

08 a 11 de Outubro de 2018
Instituto Federal Fluminense
Búzios - RJ

PREDIZENDO A RESISTÊNCIA DO CONCRETO À COMPRESSÃO: UMA COMPARAÇÃO BASEADA EM TRÊS MÉTODOS DE REGRESSÃO

Renan Mateus B. do Nascimento¹ - renanmateusbn@gmail.com

Nícolas Arruda Maduro¹ - nicolasamaduro@gmail.com

Matheus I. Nesteruk Moreira¹ - matheusibrahim@gmail.com

Rogério Martins Gomes¹ - rogerio@cefetmg.br

Bruno Andre Santos¹ - bruno@decom.cefetmg.br

¹Centro Federal de Educação Tecnológica de Minas Gerais, CEFET-MG - Belo Horizonte, MG, Brasil

Abstract. *O concreto é o material mais importante da Engenharia Civil e é de fundamental importância conhecer sua resistência para uma determinada mistura e uma idade específica (dias). Este artigo propõe a criação e comparação de modelos de regressão que sejam capazes de prever a resistência do concreto à compressão. Uma base de dados contendo os componentes que podem ser utilizados na fabricação do concreto foi utilizada no treinamento de três modelos de regressão: Regressão Linear, Rede Neural Artificial de Múltiplas Camadas e Support Vector Regression. Esses algoritmos foram testados considerando o Erro Quadrático Médio e o valor R^2 como medidas de desempenho. Os testes mostraram que os modelos de Rede Neural Artificial de Múltiplas Camadas e Support Vector Regression alcançaram um excelente desempenho em comparação ao modelo de Regressão Linear. Além disso, o maior valor de R^2 obtido pela Rede Neural Artificial de Múltiplas Camadas indicou que esse método foi o que conseguiu explicar de maneira mais satisfatória os valores observados.*

Keywords: *Resistência à compressão do concreto, Inteligência computacional, Regressão Linear, Rede Neural Artificial de Múltiplas Camadas, Support Vector Regression*

1. INTRODUÇÃO

A Engenharia Civil figura como uma área de extrema importância, pois é responsável pela concepção, projeto, construção, supervisão, operação e manutenção de todo tipo de infraestrutura que existe na nossa sociedade. Logo, o estudo das características dos materiais e insumos utilizados na área é relevante para garantir não só a segurança, mas a economia e durabilidade das construções. Dentre os materiais utilizados para construção de estruturas, o concreto é o mais importante e o mais utilizado devido as suas características de resistência, durabilidade e trabalhabilidade, bem como as inúmeras possibilidades arquitetônicas que ele permite realizar. Sendo assim, por se tratar de uma mistura de vários componentes, o concreto é um material

de alta complexidade e o desenvolvimento de um modelo capaz de compreender seu comportamento e produzir um material de qualidade e resistente à compressão não é uma tarefa trivial.

A literatura da área de Engenharia Civil estuda, na maioria das vezes, estes modelos por meio das composições físicas e químicas dos materiais envolvidos na mistura. Outras variáveis como o tempo de preparo, quantidade de água e condições climáticas também são incluídas nesse estudo (Aitcin, 2014; Economides *et al.*, 1989; Gjørsv, 2014; Hu *et al.*, 2017). Este trabalho, no entanto, propõe a criação e comparação de modelos de regressão que sejam capazes de prever a resistência do concreto à compressão com base em um conjunto de dados cuja resistência à compressão real do concreto, para uma determinada mistura e uma idade específica (dias), foi determinada a partir de experimentos em laboratório.

Regressão é uma das técnicas mais utilizadas para analisar dados com múltiplos fatores. Sua utilidade resulta do interesse em expressar com uma equação o relacionamento entre uma variável de interesse (a resposta) e algumas variáveis de predição que sejam relevantes (Montgomery *et al.*, 2012). Quando não é possível criar uma relação matemática entre as variáveis e a variável de interesse ou quando a mesma não é conhecida, podem-se criar modelos estatísticos que visam simular essa relação a fim de se alcançar resultados semelhantes.

Dos modelos de regressão que serão abordados, a Regressão Linear Múltipla trabalha com mais de uma variável independente que possuem uma relação linear com a variável de resposta (Tabachnick & Fidell, 2007). Um modelo de Regressão Linear Múltipla pode ser formulado conforme a Eq. (1):

$$y = b_0 + b_1x_1 + \dots + b_nx_n, \quad (1)$$

em que y é o valor de saída, x_i são as entradas do sistema e b_i são as constantes que ponderam as entradas.

