



Estudo da capacidade dúctil de pilares em concreto armado com aplicação de *Machine Learning*

Palavras-Chave: Pilares; Concreto Armado; Machine Learning; Abalo Sísmico.

Autores(as):

ISADORA DE CASTRO GELAMO – FECFAU - UNICAMP

Prof. Dr. Gustavo Henrique Siqueira (orientador), FECFAU - UNICAMP

INTRODUÇÃO:

O projeto e o dimensionamento de estruturas civis envolvem a consideração de diferentes tipos de carregamentos, como os verticais, provenientes do peso próprio da estrutura e de cargas acidentais, e os horizontais, associados à ação do vento e dos sismos, sempre com base nas diretrizes estabelecidas por normas técnicas específicas. No Brasil, o dimensionamento ao estado limite último é normatizado, e os efeitos dinâmicos de ações como o vento e os terremotos são tratados em normas separadas. Dentro desse contexto, destaca-se a importância da ductilidade em pilares de concreto armado, que representa a capacidade da estrutura de se deformar plasticamente antes da ruptura, dissipando energia durante eventos extremos, como os sismos.

A determinação da ductilidade de um pilar depende de diversos parâmetros estruturais, incluindo geometria, materiais e detalhamento, sendo um desafio principalmente em estruturas de concreto armado devido à interação entre aço e concreto. A norma ABNT NBR 6118:2023 traz atualizações importantes em relação à versão de 2014, motivando estudos comparativos sobre sua influência na capacidade dúctil dos pilares. Além disso, apesar da baixa sismicidade do Brasil, eventos sísmicos de menor intensidade podem causar colapsos em regiões vulneráveis, especialmente em estruturas construídas antes da criação da norma sísmica ABNT NBR 15421:2006, cuja aplicação ainda é pouco difundida entre projetistas.

Nesse cenário, torna-se fundamental identificar os elementos estruturais mais vulneráveis, especialmente os pilares, que segundo estudos são componentes críticos nos mecanismos de colapso. A aplicação de técnicas de inteligência artificial, como o *Machine Learning*, surge como uma abordagem inovadora para otimizar o dimensionamento desses elementos. Ao permitir a análise de grandes volumes de dados e a identificação de padrões relevantes, os algoritmos de *Machine Learning* podem auxiliar na previsão da ductilidade estrutural e na definição de parâmetros que aumentem a segurança das edificações frente a cargas sísmicas.

METODOLOGIA:

Primeiramente, foi realizado uma análise estática não linear (Pushover), de um pórtico bidimensional com quatro nós, como pode ser observado na Figura 1, sendo os da base engastados para impedir deslocamentos e rotações, através de um código desenvolvido no software OpenSees. Os materiais foram definidos com os modelos Concrete01 para o concreto e Steel01 para o aço, ambos com base em modelos constitutivos da biblioteca Fedees. A seção transversal dos pilares foi modelada com elementos de fibras, distribuindo o concreto entre núcleo e capa, e posicionando as armaduras em camadas. A discretização do pilar foi feita com elementos finitos do tipo forceBeamColumn, apropriados para análises não lineares. As cargas verticais foram aplicadas como peso próprio, enquanto as cargas horizontais foram incrementadas por controle de deslocamento até o colapso.



Figura 1: Pórtico bidimensional modelado e analisado no openseespy.

O processo utilizou o teste NormDispIncr para verificar a convergência da solução a cada incremento de carga. Foram feitas 100 análises, variando os valores de resistência de concreto (F_c) e resistência de aço (F_y) acrescentando de 50 em 50. Além disso, variou-se a dimensão da seção do Pilar quadrada acrescentando de 0,005 em 0,005. Os valores de máximo, mínimo e médio testados podem ser observados na Figura 2, sendo o valor máximo em vermelho, o valor médio em amarelo e o valor mínimo em azul.

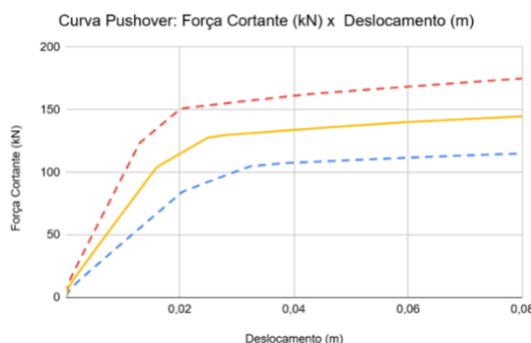


Figura 2: Curvas Pushover feitas por modelagem no Opensees.

