

ESTUDO DA FRAGILIDADE DE PÓRTICOS EM CONCRETO ARMADO COM APLICAÇÃO DE *MACHINE LEARNING*

Palavras-Chave: FRAGILIDADE SÍSMICA, OPENSEESPY, *MACHINE LEARNING*

Autores(as):

YASMIN ESMAHAN FARES – FECFAU - UNICAMP

Prof. Dr. GUSTAVO HENRIQUE SIQUEIRA (orientador) – FECFAU - UNICAMP

INTRODUÇÃO:

Este projeto propõe desenvolver curvas de fragilidade analíticas para pórticos de concreto armado, utilizando os softwares OpenSees e MATLAB. Essas curvas descrevem a relação entre a intensidade sísmica e a probabilidade dos diferentes níveis de danos estruturais (dano leve, moderado, extensivo e colapso), com base em distribuições lognormais da demanda e da capacidade. Posteriormente, serão aplicadas técnicas de Machine Learning com modelos de substituição (surrogate models) para reduzir o custo computacional das análises não lineares e facilitar a previsão de comportamentos estruturais.

METODOLOGIA:

Para o desenvolvimento da iniciação científica, foi criado um modelo computacional usando o




Figura 1: Representação do pórtico e dos nós analisados.

OpenSeesPy, uma interface em Python para o software OpenSees, focado em análises estruturais e sísmicas. O modelo simula um pórtico simples de concreto armado em duas dimensões, com quatro nós representando pontos principais da estrutura. Os nós da base foram fixados para impedir deslocamentos, simulando condições reais de apoio. A estrutura analisada está

ilustrada na Figura 1.

A primeira análise realizada foi a da capacidade da estrutura a partir da análise Pushover, em que modelou-se o concreto e o aço da estrutura com materiais que representam seu comportamento real, usando elementos que capturam a resposta não linear. Aplicou-se carga gravitacional para estabilizar a estrutura e depois uma carga lateral controlada por deslocamento para analisar sua capacidade de deformação. Foram feitas 100 variações nos parâmetros dos materiais para avaliar o impacto na resistência e ductilidade. Os deslocamentos e forças foram registrados para gerar curvas Pushover, que mostram a resposta da estrutura a diferentes níveis de carga.




Figura 2: Foram feitas 100 análises com variações nas propriedades dos materiais, mostrando três curvas principais: a vermelha tracejada indica o valor máximo, a amarela contínua a média e a azul tracejada o valor mínimo dos resultados

Em prosseguimento a este trabalho, foi realizada a simulação de resposta de demanda do mesmo pórtico de concreto armado durante um terremoto, usando o OpenSeesPy. Para simular o terremoto, é usado um registro real de acelerações do solo, que é processado para extrair os dados de tempo e intensidade da vibração. Esse registro é aplicado à base da estrutura como um movimento lateral variável no tempo, simulando o efeito do tremor. Os terremotos utilizados para a análise sísmica da estrutura foram captados através da biblioteca NGA-West 2, possuem magnitude entre 3 a 8, com o espectro de resposta dos registros representados pela Figura 3.




Figura 3: Espectros de pseudoaceleração (pSa) obtidos a partir de diversos registros sísmicos, em função do período. As linhas cinza representam os espectros individuais, a linha preta contínua corresponde à linha média e as linhas tracejadas indicam os limites (Fonte: NGA-WEST2, 2025)

intensidade sísmica, foi realizada a geração de uma nuvem de pontos para extração da curva de fragilidade, conhecida como a *Cloud Analysis*, uma entre as técnicas possíveis. Com os dados coletados, foi possível plotar os pontos em um gráfico log-log para que a resposta seja linearizada e assim, facilitar a determinação dos coeficientes que regem a distribuição dos pontos.




Figura 4: Gráfico log-log que representa a nuvem de pontos obtida a partir dos pares de valores de deslocamento máximo da estrutura e intensidade do abalo sísmico.

Sendo assim, para a determinação das curvas de fragilidade, foram calculados os diferentes valores de probabilidade (equações 1, 2 e 3) a partir dos valores de demanda e capacidade obtidos através das análises realizadas.

$$P[LS|IM] = \Phi \left[\frac{\ln(IM) - \theta}{\beta} \right]$$

Equação 1: Equação do cálculo da probabilidade de se atingir um estado limite, sendo Φ a função de distribuição normal acumulada, $\ln(IM)$ o logaritmo natural de intensidade do abalo sísmico, obtido a partir da linearização de demanda realizada anteriormente; θ e β , que são coeficientes calculados. (Fonte: Ronch, 2024)

$$\beta = \frac{\sqrt{\beta_{D|IM}^2 + \beta_C^2}}{b}$$

Equação 2: Equação para o cálculo de β , a partir do coeficiente b obtido pela linearização realizada anteriormente, $\beta_{D|IM}$ a dispersão logarítmica da demanda e β_C a dispersão logarítmica da capacidade. O valor de β representa a dispersão logarítmica total da função de fragilidade, combinando a variabilidade da demanda e da capacidade estrutural, normalizada pelo coeficiente b . (Fonte: Ronch, 2024)

$$\theta = \exp \left[\frac{\ln(S_C) - \ln(a)}{b} \right]$$


Equação 3: Equação para o cálculo de θ , a partir dos coeficientes $\ln(a)$ e b , obtidos pela linearização anterior, e $\ln(S_C)$, o logaritmo da mediana da capacidade. O parâmetro θ representa o valor mediano da intensidade sísmica IM necessário para que a demanda estrutural média iguale a capacidade S_C , levando ao colapso ou falha da estrutura. (Fonte: Ronch, 2024)

