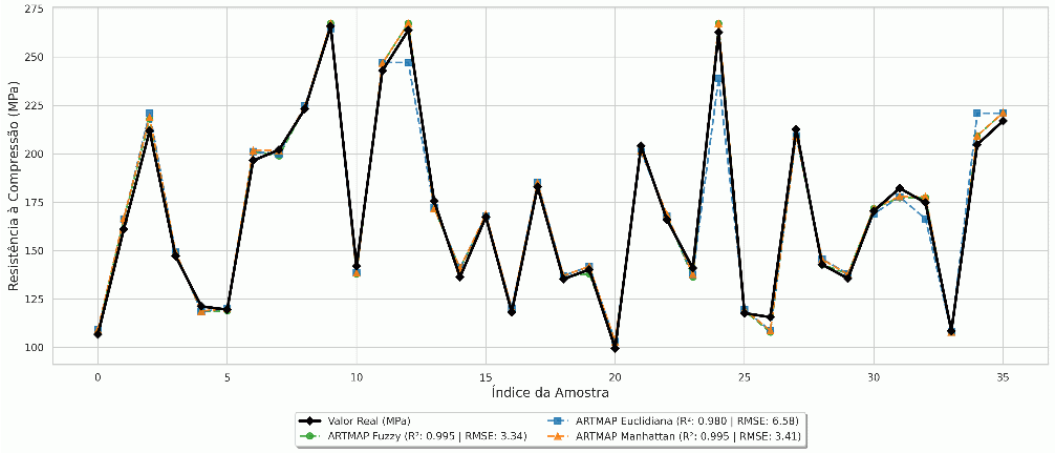


Fonte: os autores.

Os resultados indicam que, no Cenário 1, a métrica Fuzzy, baseada em interseção de conjuntos e geometria de hiper-retângulos, mostrou-se mais adequada para representar a variabilidade dos dados quando o slump está presente e o teor de metacaulim está ausente como preditor. Esse comportamento sugere que, nessa configuração de variáveis, as fronteiras de decisão retangulares da versão Fuzzy capturam melhor a estrutura do espaço de atributos do que as fronteiras isotrópicas da métrica Euclidiana ou os hiper-losangos da métrica Manhattan.

A Figura 2 apresenta a comparação entre os valores experimentais e os valores previstos pelos três modelos ao longo das amostras do conjunto de teste.

Figura 2 - Comparativo entre valores reais e previstos pelos modelos ARTMAP (Cenário 1)



Fonte: os autores.

De modo geral, verifica-se elevada proximidade entre os valores previstos e os experimentais ao longo das amostras, com as maiores discrepâncias concentradas em pontos de transição mais abrupta da resistência. Esse comportamento é esperado em modelos baseados em categorização por similaridade, nos quais regiões de alta variabilidade local tendem a ser mais difíceis de representar com precisão. Ainda assim, todos os modelos apresentaram coeficientes de determinação superiores a 0,98, indicando forte correlação entre dados experimentais e estimados.

4.2 Cenário 2 - Previsão com a variável teor de metacaulim

O Cenário 2 foi estruturado com as variáveis MK (%), a/c, cimento (kg/m³) e idade de cura (dias) como preditores, incorporando o teor de metacaulim ao conjunto de entrada e excluindo o slump. Essa configuração representa uma situação em que a informação sobre o grau de substituição do cimento está disponível ao modelo, permitindo verificar se sua inclusão altera o desempenho preditivo das arquiteturas e, em particular, se modifica o comportamento relativo entre as métricas de similaridade.

A Tabela 3 apresenta os hiperparâmetros ótimos obtidos para cada arquitetura ARTMAP nesse cenário, após otimização bayesiana com validação cruzada K-*fold* de cinco partições.

Tabela 3 - Hiperparâmetros ótimos dos modelos ARTMAP (Cenário 2)

Modelo	Parâmetro	Símbolo	Valor
ARTMAP Fuzzy	Taxa de aprendizagem	β	0,9284
	Vigilância - entrada	ρ_a	0,8456
	Vigilância - saída	ρ_b	0,9945
	Parâmetro de escolha	α	0,6511
ARTMAP Euclidiana	Taxa de aprendizagem	β	0,7852
	Vigilância - entrada	ρ_a	0,8103
	Vigilância - saída	ρ_b	0,0106
ARTMAP Manhattan	Taxa de aprendizagem	β	0,9047
	Vigilância - entrada	ρ_a	0,4656
	Vigilância - saída	ρ_b	0,0001

Fonte: os autores.