A partir dos 100 resultados encontrados, foi realizada o cálculo da capacidade dúctil de cada curva pushover formada. A curva força \times deslocamento obtida permite estimar a capacidade dúctil da estrutura, definida como a razão entre o deslocamento último (Δ_u) e o deslocamento de escoamento (Δ_y). Para identificar esses parâmetros, adotou-se uma abordagem simplificada, conforme sugerido pela FEMA 356, considerando como Δ_y o deslocamento correspondente ao ponto em que a força atinge 75% do valor máximo obtido durante o carregamento. O deslocamento último foi considerado como aquele

associado ao pico de força da curva pushover. A partir desses valores, foi possível calcular a capacidade dúctil $\mu = \Delta u / \Delta y$, fornecendo uma medida da deformabilidade da estrutura além do limite elástico e indicando seu potencial de dissipação de energia em situações de carregamento extremo, como sismos.

A partir dos valores obtidos de capacidade estrutural, foi gerado um arquivo Excel contendo os 100 conjuntos de dados simulados. Para cada simulação, foram registrados os valores de resistência do concreto (f_c), resistência do aço (f_y), seção transversal dos pilares, o período fundamental de vibração (T) e a capacidade dúctil da estrutura. O período T foi calculado por meio da função eigen do OpenSees, que determina os autovalores do sistema estrutural linearizado, a partir dos quais se obtém a frequência natural e, conseqüentemente, o período de oscilação. Então, foi colocado esses dados em uma análise por Machine Learning, testando dois modelos de regressão: *Decision Tree* e *Random Forest*. O modelo foi testado para ler os parâmetros colocados e resultar nos valores de capacidade dúctil colocado, foi separado 70% para treinamento da máquina e 30% para teste.

RESULTADOS E DISCUSSÃO:

Os resultados foram colocados em gráficos gerados para visualizar e comparar os valores reais e os valores previstos pelo modelo de regressão aplicado (Figuras 3 e 4). No eixo Y, são representadas os valores de capacidade, enquanto o eixo X corresponde ao índice das amostras da base de teste, ou seja, a ordem dos registros usados para validar o modelo. O gráfico exibe duas curvas: uma com os dados reais e outra com os dados previstos, permitindo observar o quanto o modelo conseguiu capturar o comportamento dos dados. Essa visualização é importante para avaliar, de forma intuitiva, se o modelo acompanha adequadamente as variações nos dados e se as previsões estão próximas da realidade.

Foram comparados dois modelos de regressão: *Decision Tree* e *Random Forest*, com base nas métricas R^2 , MAE, MSE e RMSE. O modelo *Random Forest* apresentou desempenho superior, com um R^2 de 0,88, indicando maior capacidade de explicar a variabilidade dos dados, em comparação ao R^2 de 0,78 obtido pelo *Decision Tree*. Em relação ao erro absoluto médio (MAE), o *Random Forest* teve valor de 0,36, enquanto o *Decision Tree* apresentou 0,43, revelando previsões mais precisas no modelo *Random Forest*. As métricas de erro quadrático também reforçam essa superioridade: o *Random Forest* obteve MSE de 0,39 e RMSE de 0,62, contra MSE de 0,71 e RMSE de 0,84 do *Decision Tree*. Com isso, conclui-se que o modelo *Random Forest* foi mais eficiente e adequado para a tarefa de regressão analisada.