Dentre os métodos que podem ser utilizados para determinar os valores de b_i , utilizou-se o Gradiente Descendente que se baseia na caminhada oposta ao sentido do crescimento do erro do sistema. Nesse método, ao final do processo de treinamento do modelo, são encontrados os valores de b_i que produzem o menor Erro Quadrático Médio para todos os dados de entrada ou treinamento.

Outro modelo utilizado para fazer regressão são as Redes Neurais de Múltiplas Camadas (RNA de Múltiplas Camadas). Este modelo é constituído por um sistema de neurônios simples interconectados chamados nós. Os neurônios são conectados por pesos e, ao final, tem seus valores somados e ativados por uma função de ativação (Gardner & Dorling, 1998). A Fig. 1 ilustra um modelo com dois neurônios de entradas $E1$ e $E2$ conectados a quatro neurônios em uma camada interna que, por sua vez, conectam-se a um neurônio de saída Y .

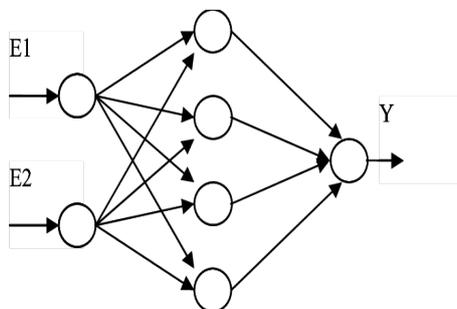


Figura 1- Exemplo de RNA de Múltiplas Camadas.

Os pesos dos vértices do modelo são treinados com auxílio de algoritmos que propagam o erro de saída do modelo para as camadas mais internas. Na literatura, são encontrados diversos algoritmos de correção de erro e, portanto, de ajuste dos pesos. Entre eles, vale destacar os seguintes: o Gradiente Descendente, utilizado também na regressão linear; *Broyden–Fletcher–Goldfarb–Shanno* (BFGS), que é baseado em modelos de otimização *Quasi-Newton*; e o *Levenberg–Marquardt*, que fica entre o algoritmo de *Gauss-Newton* (GNA) e o método do gradiente descendente.

Por fim, tem-se o modelo *Support Vector Regression* (SVR), baseado no *Support Vector Machine* (SVM) que é utilizado para classificação de apenas dois grupos. O SVM, conceitualmente, implementa a seguinte ideia: os vetores de entrada são mapeados não linearmente para um espaço de características de alta dimensão. Neste espaço, uma superfície de decisão linear é construída. Propriedades de borda da superfície de decisão garantem alta capacidade de generalização da máquina de aprendizagem (Cortes & Vapnik, 1995). A Fig. 2 mostra um exemplo da abordagem do SVM.

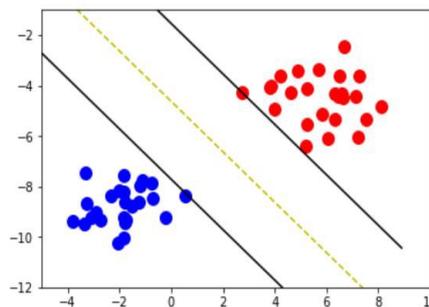


Figura 2- Exemplo do SVM.

No entanto, a ideia básica do SVR é mapear os dados de entrada x em um espaço de características de maior dimensão por meio de um mapeamento não linear Φ . Em seguida, um problema de regressão linear é obtido e resolvido neste espaço de características. Dessa forma, a aproximação feita pela regressão resolve o problema de se estimar uma função com base em certo conjunto de dados conforme Eq. (2).

$$G = (x_i, y_i)_{i=1}, \quad (2)$$

em que x_i é vetor de entrada e y_i é o valor desejado (Wang & Xu, 2004).

Resumindo, este trabalho propõe a criação e comparação dos modelos Regressão Linear, Rede Neural Artificial de Múltiplas Camadas e *Support Vector Regression* a serem utilizados na predição da resistência do concreto à compressão, assim, auxiliando no desenvolvimento de um material de melhor qualidade.

Neste artigo, a seção 2. descreve a metodologia utilizada no desenvolvimento deste trabalho. Em seguida, a seção 3. apresenta e analisa os resultados obtidos. Por fim, a seção 4. conclui o artigo e mostra perspectivas de trabalhos futuros.

2. METODOLOGIA

A construção do sistema de predição da resistência do concreto à compressão passa pelas seguintes etapas: i) Seleção das ferramentas que serão utilizadas no desenvolvimento do sis-

tema; ii) Escolha da base de dados; iii) Pré-processamento dos dados; iv) Realização dos experimentos; v) Análise dos resultados.