A comparação entre as Tabelas 1 e 3 revela mudanças expressivas nos hiperparâmetros ótimos de cada modelo. No Cenário 2, o valor de ρ_a da ARTMAP Fuzzy aumentou de 0,5163 para 0,8456, indicando que a rede passou a exigir maior similaridade entre o vetor de entrada e os protótipos existentes antes de aceitar ressonância. Esse ajuste sugere que a inclusão do teor de metacaulim como preditor reorganiza o espaço de atributos de forma que categorias mais restritas passam a ser necessárias para discriminar adequadamente os padrões.

Para a ARTMAP Euclidiana, o valor de ρ_a aumentou substancialmente, de 0,2276 para 0,8103, mantendo ρ_b em patamar igualmente baixo. Esse comportamento indica que, no Cenário 2, a rede Euclidiana opera com critério de vigilância mais exigente na entrada, formando categorias menores e mais específicas. A ARTMAP Manhattan, por sua vez, apresentou redução expressiva de ρ_b, atingindo valor próximo de zero (0,0001), o que indica um critério mais restritivo no módulo de saída, exigindo maior proximidade entre os padrões e favorecendo a formação de categorias mais específicas.

A Tabela 4 apresenta os indicadores de desempenho obtidos no conjunto de teste para cada arquitetura no Cenário 2.

Tabela 4 - Desempenho dos modelos ARTMAP (Cenário 2)

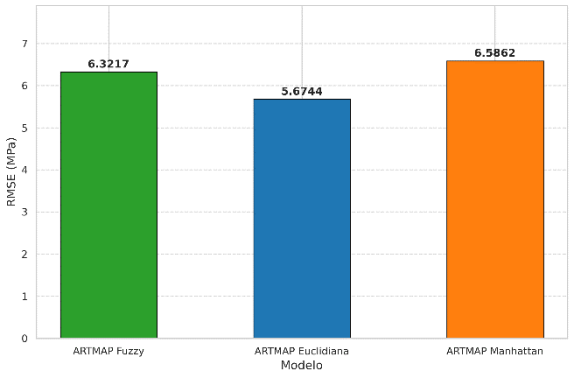
Modelo	RMSE	MAE	MSE	R^2	MAPE (%)
ARTMAP Fuzzy	6,3217	4,2563	39,9643	0,9816	2,5582
ARTMAP Euclidiana	5,6745	3,7420	32,1996	0,9852	2,2061
ARTMAP Manhattan	6,5862	4,6194	43,3775	0,9801	2,8185

Fonte: os autores.

No Cenário 2, o comportamento relativo entre os modelos se diferencia do observado no Cenário 1. A ARTMAP Euclidiana passou a apresentar o melhor desempenho preditivo, com RMSE = 5,6745, R^2 = 0,9852 e MAPE = 2,2061%. A ARTMAP Fuzzy manteve desempenho satisfatório (RMSE = 6,3217; R^2 = 0,9816), e a ARTMAP Manhattan registrou os maiores erros (RMSE = 6,5862; R^2 = 0,9801). Todos os modelos mantiveram coeficientes de determinação superiores a 0,98, evidenciando forte correlação entre valores experimentais e estimados mesmo com a alteração do conjunto de preditores.

A Figura 3 apresenta a comparação dos valores de RMSE entre os três modelos no Cenário 2.

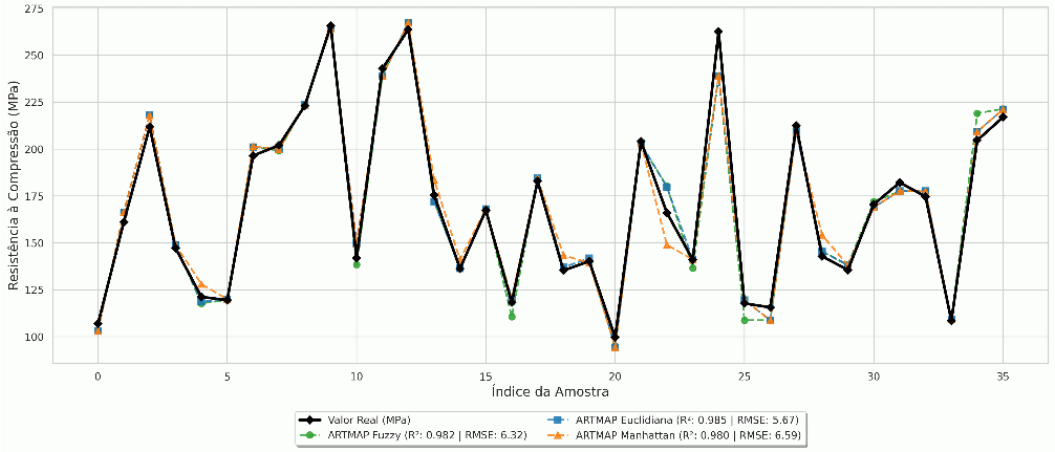
Figura 3 - Comparação do RMSE entre os modelos ARTMAP (Cenário 2)



Fonte: os autores.

