



Uso da Inteligência Artificial para Predição da Retração por Secagem do Concreto

The Use of Artificial Intelligence for Predicting Concrete Drying Shrinkage

Diogo Faria de Sousa (1); Francisco José B. T. L. Strunck (2); Amanda Lemette T. Brandão (3); Flávio de Andrade Silva (4)

(1) Mestrando, Departamento de Engenharia Civil e Ambiental, Pontifícia Universidade Católica do Rio de Janeiro (PUC - Rio)

(2) Mestrando, Departamento de Engenharia Química e Materiais, Pontifícia Universidade Católica do Rio de Janeiro (PUC - Rio)

(3) Professora Doutora, Departamento de Engenharia Química e Materiais (PUC - Rio)

(4) Professor Doutor, Departamento de Engenharia Civil e Ambiental (PUC - Rio)

Rua Marques de São Vicente, 225, Rio de Janeiro, RJ, 22451-900 - Brasil.

Resumo

Devido a variações volumétricas do concreto, a compreensão dos mecanismos da retração tornou-se ponto importante para redução de fissuras e, consequentemente, da penetração de agentes agressivos. Apesar do aumento do número de estudos experimentais de retração por secagem e autóloga ainda é necessário o desenvolvimento de novos modelos analíticos e numéricos para predição da retração apoiando assim o projeto de estruturas de concreto. Este estudo propôs um modelo de redes neurais artificiais para predição da retração por secagem do concreto. Um banco de dados contendo 689 leituras de retração por secagem em mais de 90 dosagens diferentes foi construído. O modelo teve como dados de entrada para predição da retração o consumo e tipo de cimento, aditivo retardador e plastificante retardador, compensador de retração, relação água/cimento e idade do concreto. O resultado apresentou um modelo de alto desempenho com determinação de coeficientes (R^2) para dados de treino e teste acima de 0,998 e 0,906, respectivamente, comprovando que o modelo é um importante aliado para predição da retração por secagem para tomadas de decisão durante os estudos iniciais na fase de projeto e dosagem do concreto.

Palavra-Chave: C Retração do concreto, fissuração, predição, inteligência artificial, redes neurais.

Abstract

Due to volumetric variations of concrete, understanding the mechanisms of shrinkage has become an important point for reducing cracks and, consequently, the penetration of deleterious agents into concrete structures. Despite the increase in experimental studies on concrete drying and autogenous shrinkage there is still a need to develop new analytical and numerical methods to predict shrinkage supporting the design of concrete structures. This study proposed an Artificial Neural Network (ANN) model to predict the concrete drying shrinkage. A database containing 689 experimental shrinkage data readings, in more than 90 different mixtures was constructed. The model had as input data for predicting shrinkage the consumption and type of cement, retarding and plasticizer additive, shrinkage compensator, water/cement ratio and age of the concrete. The result presented a high-performance model with determination of coefficients (R^2) for training and test data above 0,998 e 0,906, proving that the model is an important ally for predicting drying shrinkage for decision making during the initial study in the design phase and concrete dosage.

Keywords: C Shrinkage, cracks, prediction, machine learning, artificial neural network.

1 Introdução

O concreto é o material mais utilizado em todo o mundo, justificando a importância de estudar várias características deste material. Especificamente, estudar a durabilidade do concreto, que é afetado pela retração, é de particular interesse por causa do seu efeito significativo na vida útil da estrutura. A retração do concreto promove o surgimento de fissuras que podem levar ao ingresso de agentes deletérios. Conseqüentemente, a retração do concreto tem sido motivo de grande preocupação em projetos de estruturas duráveis (Nehdi and Soliman, 2012; Abbasnia, Shekarchi and Ahmadi, 2013).

A pasta de cimento, a argamassa ou o concreto são materiais que se deformam pela variação de umidade e temperatura independente da aplicação de forças externas. Dentre as deformações causadas por forças internas está a deformação por retração. Tal fenômeno ocorre devido à perda de volume da mistura sem que haja nenhuma força externa, e pode ocorrer por diferentes causas. A retração ocorre com o tempo principalmente devido ao movimento da troca de umidade do concreto com meio externo, ou por consumo de água interna pela hidratação do cimento. As retrações mais comuns relacionadas ao concreto são a retração plástica, por secagem, autógena e química (Motta, 2018).