Como valores de dispersão e mediana de capacidade a partir dos diferentes estados de dano foram utilizados os seguintes valores:

Capacity models adopted in this study.								
Typology	IO		LS		CP			
	S_C	σ_C	S_C	σ_C	$S_{C,inf}$	$S_{C,sup}$	$\sigma_{C,inf}$	$\sigma_{C,sup}$
BF	0.5%	0.3	1.0%	0.3	2.0%	4.0%	0.3	0.6
OGS	0.5%	0.3	1.0%	0.3	2.0%	4.0%	0.3	0.6
IF	0.3%	0.3	0.5%	0.3	1.25%	2.5%	0.3	0.6

Tabela 1: Valores de mediana (S) e dispersão logarítmica (σ) utilizados para o cálculo da probabilidade de se atingir um estado limite. Sendo IO (Immediate Occupancy) o dano leve, LS (Life Safety) dano moderado, CP (Collapse Prevention) inferior o dano extensivo e superior o colapso. As tipologias representadas para o estudo são: BF (*Bare Frame*), estrutura sem alvenaria; OGS (*Open Ground Story*), edifício com térreo aberto; e IF (*Infilled Frame*), estrutura com alvenaria de vedação. Os valores utilizados para o estudo foram os do *Bare Frame*. (Fonte: Pereira et al., 2024)

A partir dos resultados, foram geradas as curvas de fragilidade da estrutura (Figura 5). Por fim, os dados da curva de dano moderado (curva laranja) foram inseridos em uma análise utilizando técnicas de aprendizado de máquina, por meio da aplicação de dois modelos de regressão: *Decision Tree* e *Random Forest*. O modelo foi testado para ler os parâmetros colocados e resultar nos valores de



probabilidade colocados, sendo capaz de gerar as curvas de fragilidade. Para isso, o conjunto de dados foi dividido em 70% para treinamento e 30% para teste.

Figura 5: Curvas de Fragilidade da estrutura, sendo a curva verde representando a probabilidade da estrutura atingir o dano leve; amarela, dano moderado; laranja, dano extensivo; e vermelha, colapso; em função da intensidade do terremoto.

RESULTADOS E DISCUSSÃO:

Os resultados obtidos por meio das análises com Machine Learning foram representados graficamente com o objetivo de facilitar a comparação entre os valores reais e aqueles estimados pelo modelo de regressão empregado (Figuras 6 e 7). No eixo vertical (Y), estão dispostas as probabilidades associadas a cada amostra, enquanto o eixo horizontal (X) indica a ordem dos registros da base de teste utilizados na etapa de validação. Os gráficos apresentam duas curvas: uma correspondente aos dados observados (em azul) e outra às previsões do modelo (em vermelho), o que possibilita uma avaliação visual da aderência entre os valores previstos e os reais. Essa forma de apresentação permite verificar, de maneira intuitiva, o grau de fidelidade do modelo ao comportamento dos dados. Além disso, estão representados pela Tabela 2 os valores de erros obtidos através das duas análises de *Machine Learning*.




Figura 6: Gráfico das Curvas de Valores Reais e Valores Previstos pelo modelo *Decision Tree*.




Figura 7: Gráfico das Curvas de Valores Reais e Valores Previstos pelos modelos *Random Forest*.

Os principais indicadores para avaliar os modelos foram calculados a partir das diferenças entre os valores previstos e observados na Tabela 2. O RMSE é a raiz quadrada da média dos quadrados dessas diferenças; O MSE corresponde à média dos quadrados dos erros; O MAE é a média dos valores absolutos das diferenças; e o coeficiente de determinação R^2 indica a proporção da variação total explicada pelo modelo, variando de 0 (sem explicação) a 1 (ajuste perfeito).

	<i>Decision Tree</i>	<i>Random Forest</i>
R^2	0.998	0.999
MAE	0.002	0.001
MSE	6.432e-06	3.864e-06
RMSE	0.002	0.002

Tabela 2: Valores de erros obtidos pelas duas formas de análise através de Machine Learning.

CONCLUSÕES:

Os resultados deste estudo demonstraram que é possível prever com boa precisão a probabilidade de se atingir um estado limite através da intensidade de um abalo sísmico um por meio de algoritmos de *Machine Learning*. Dentre os modelos testados, o *Random Forest* se destacou pelo melhor desempenho nas métricas avaliadas, evidenciado pelos menores valores de erros obtidos durante a análise.

BIBLIOGRAFIA

RONCH, Lucas Filipe da. *Estudo de vulnerabilidade sísmica de OAE's através de métodos em Machine Learning*. 2024. Dissertação (Mestrado em Engenharia Civil) – Faculdade de Engenharia Civil, Arquitetura e Urbanismo, Universidade Estadual de Campinas, Campinas, 2024

PEREIRA, E. M. V.; LEITÃO, F. F.; ANDRADE, R. B.; CAROBENO, C. L.; SIQUEIRA, G. H. Seismic risk evaluation of low-rise RC buildings in Brazil. *Journal of Building Engineering*, v. 88, 2024.

LEITÃO, F.; ANDRADE, R.; CAROBENO, C.; PEREIRA, E.; SIQUEIRA, G. H. Fragilidade sísmica em estruturas de CA via machine learning: revisão sistemática. *Anais do 64º Congresso Brasileiro do Concreto*, 2023. IBRACON. ISSN 2175-8182

NGA-WEST2. Pacific Earthquake Engineering Research Center. Disponível em: <https://ngawest2.berkeley.edu/>.