

APRENDIZADO DE MÁQUINA NA PREVISÃO DA RESISTÊNCIA À PUNÇÃO DE LAJES LISAS DE CONCRETO ARMADO

¹Queiliane Barbosa do Nascimento ²Douglas Freitas Augusto dos Santos

¹Estudante do Curso Superior de Bacharelado em Engenharia Civil – IFTO. Bolsista do CNPq. e-mail: queiliane.nascimento@estudante.ifto.edu.br

²Docente do Curso Superior de de Bacharelado em Engenharia Civil – IFTO. Orientador(a). e-mail: douglas.augusto@ifto.edu.br

1 INTRODUÇÃO

As lajes lisas ou lajes planas, são denominadas desta forma, devido à ausência de vigas no sistema estrutural, ou seja, as lajes se apoiam diretamente sobre os pilares. A punção consiste em um modo de ruptura que ocorre em elementos de concreto armado devido a esforços de cisalhamento causados por cargas concentradas transversais ao plano do elemento (Broms, 2005).

De acordo com Guandalini (2006), a punção representa um tipo abrupto de falha, caracterizada por cisalhamento, que pode ocorrer como resultado da aplicação de uma carga concentrada em uma área específica, geralmente associada à reação de um pilar ou a uma força concentrada. A resistência à punção de lajes lisas de concreto armado pode ser sensivelmente afetada por diversos parâmetros, tais como a resistência à compressão do concreto, a taxa de armadura de flexão, bem como as características geométricas e a espessura da laje.

2 OBJETIVO

O objetivo geral é analisar o desempenho comparativo entre critérios normativos de dimensionamento à punção de lajes lisas e modelos de *Machine Learning*, tendo como referência as normas ACI 318 (2014), Eurocode 2 (2004) e NBR 6118 (2014).

3 MATERIAL E MÉTODOS

O estudo foi desenvolvido a partir de um dataset construído com dados coletados em artigos, dissertações e teses que apresentavam ensaios experimentais de punção em lajes lisas de concreto armado, observando exigências normativas e recomendações técnicas. Foram extraídos parâmetros como resistência à compressão do concreto, taxa de armadura de flexão e características geométricas das lajes, garantindo consistência e comparabilidade das informações.

A análise exploratória contemplou estatísticas descritivas, gráficos de dispersão, histogramas e boxplots para identificação de padrões, tendências e outliers. Relações entre variáveis foram avaliadas por meio dos coeficientes de correlação de Pearson e Spearman.

Para o pré-processamento, os dados passaram por normalização e padronização utilizando *StandardScaler*, *MinMaxScaler* e *RobustScaler* da biblioteca *scikit-learn*, escolhendo-se o método mais adequado a cada modelo. O escalonamento foi realizado após a divisão do conjunto em 70% para treino e 30% para teste, utilizando *random state* fixo para garantir reprodutibilidade.

Os modelos de aprendizado de máquina adotados incluíram regressão linear múltipla e redes neurais artificiais, implementados com as bibliotecas *scikit-learn* e *TensorFlow/Keras*. O ajuste de hiperparâmetros foi feito por *grid search* e a validação repetida assegurou a robustez das previsões.

Por fim, os resultados obtidos pelos modelos preditivos foram comparados aos métodos normativos de cálculo da NBR 6118 (2014), ACI 318 (2014) e Eurocode 2 (2004), utilizando o coeficiente de determinação (R^2), gráficos de dispersão e de resíduos para avaliar o desempenho preditivo.

No dimensionamento à punção de lajes lisas, o ACI 318 (2014) estabelece que a resistência deve ser determinada considerando uma tensão resistente aplicada em um perímetro crítico, definido a uma distância de $d/2$ do pilar e passando pelo meio de uma fissura inclinada de 45° ao longo da altura útil. Nesse critério, a tensão resistente à punção depende apenas da raiz quadrada da resistência à compressão do concreto, sendo estimada empiricamente pela Equação 1.

$$V_{Rc} = 0,33 \cdot \sqrt{f_c} \cdot u_1 \cdot d \quad \text{Equação 1}$$

Onde: f_c é a resistência à compressão do concreto limitada ao valor máximo de 69 MPa; u_1 é o perímetro de controle segundo o ACI; d é a altura útil da laje.