A prevenção da retração do concreto resulta no desenvolvimento em menores valores de tensões de tração. Se estas tensões de tração excedem a resistência a tração do concreto, é visível o surgimento de fissuras. Vários fatores podem influenciar o potencial de fissuração, como a magnitude de retração, grau de restrição, fluência, condições de ambiente externo, propriedades dos materiais, geometria da estrutura e resistência a tração do concreto (Mazzoli, Monosi and Plescia, 2015).

A retração tem como resultado a fissuração da estrutura, assim gerando uma ameaça à integridade estrutural do concreto e se não inibida, levará à deterioração prematura, redução da vida útil da estrutura e o aumento dos custos de manutenção (BAKSHI, 2011). Embora os materiais, dosagens de concreto, especificações de projeto e tecnologias da construção avançaram muito ao longo dos anos, a fissuração por retração ainda permanece um problema significativo na construção civil. A escassez de estudos sobre os mecanismos de fissuração por retração, as técnicas de mitigação e equações analíticas que permitem a predição das deformações diferidas no tempo mostram a relevância da presente pesquisa.

2 Objetivo

A proposta deste artigo é apresentar um modelo de predição da retração do concreto por secagem através de inteligência artificial com o uso de redes neurais com a análise de um banco de dados construído com ensaios de retração conforme NBR 16834 (2020), contendo 689 leituras em mais de 90 dosagens diferentes de concreto.

3 Banco de Dados e Tratamento dos Elementos

3.1 Base de Dados

O conjunto de dados de ensaios de retração do concreto por secagem foram obtidos por laboratório, inclui 689 leituras de retração NBR 16834 (2020). Neste banco de dados cada corpo de prova foi adicionado suas características de mistura, como a identificação da localidade dos materiais, relação água/cimento, relação agregados/cimento, teor de ANAIS DO 64º CONGRESSO BRASILEIRO DO CONCRETO - CBC2023 – 64CBC2023

argamassa, relação agregado miúdo artificial/agregado miúdo total, consumo de agregados, consumo de cimento e tipo de cimento, consumo de microfibras e macrofibras sintéticas ou metálicas. Juntamente com as informações anteriores, foram acrescentados os aditivos, como a dosagem dos aditivos tipo redutor de água tipo 1 (RA1), redutor de água tipo 1/retardador (RA1-R), redutor de água tipo 2 (RA2) e compensador de retração (CR), segundo a classificação da NBR 11768-1 (2019), conhecidos comercialmente como polifuncional, mid ranger e superplastificante, respectivamente.

3.2 Análise dos Dados

A análise de dados foi realizada usando bibliotecas Seaborn, Scikit-learn, NumPy, Pandas e aprendizado de máquina na estrutura Keras para Python. Vários algoritmos foram usados para visualização de dados, como HeatMap ou Scatterplot.

A Figura 1 apresenta a frequência das leituras por região, observa-se que a região sul tem o maior número de resultados neste banco de dados elaborado. A Figura 2 ilustra o total de quantitativo por tipo de cimento, onde o CP II F 40 foi o mais utilizado nas dosagens, o oposto do CP V ARI.

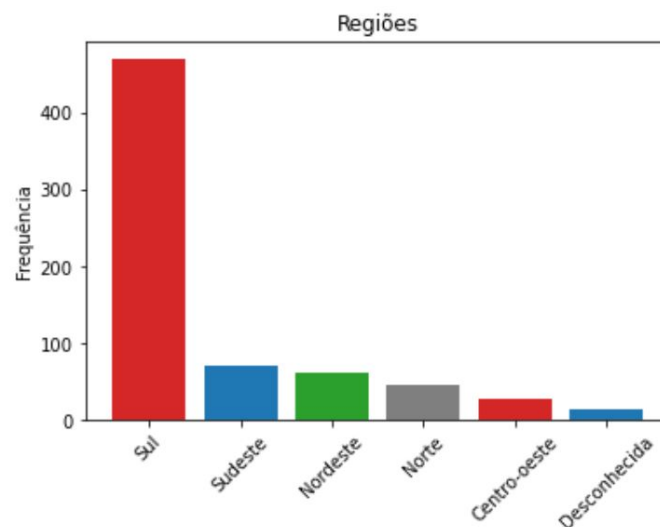


Figura 1 – Números de leitura por região.