A Figura 4 apresenta a comparação entre os valores experimentais e os valores previstos pelos três modelos ao longo das amostras do conjunto de teste.

Figura 4 - Comparativo entre valores reais e previstos pelos modelos ARTMAP (Cenário 2)

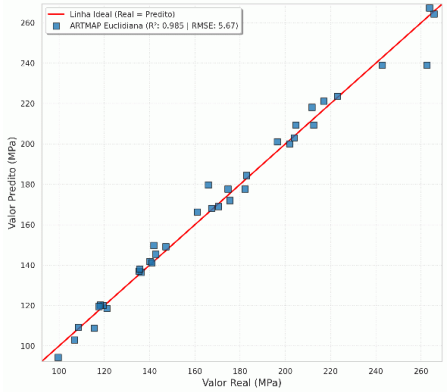


Fonte: os autores.

As maiores discrepâncias concentram-se em pontos de transição mais abrupta da resistência, comportamento esperado em modelos baseados em categorização por similaridade ou distância.

A Figura 5 apresenta o gráfico de dispersão entre valores reais e preditos pelo modelo ARTMAP Euclidiana, que registrou o melhor desempenho nesse cenário.

Figura 5 - Dispersão entre valores reais e preditos pelo modelo ARTMAP Euclidiana (Cenário 2)



Fonte: os autores.

O coeficiente de determinação obtido (R^2 = 0,985) demonstra que aproximadamente 98,5% da variabilidade da resistência à compressão é explicada pelo modelo. O erro quadrático médio (RMSE = 5,67 MPa) pode ser considerado relativamente baixo em relação à faixa de valores analisados, o que reforça a precisão das estimativas geradas pela arquitetura nesse cenário.

4.3 Análise Comparativa entre Cenários

A comparação entre os dois cenários investigados permite discutir a influência conjunta da métrica de similaridade e da composição do conjunto de variáveis preditoras no desempenho das redes ARTMAP. Os resultados obtidos indicam que essas duas dimensões interagem de forma não trivial: a métrica que apresenta melhor desempenho em um cenário não necessariamente mantém essa posição quando o conjunto de entrada é alterado.

No Cenário 1, sem o teor de metacaulim e com o slump como preditor, a ARTMAP Fuzzy registrou os melhores indicadores, com RMSE = 3,3354 e R^2 = 0,9949. No Cenário 2, com a inclusão do teor de metacaulim e exclusão do slump, a ARTMAP Euclidiana passou a apresentar desempenho superior, com RMSE = 5,6745 e R^2 = 0,9852. Essa inversão não representa inconsistência metodológica. Reflete, antes, a sensibilidade de cada métrica à geometria do espaço de atributos formado pelas variáveis disponíveis.

A métrica Fuzzy opera por interseção de conjuntos, formando categorias com geometria de hiper-retângulos. Essa representação tende a ser mais adequada quando as variáveis de entrada apresentam relações de faixa bem delimitadas, como ocorre com o slump, cujos valores se distribuem em intervalos característicos de cada traço. A métrica Euclidiana, por sua vez, forma categorias esféricas e isotrópicas no espaço de atributos. A inclusão do teor de metacaulim, variável contínua que interage de forma aproximadamente proporcional com a resistência, parece favorecer esse tipo de representação geométrica, o que explicaria a inversão de desempenho observada.

Do ponto de vista prático, os resultados sugerem que a disponibilidade do teor de metacaulim como variável preditora não implica necessariamente ganho de desempenho para todas as arquiteturas. A ARTMAP Fuzzy, por exemplo, apresentou aumento nos erros quando o MK% foi incluído e o slump foi removido, ao passo que a ARTMAP Euclidiana se beneficiou dessa troca. Esse comportamento reforça a importância de avaliar a métrica de similaridade em conjunto com a seleção de variáveis, e não de forma isolada.

A Tabela 5 sintetiza os melhores resultados obtidos em cada cenário, permitindo visualizar diretamente a influência da composição do conjunto de preditores sobre o desempenho de cada arquitetura.