2.1 Ferramentas utilizadas

A linguagem de desenvolvimento escolhida foi *Python 3.7* devido a versatilidade e facilidade de uso, além de proporcionar uma série de bibliotecas de qualidade para se trabalhar com aprendizado de máquina. Dentre as diversas bibliotecas oferecidas para aprendizado de máquina, a *scikit-learn* foi escolhida por ser de código aberto e possuir vários algoritmos de classificação, regressão e agrupamento já disponíveis para utilização.

Como ambiente de desenvolvimento, optou-se pelo *Jupyter Notebook* por ser um ambiente que permite a criação de textos explicativos sobre análises e cujos resultados são exibidos em conjunto com o código em *Python*. Dessa forma, é possível ter pequenos trechos de código com explicações dos processos realizados de forma clara e objetiva auxiliando na documentação do experimento.

2.2 Base de dados

A base de dados utilizada no experimento foi a *Concrete Compressive Strength Data Set* (University of California Irvine, 2007; Yeh, 1998). Essa base possui 1030 instâncias com 9 atributos e pode ser vista na Tabela 1.

Table 1- Relação dos atributos da base de dados

Nome	Tipo	Medida	Descrição
<i>Cement</i>	Quantitativo	kg/m^3	Entrada
<i>Blast Furnace Slag</i>	Quantitativo	kg/m^3	Entrada
<i>Fly Ash</i>	Quantitativo	kg/m^3	Entrada
<i>Water</i>	Quantitativo	kg/m^3	Entrada
<i>Superplasticizer</i>	Quantitativo	kg/m^3	Entrada
<i>Coarse Aggregate</i>	Quantitativo	kg/m^3	Entrada
<i>Fine Aggregate</i>	Quantitativo	kg/m^3	Entrada
<i>Age</i>	Quantitativo	dias (1-365)	Entrada
<i>Concrete Compressive Strength</i>	Quantitativo	<i>MPa</i>	Saída

Apesar de terem sido escolhidos oito componentes que determinam as propriedades do concreto, é importante ressaltar que cada um desses elementos apresenta propriedades particulares na sua constituição como, por exemplo, o cimento pode ser produzido em grãos de pó de várias espessuras e possuir diferentes composições químicas (Yeh, 1998). Considerando tais fatos, Yeh (1998) realizou experimentos com dados a respeito da composição e processo de mistura (proporção dos componentes e técnica) vindos de diferentes fontes para, assim, avaliar as amostras de concreto obtidas e determinar quais registros iriam compor o banco de dados.

2.3 Pré-processamento

Para se trabalhar com modelos de regressão, usualmente é importante realizar a normalização dos dados. A normalização de dados consiste em tornar diferentes entradas com diferentes médias, escalas e desvios padrão em valores com a mesma escala de tal forma que seja possível

compará-los. Isso é importante para que o modelo de regressão não seja dominado por uma entrada que possua uma escala superior às demais. Neste trabalho, a normalização utilizada é descrita pela Eq. (3):

$$\gamma_i = \frac{x_i}{\mu_{x_i}}, \quad (3)$$

em que x_i representa todas as instâncias de uma das características e μ_{x_i} a média destes valores.

3. Experimentos e Resultados

Para realizar os experimentos, dividiu-se o conjunto de dados em dois grupos de forma aleatória em que 70% foi para o conjunto de treino e os 30% restantes para o conjunto de teste. Com esse conjunto de treinamento e teste, realizou-se o treinamento e a validação dos três métodos de regressão propostos nesse trabalho: Regressão Linear, RNA de Múltiplas Camadas e *Support Vector Regression*.

Na RNA de Múltiplas Camadas, utilizou-se como parâmetro o *solver 'lbfgs'* que é um otimizador da família *Quasi-Newton* para realizar a otimização dos pesos. O fator de apredizagem *alpha* foi definido como 0,01. A rede foi estruturada com uma camada escondida com 8 neurônios e a função de ativação utilizada foi a sigmoideal. O número máximo de iterações foi ajustado para 10.000 e os demais parâmetros utilizados no ajuste das funções de Regressão Linear e *Support Vector Regression* do *scikit-learn* foram mantidos em seus valores padrões.

Os resultados dos experimentos podem ser vistos nas figuras 3, 4 e 5. Estes gráficos mostram o valor medido da resistência à compressão no eixo x e o valor predito pelo modelo no eixo y . A reta traçada representa todos os pontos em que a predição deveria coincidir com o valor medido caso a predição fosse exata. Sendo assim, em um modelo ideal de predição todos os pontos estariam posicionados em cima da reta. Da mesma forma, quanto mais longe da reta o ponto estiver maior será o erro de predição apresentado.