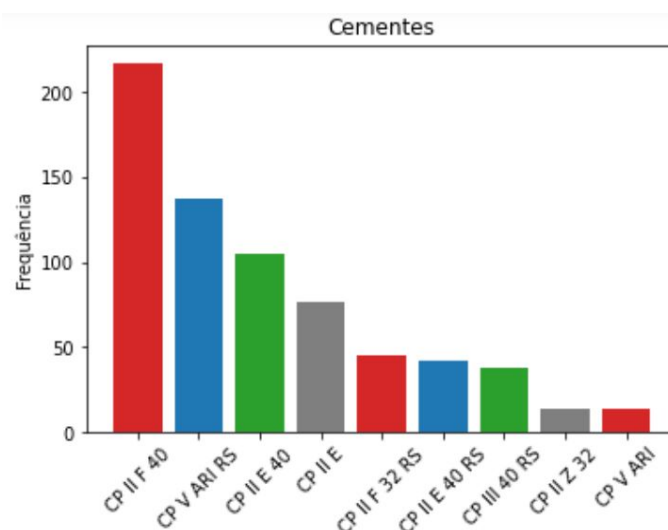
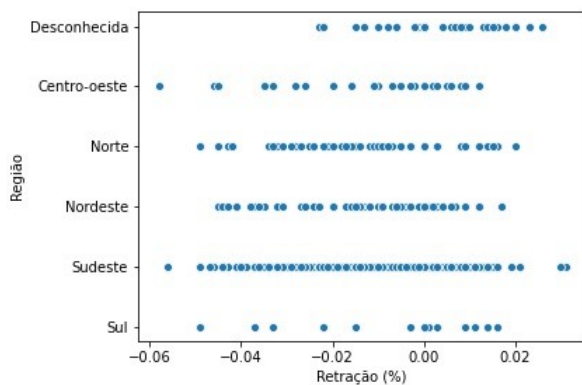



Figura 2 – Números de leitura por tipo de cimento.


Os dados de entrada como a/c , teor de argamassa, relação entre agregado artificial e agregado natural, superplastificante, microfibra, macrofibra de polipropileno e aço foram removidos dos dados de entrada do modelo, uma vez que os resultados de correlação foram baixos. Os resultados apresentados pelo modelo de correlação de Spearman são apresentados somente com relação com a retração, devido à limitação da apresentação da dimensão da matriz completa neste trabalho. Na bibliografia, estudos e pesquisas apresentam correlação direta entre a/c (água/cimento) e c (consumo de cimento) para resultado da retração, neste trabalho permanecem como dados de entrada para o modelo proposto esses inputs, por mais que neste banco de dados os valores de correlação apresentaram valores baixos.




(a)




(b)




(c)




(d)



(e)



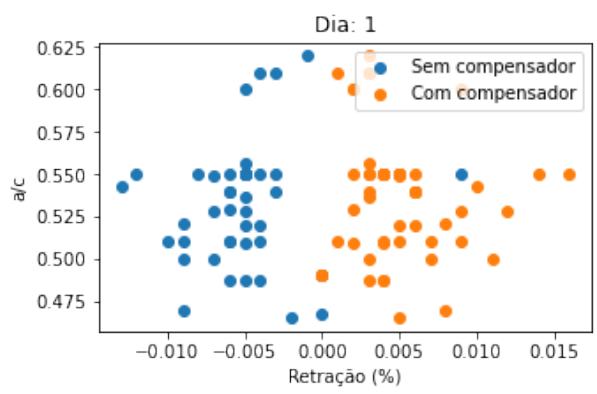
(f)