O Eurocode 2 (2004), de forma semelhante ao ACI, determina a resistência à punção a partir da aplicação de uma tensão resistente em uma área delimitada por um perímetro crítico. Contudo, nesse caso, o perímetro é definido no término da fissura de punção, correspondente a um ângulo de $26,6^\circ$, resultando em um afastamento de $2d$ em relação ao pilar. A estimativa empírica da resistência é expressa pela Equação 2.

$$V_{Rc} = 0,18 \cdot k \cdot (100 \cdot \rho \cdot f_c)^{\frac{1}{3}} \cdot u_1 \cdot d \geq v_{min} \cdot u_1 \cdot d \quad \text{Equação 2}$$

Onde: k é a parcela do efeito de escala obtida através de $k = 1 + \sqrt{\frac{200}{d}} \leq 2$; ρ é a média da taxa de armadura nas duas direções calculado por $\rho = \sqrt{\rho_x \cdot \rho_y} \leq 0,02$, onde ρ_x e ρ_y são as taxas de armadura de flexão da laje nos sentidos x e y ; f_c é resistência à compressão do concreto; u_1 é o perímetro de controle afastado em $2d$ do pilar; d é a altura útil da laje; v_{min} é a tensão resistente mínima para o caso de taxas de armadura de flexão muito baixas. Obtida através de $v_{min} = 0,035 \cdot k^{\frac{2}{3}} \cdot \sqrt{f_c}$.

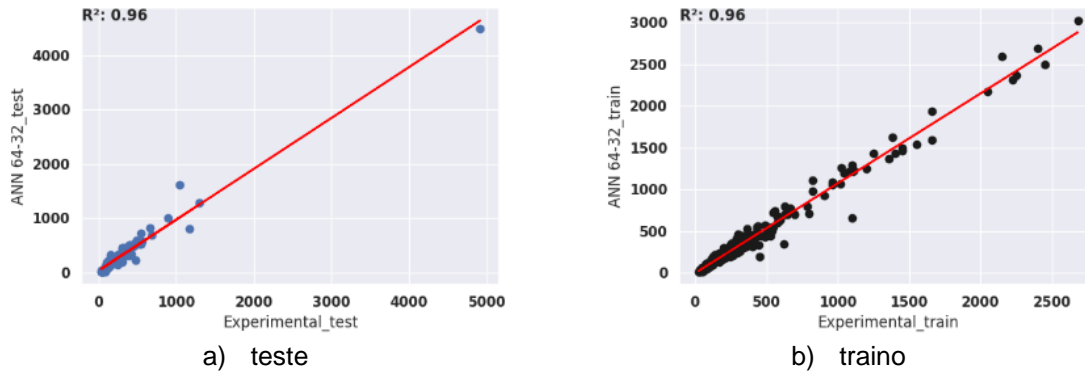
A NBR 6118 (2014) segue a mesma equação da Eurocode 2, porém sem as limitações para a taxa de armadura de flexão e para o efeito de escala.

4 RESULTADOS E DISCUSSÃO

Os modelos de aprendizado de máquina apresentaram desempenho significativamente superior às equações prescritas nas normas NBR 6118 (2014), ACI 318 (2014) e Eurocode 2 (2004) na previsão da resistência à punção de lajes lisas de concreto armado. Entre os modelos testados, a

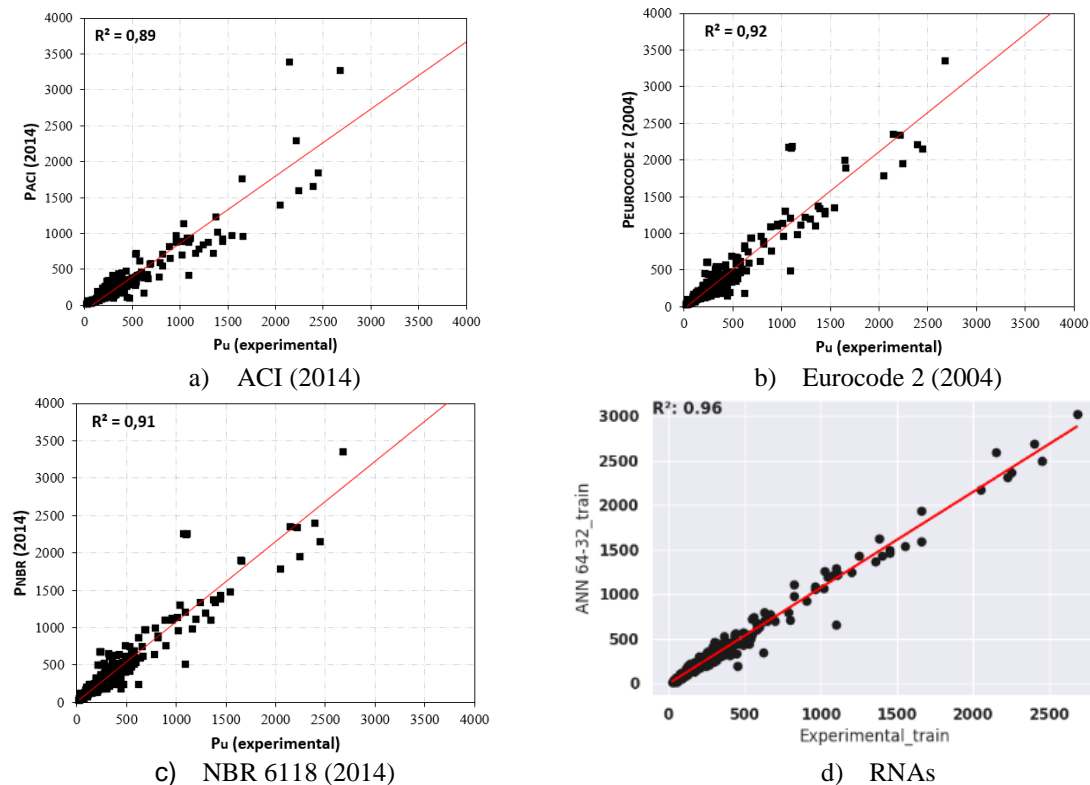
rede neural artificial (RNA) foi a que obteve os melhores resultados, apresentando coeficiente de determinação (R^2) mais elevado e menor dispersão, indicando maior precisão preditiva, ver Figura 2.