Tabela 5 - Comparativo de desempenho entre cenários

Cenário	Melhor modelo	RMSE	MAE	R^2	MAPE (%)
Cenário 1 (sem MK%, com Slump)	ARTMAP Fuzzy	3,3354	2,7834	0,9949	1,6981
Cenário 2 (com MK%, sem Slump)	ARTMAP Euclidiana	5,6745	3,7420	0,9852	2,2061

Fonte: os autores.

De forma geral, os indicadores demonstram que a métrica adotada para definição das categorias e para o cálculo da similaridade entre os padrões de entrada influencia diretamente o desempenho preditivo, e que essa influência varia conforme a composição do conjunto de variáveis. A escolha

da métrica de similaridade, portanto, não deve ser tratada como decisão independente da seleção de preditores, sendo recomendável que ambas sejam avaliadas conjuntamente no processo de modelagem.

5. CONCLUSÃO

Os resultados obtidos demonstraram que as redes neurais da família ARTMAP apresentam elevado desempenho na previsão da resistência à compressão de concretos de ultra alto desempenho com substituição parcial do cimento por metacaulim. Todas as arquiteturas analisadas apresentaram coeficientes de determinação superiores a 0,98 em ambos os cenários de modelagem, evidenciando forte correlação entre valores experimentais e estimados.

Um aspecto que merece destaque é a capacidade dessas redes de produzir resultados consistentes com bases de dados de tamanho moderado. Com apenas 180 amostras, todos os modelos convergiram para soluções estáveis, o que decorre do mecanismo de aprendizagem incremental da ARTMAP, que não exige grandes volumes de dados para formar categorias generalizáveis. Essa característica torna a arquitetura particularmente pertinente para aplicações em engenharia, campo em que bases de dados experimentais tendem a ser limitadas.

No Cenário 1, sem o teor de metacaulim como preditor e com o slump disponível, a ARTMAP Fuzzy apresentou as melhores métricas de desempenho, com RMSE = 3,3354 e R^2 = 0,9949. No Cenário 2, com a inclusão do teor de metacaulim e exclusão do slump, a ARTMAP Euclidiana registrou o melhor desempenho, com RMSE = 5,6745 e R^2 = 0,9852. A inversão no desempenho relativo entre os cenários indica que a métrica de similaridade interage com a composição do conjunto de variáveis preditoras, de forma que a escolha da arquitetura mais adequada depende das informações disponíveis para o modelo.

Os resultados reforçam que a seleção da métrica de similaridade não deve ser tratada de forma isolada no processo de modelagem. A composição do espaço de atributos, determinada pelas variáveis de entrada disponíveis, influencia a geometria das categorias formadas por cada arquitetura e, por consequência, o desempenho preditivo do modelo. Essa constatação é relevante para aplicações práticas, em que a disponibilidade de dados pode variar conforme o contexto de projeto ou de execução.

Conclui-se que a aplicação das redes ARTMAP constitui uma abordagem eficaz para a modelagem da resistência mecânica de concretos com substituição parcial de cimento por metacaulim, contribuindo para o desenvolvimento de estratégias técnicas alinhadas à redução do consumo de cimento e à mitigação de impactos ambientais na Construção Civil.

REFERÊNCIAS

BRITO DA SILVA, L.; ELNABARAWY, I.; WUNSCH, D. C. A survey of adaptive resonance theory neural network models for engineering applications. *Neural Networks*, v. 120, p. 167-203, 2019.

CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics, and Image Processing*, v. 37, n. 1, p. 54-115, 1987.

CARPENTER, G. A.; GROSSBERG, S. *Pattern recognition by self-organizing neural networks*. MIT Press, 1991.

CARPENTER, G. A.; GROSSBERG, S. Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, v. 3, n. 5, p. 698-713, 1992.

CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Networks*, v. 4, n. 5, p. 565-588, 1991.

GROSSBERG, S. Adaptive pattern classification and universal recoding. *Biological Cybernetics*, v. 23, p. 121-134, 1976.

GROSSBERG, S. Adaptive resonance theory: How a brain learns to consciously attend, learn, and recognize a changing world. *Neural Networks*, v. 37, p. 1-47, 2013.

IEA – INTERNATIONAL ENERGY AGENCY. *Cement – Analysis and Forecasts to 2030*. Paris: IEA, 2023.

SCRIVENER, K. L.; JOHN, V. M.; GARTNER, E. M. Eco-efficient cements: Potential economically viable solutions for a low-CO_2 cement-based materials industry. *Cement and Concrete Research,* v. 114, p. 2-26, 2018.