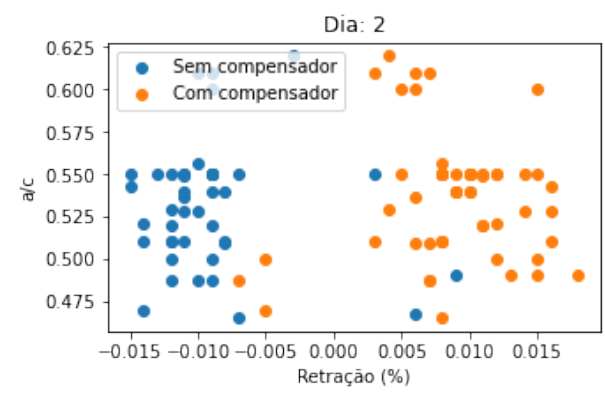
(g)

Figura 3 – Gráfico de dispersão de dados de acordo com os resultados de retração por secagem, sendo: (a) Região, (b) a/c, (c) consumo de cimento, (d) polifuncional, (e) mid range, (f) compensador, (g) tipo de cimento.

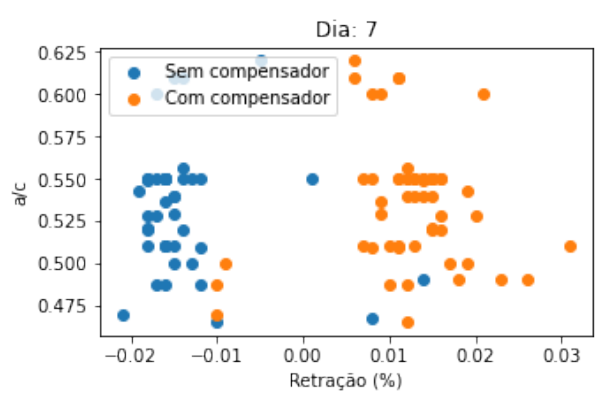
Na Figura 3 são apresentados os gráficos de dispersão de dados em relação aos dados de retração por secagem do concreto do banco de dados obtido após a exclusão dos dados de entrada com baixa correlação. Nota-se que há uma grande dispersão de pontos nos gráficos acarretando em uma não correlação entre a retração, necessitando de tratamento dos dados.




(a)



(b)



(c)



(d)




Figura 4 - Gráfico de dispersão de dados de acordo os resultados de retração por secagem em relação ao fator água/cimento, sendo: (a) Dia 1, (b) Dia 2, (c) Dia 7, (d) Dia 14, (e) Dia 28, (f) Dia 56.

Na Figura 4 é apresentado os concretos que tiveram em sua dosagem a adição do compensador de retração contraposto aos que não tiveram, em diferentes gráficos de acordo com a idade do concreto, conforme leitura da retração da NBR 16834 (2020). Observa-se nos dados que os concretos com compensador de retração estão mais descolados a direita, apresentando menor retração enquanto as dosagens sem CR apresentaram maiores valores de retração, dados descolados mais à esquerda.




Figura 5 - Comportamento comparativo de concreto com e sem agente expansor.

Os dados com o comparativo do comportamento do concreto com e sem CR ao longo do tempo são apresentados na Figura 5. Nota-se que os resultados até o décimo dia de idade do concreto com compensador apresentaram expansão e após o 56° dia com valores de retração, na média, próximo de $-300\mu\text{m/m}$. Este valor é inferior em 40% ao valor médio do concreto sem o aditivo, com valor médio de $-500\mu\text{m/m}$.

4 Resultados e Discussões

De acordo com as seções anteriores, uma metodologia de inteligência artificial foi proposta para prever os parâmetros de retração por secagem do concreto. Por meio de treinamento e definição de modelos de redes neurais, esta abordagem procura avaliar os valores numéricos da característica da mistura do concreto sem a realização de testes experimentais em laboratório para obtenção dos valores de retração do concreto. Esta seção apresenta os principais resultados e discussões sobre o desempenho de redes neurais artificiais, curva de regressão e RNA de validação, considerando pontos não incluídos no processo de treinamento da RNA.