Figura 2 – Regressão do modelo RNAs



As análises comparativas demonstraram que as equações normativas tendem a apresentar valores conservadores, enquanto os modelos preditivos ajustados a partir de dados experimentais mostraram maior aderência aos resultados reais, especialmente quando incluídas variáveis relacionadas à geometria da laje e propriedades mecânicas do concreto, ver Figura 3.

Figura 3 – Distribuição das relações experimental pelas normas ACI 318 (2019), NBR 6118 (2014), EUROCODE 2 (2004)



Os resultados confirmam evidências da literatura quanto ao potencial das técnicas de *machine learning* em complementar ou aprimorar métodos normativos. Essa abordagem favorece o

dimensionamento estrutural otimizado, garantindo a segurança, mas minimizando a superestimação de armaduras e espessuras, o que resulta em benefícios técnicos e econômicos.

5 CONSIDERAÇÕES FINAIS

O presente trabalho demonstrou que o uso de técnicas de aprendizado de máquina, especialmente redes neurais artificiais, apresenta elevado potencial para previsão da resistência à punção de lajes lisas de concreto armado, superando em precisão as equações prescritas por normas amplamente utilizadas como a NBR 6118 (2014), ACI 318 (2014) e Eurocode 2 (2004). Assim, o objetivo inicial — avaliar a viabilidade e desempenho comparativo entre métodos normativos e modelos preditivos — foi plenamente alcançado.

A aplicação de modelos treinados com dados experimentais permitiu identificar relações não lineares entre variáveis estruturais e a resistência à punção, oferecendo uma abordagem complementar aos métodos tradicionais de cálculo. Essa integração pode contribuir para projetos mais eficientes, com dimensionamentos seguros e economicamente otimizados. Como limitação, destaca-se a dependência da qualidade e abrangência do banco de dados utilizado, além da necessidade de validação com novos conjuntos de dados experimentais para ampliar a generalização dos modelos.

6 AGRADECIMENTOS

Agradecemos ao Instituto Federal do Tocantins (IFTO) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo fomento e apoio à execução deste projeto, bem como pela concessão da bolsa de Iniciação Científica, que viabilizou o desenvolvimento da pesquisa.

REFERÊNCIAS

ACI 318 (2014). **Building Code Requirements for Structural Concrete**. American Concrete Institute, Farmington Hills, Michigan.

ASSOCIACAO BRASILEIRA DE NORMAS TECNICAS NBR 6118 (2014). **Projeto de Estruturas de Concreto – Procedimento**. Rio de Janeiro.

BROMS, C. E., **Concrete Flat Slabs and Footings: Design Method for punching and Detailing for Ductility**. PhD Thesis. Department of Civil and Architectural Engineering, Division of Strucutural Design and Bridges, Royal Institute of Technology, Stockholm, Sweden, 2005, 114pp.

EN 1992-1-1/AC (2010). **Corrigendum AC – Eurocode 2: Design of Concrete Structures—Part 1-1: General Rules and Rules for Buildings**. CEN, EN 1992-1-1, Brussels, Belgium.

GUANDALINI S, BURDET, O. L. MUTTONI A. (2009). **Symmetrical punching tests on slabs without transverse reinforcement**. ACI Structural Journal.