Na Fig. 3, visualiza-se o resultado do modelo de Regressão Linear. Pode-se perceber que os pontos, apesar de possuírem uma tendência em direção semelhante à reta, apresentam-se de forma dispersa. Isso significa que o modelo apresenta um considerável erro de predição. Por outro lado, na Fig. 4, que representa o resultado do modelo RNA de Múltiplas Camadas, observa-se que a nuvem de pontos é mais compacta e está próxima da reta, principalmente nos pontos em que os valores de resistência à compressão são mais baixos. Por fim, na Fig. 5, onde é mostrado o resultado obtido pelo *Support Vector Regression*, a nuvem de pontos também se apresenta de forma mais compactada do que na Fig. 3.

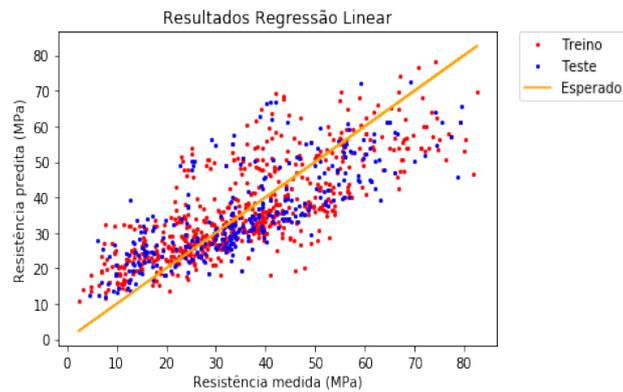


Figura 3- Resultados obtidos pelo modelo Regressão Linear para os conjuntos de dados de treinamento e teste.

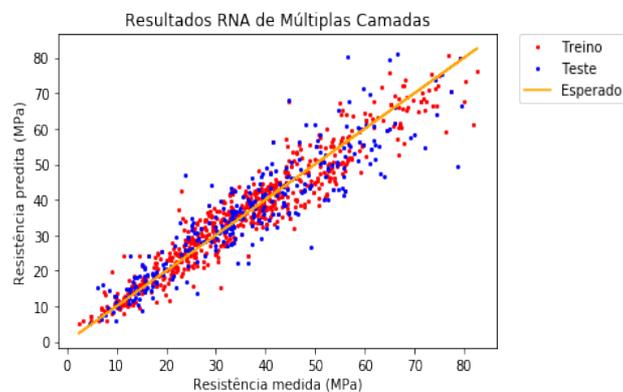


Figura 4- Resultados obtidos pelo modelo RNA de Múltiplas Camadas para os conjuntos de dados de treinamento e teste.

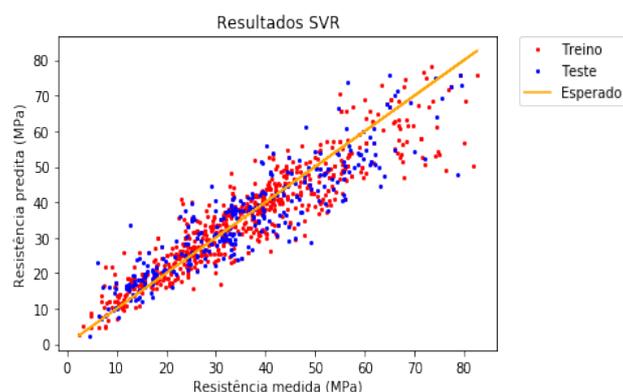


Figura 5- Resultados obtidos pelo modelo *Support Vector Regression* para os conjuntos de dados de treinamento e teste.

Com intuito de comparar os métodos de maneira quantitativa, os valores de Erro Quadrático Médio (EQM) e R^2 foram obtidos nos experimentos para cada método.

O EQM representa a média dos quadrados da diferença entre os valores que foram estimados e o respectivo valor esperado. Na Fig. 6, que mostra o EQM em cada método, observa-se que o erro obtido com a Regressão Linear é superior ao alcançado pelos outros métodos testados. É importante observar também que este resultado corrobora com os resultados mostrados nas figuras 3, 4 e 5 quanto a análise visual dos pontos gerados pela Regressão Linear e pelos outros dois métodos testados. Nessa comparação, é possível observar que os pontos encontram-se mais afastados da reta desejada, ou seja, apresentam um maior erro. Comparando o EQM dos métodos SVR e RNA de Múltiplas Camadas, nota-se que o primeiro método apresentou maior acurácia que o último tanto em treino quanto em teste.