4.1 RNA Treinamento e Performance

Métricas de desempenho adicionais são apresentadas na Tabela 1 para avaliar o desempenho do modelo de vários ângulos. Em geral, as métricas de desempenho indicam alta performance do modelo. Os valores de R^2 ultrapassam 0,99 para todo conjunto de dados, o que evidencia a alta proporção de variância na variável dependente (Y) que é explicada pelas variáveis independentes (X_s). Como o coeficiente dos valores de determinação não diferem do coeficiente ajustado de determinação (R^2_{adj}), o número de variáveis de entrada não diverge os resultados. Enquanto a média do erro absoluto (MAE, em inglês – Mean Absolute Error) é menos sensível a valores atípicos, a média de erro quadrático (MSE) penaliza grandes erros. Até embora não haja um valor padronizado para MAE e MSE (em inglês – Mean Squared Error), as pontuações são pequenas e comparáveis para todos os subconjuntos de dados. A raiz média de valores de erro ao quadrado (RMSE, em inglês – Root Mean Squared Error) são relatados na tabela com valor de 0,0461.

Tabela 1 – Dados de avaliação de desempenho do treinamento.

	Treino
MSE	0,0021
MAE	0,0248
RMSE	0,0461
R^2	0,998
R^2_{adj}	0,998

Os valores apresentados na tabela anterior referem-se a arquitetura onde há 5 camadas, sendo que a camada de entrada utilizou os inputs: a/c (água/cimento), c (consumo de cimento/ m^3), multifuncional (consumo de aditivo tipo RA1), mid ranger (consumo de aditivo tipo RA1-R), compensador (consumo de aditivo tipo CR), idade do concreto (dias) e tipo de cimento. Adotou-se nas camadas de processamento dos dados três camadas ocultas, do seguinte modo: a primeira teve 2.000, a segunda 500 e a terceira 2.000 neurônios com a utilização da fundação de ativação '*relu*'. Para obtenção do resultado teve uma camada com um neurônio de output para predição da retração por secagem do concreto.




Figura 6 - Gráfico de comparação entre previsto e observado da dispersão do modelo de treino.

A Figura 6 mostra a curva de regressão para os valores previstos e observados para o conjunto de dados de treinamento. O alto grau de concordância entre os valores experimentais e as saídas do modelo sugerem que o modelo aprendeu o padrão dos dados mesmo em regiões não lineares.

4.2 RNA Validação

Dados de desempenho para avaliar a validação da rede são apresentados na Tabela 2. Observa-se os valores de R^2 estão acima de 0,90 para a base de dados analisada, apresentando o aprendizado do modelo com alta relação com os dados de input versus retração do concreto. O valor de coeficiente R^2_{adj} não difere do R^2 , validando o número de variáveis de entrada de forma que não descaracteriza os resultados. Os valores de MSE e MAE permanecem ainda pequenos e comparáveis para todos os subconjuntos de dados. O valor de 0,30 de RMSE é apresentado na tabela.

Tabela 2 – Dados de avaliação de desempenho da validação.

	Validação
MSE	0,0902
MAE	0,211
RMSE	0,30
R^2	0,906
R^2_{adj}	0,890

A apresentação do gráfico da curva de regressão entre os valores previstos e observados para o conjunto de dados de validação são ilustrados na Figura 7. Os resultados apresentam alta relação entre os valores experimentais e os outputs do modelo, indicando que o modelo obteve aprendizado mesmo no padrão de dados em regiões não lineares.




Figura 7 - Gráfico de comparação entre previsto e observado da dispersão do modelo de validação.

4.3 RNA Avaliação

O histograma dos erros entre valores previstos e experimentais do conjunto de dados de validação são apresentados na Figura 8. Os erros foram assimétricos para ambos os lados e conjuntos de dados. Um pequeno erro padrão foi observado no caso do conjunto de dados de retração, valores a esquerda do gráfico, uma vez que o volume de dados de retração é maior comparado com os valores de expansão.




Figura 8 - Histograma dos valores de erro entre os valores de retração e expansão previstos e experimentais.