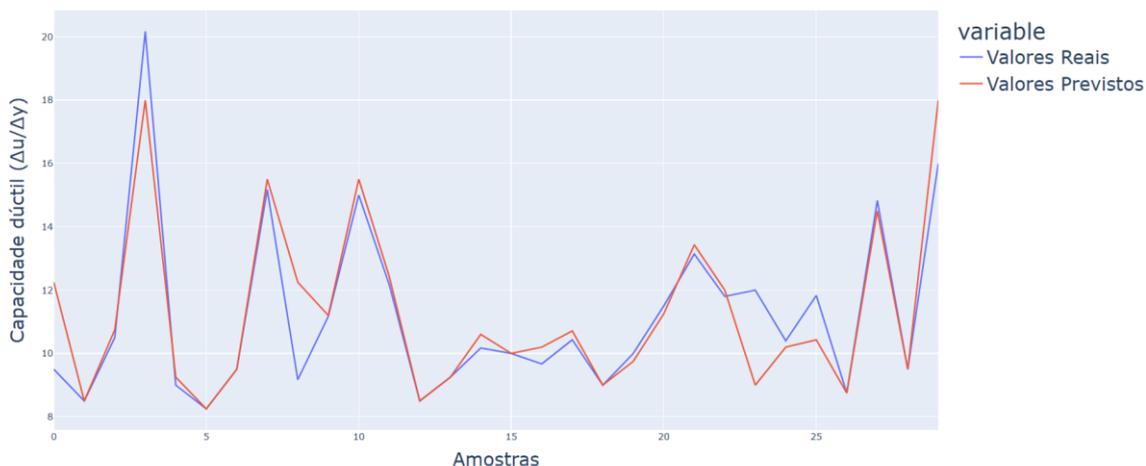


Figura 3: Gráfico das Curvas de Valores Reais e Valores Previstos pelo modelo *Decision Tree*.

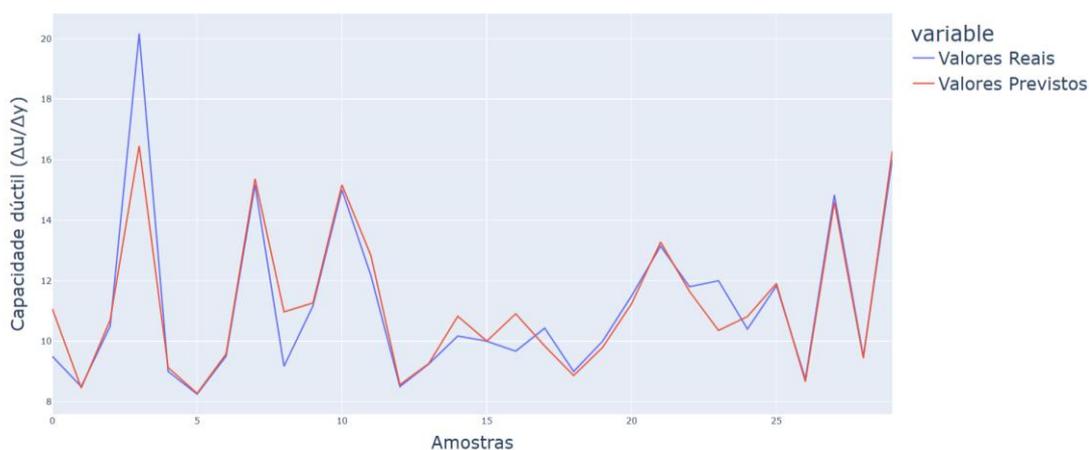


Figura 4: Gráfico das Curvas de Valores Reais e Valores Previstos pelo modelo *Random Forest*.

CONCLUSÕES:

Os resultados deste estudo demonstraram que é possível prever com boa precisão a capacidade dúctil de pilares em concreto armado por meio de algoritmos de Machine Learning. Dentre os modelos testados, o Random Forest se destacou pelo melhor desempenho nas métricas avaliadas, evidenciando sua capacidade de capturar a relação entre os parâmetros estruturais e a ductilidade.

Essa abordagem representa um avanço relevante na análise estrutural, ao permitir que dados obtidos por simulação numérica sejam utilizados para treinar modelos preditivos confiáveis. Assim, o uso da inteligência artificial se mostra uma ferramenta promissora para auxiliar projetistas na tomada de decisão e no dimensionamento mais seguro de estruturas sujeitas a ações sísmicas.

BIBLIOGRAFIA

- [1] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 6118:2023 – Projeto de estruturas de concreto – Procedimento. Rio de Janeiro: ABNT, 2023.
- [2] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 15421:2023 – Projeto de estruturas resistentes a sismos. Rio de Janeiro: ABNT, 2023.
- [3] FEDERAL EMERGENCY MANAGEMENT AGENCY. *Prestandard and commentary for the seismic rehabilitation of buildings*. Prepared by American Society of Civil Engineers. Washington, D.C.: FEMA, nov. 2000. (FEMA 356).
- [4] FILIPPOU, F. C.; POPOV, E. P.; BERTERO, V. V. **Effects of bond deterioration on hysteretic behavior of reinforced concrete joints**. Berkeley: University of California, 1983.
- [5] OPENSEESPY. OpenSeesPy Documentation. Disponível em: <https://openseespydoc.readthedocs.io/en/latest/>.
- [6] Open System for Earthquake Engineering Simulation - Home Page. Disponível em: <<https://opensees.berkeley.edu/>>.