Neste estudo, o gráfico de SHAP (em inglês – SHaple Additive exPlanation) fornece interpretações locais e globais de cada parâmetro de entrada. O gráfico SHAP ilustra informações comparáveis para caracterizar a importância que tem sido amplamente utilizada na literatura, mas é mais apropriada para modelos de aprendizado de máquina, pois é mais estável e fornece informações quantitativas (Hilloulin and Tran, 2022).

Os valores SHAP de cada recurso, classificados em ordem de seu valor SHAP médio, são mostrados na Figura 9. Os dados listados no topo da figura podem ser associados à maiores contribuições para saídas do modelo. Os cinco parâmetros que mais

influenciam as previsões de retração foram a idade do concreto (dt), aditivo compensador (compensador), cimento tipo CP II Z 32, relação água/cimento (a/c), aditivo tipo RA1 (multifuncional) e consumo de cimento (C).




Figura 9 - Análise de importância de recursos usando a biblioteca SHAP em código Python.

Observa-se que a alta relação dt diminui o valor SHAP, ou seja, aumenta a retração, assim como o maior consumo do aditivo tipo RA1 e consumo de cimento. O alto teor de aditivo tipo CR, cimento CP II Z 32 e aditivo tipo RA1-R apresentam valores positivos de SHAP em seus valores de alta relação, resultando na expansão do concreto.

5 Conclusão

Este estudo apresentou o potencial do modelo de aprendizado de máquina para prever a retração por secagem do concreto mediante a característica da dosagem da mistura. O modelo utilizado de machine learning foi construído com a biblioteca Keras na linguagem de programação em Python. O gráfico SHAP foi utilizado para interpretar a dependência dos dados de entrada para o modelo de aprendizado construído. As seguintes conclusões foram obtidas:

- O modelo de aprendizado de máquina pode atingir alta precisão de treinamento e validação para prever a retração por secagem, atingindo os valores de 0,998 e 0,906 de R^2 , respectivamente;
- O modelo pode ser interpretado usando valores SHAP. Os parâmetros mais correlacionados foram: idade do concreto (dt), consumo do aditivo tipo CR, cimento CP II Z 32, relação água/cimento (a/c), aditivo tipo RA1 e consumo de cimento (C).



O estudo pode abrir novos caminhos de pesquisa relacionadas ao uso de novas adições combinadas com outras mais em conjunto com a combinação de aditivos. Por exemplo, os resultados podem orientar a seleção de materiais constituintes do concreto para diminuir a retração por secagem de acordo com a disponibilidade da região de forma a buscar o melhor custo.

6 Referências

Abbasnia, R., Shekarchi, M. and Ahmadi, J. (2013) 'Evaluation of concrete drying shrinkage related to moisture loss', *ACI Materials Journal*, 110(3), pp. 269–277. doi: 10.14359/51685660.

BAKSHI, M. (2011) *Characterization and Modeling of Moisture Flow through hydrating Cement-Based Materials under Early-age Drying and Shrinkage Conditions*. Arizona State University.

Hilloulin, B. and Tran, V. Q. (2022) 'Using machine learning techniques for predicting autogenous shrinkage of concrete incorporating superabsorbent polymers and supplementary cementitious materials', *Journal of Building Engineering*, 49(December 2021), p. 104086. doi: 10.1016/j.jobbe.2022.104086.

Mazzoli, A., Monosi, S. and Plescia, E. S. (2015) 'Evaluation of the early-age-shrinkage of Fiber Reinforced Concrete (FRC) using image analysis methods', *Construction and Building Materials*, 101, pp. 596–601. doi: 10.1016/j.conbuildmat.2015.10.090.

Motta, M. dos S. (2018) *Fluência e retração de pastas de cimento em idade jovem*. Pontifícia Universidade Católica do Rio de Janeiro.

NBR 11768-1 (2019) *Aditivos para concreto de cimento Portland*.

NBR 16834 (2020) *NBR 16834-2020: Concreto - Determinação da variação dimensional (retração ou expansão linear)*.

Nehdi, M. L. and Soliman, A. M. (2012) 'Artificial intelligence model for early-age autogenous shrinkage of concrete', *ACI Materials Journal*, 109(3), pp. 353–362. doi: 10.14359/51683826.