Em seguida, na Fig. 7, é apresentado o resultado obtido pelo método R^2 , chamado de Coeficiente de Determinação. Com valores entre 0 (zero) e 1 (um), o R^2 é uma medida descritiva da qualidade do ajuste obtido e indica o quanto o modelo consegue explicar os valores observados (PortalAction, 2010). É possível observar que, de maneira semelhante aos resultados de EQM, a Regressão Linear apresentou o pior resultado dentre os métodos testados. Entretanto, a RNA de Múltiplas Camadas, diferentemente do EQM, obteve um resultado ligeiramente superior ao apresentado pelo método SVR. De qualquer forma, os resultados indicam que os ajustes que foram feitos nos três casos tiveram boa qualidade, visto que o menor R^2 obtido foi de aproximadamente 0.8.

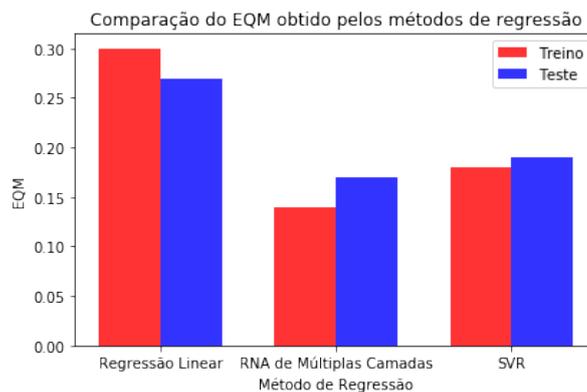


Figura 6- EQM obtido por cada método de regressão para os conjuntos de dados de treinamento e teste.

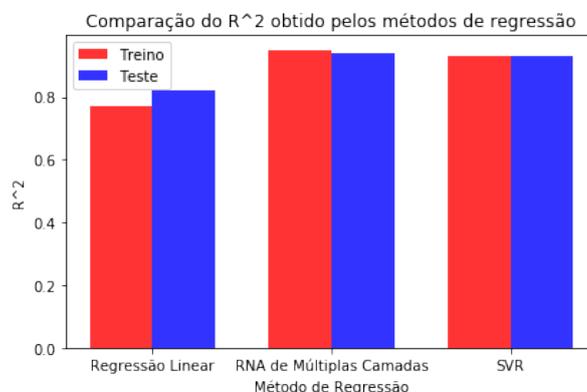


Figura 7- R^2 obtido por cada método de regressão para os conjuntos de dados de treinamento e teste.

4. CONCLUSÕES

Este artigo se propôs a realizar uma comparação entre três métodos de regressão. Para isso realizou uma análise quantitativa em termos do Erro Quadrático Médio e R^2 .

Ao final, foi possível observar que o método de Redes Neurais de Múltiplas Camadas apresentou os melhores resultados em comparação aos demais métodos por ter apresentado menor Erro Quadrático Médio. Além disso, um maior valor de R^2 indica que esse modelo consegue explicar de forma satisfatória os valores observados.

Sendo assim, este trabalho mostrou que, em um cenário real, é factível a utilização das Redes Neurais Artificiais de Múltiplas Camadas na predição da resistência do concreto à compressão considerando as variáveis pertinentes da sua formação, visando a construção de um material de melhor qualidade.

Agradecimentos

Os autores gostariam de agradecer ao Laboratório de Sistemas Inteligentes (LSI) pela infraestrutura disponibilizada, ao CEFET-MG e à FAPEMIG pelo suporte financeiro, sem o qual esse trabalho não teria sido viável.

REFERENCES

- Aïtcin, P.-C. (2014), *Binders for durable and sustainable concrete*. CRC Press.
- Concrete Compressive Strength Data Set. Disponível em: <http://archive.ics.uci.edu/ml/datasets/concrete+compressive+strength>. Acesso em: 21 de junho de 2018.
- Cortes, C. and Vapnik, V. (1995), *Support-vector networks*. *Machine learning*, Springer, v. 20, n. 3, p. 273–297.
- Economides, M. J., Nolte, K. G., et al. (1989), *Reservoir stimulation*, volume 2. Prentice Hall Englewood Cliffs, NJ.
- Gjørv, O. E. (2014). *Durability design of concrete structures in severe environments*. CRC Press.
- Gardner, M. W. and Dorling, S. (1998), *Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences*. *Atmospheric environment*, Elsevier, v. 32, n. 14-15, p. 2627–2636.
- Hu, X., Shi, Z., Shi, C., Wu, Z., Tong, B., Ou, Z., and De Schutter, G. (2017), Drying shrinkage and cracking resistance of concrete made with ternary cementitious components. *Construction and Building Materials*, 149:406–415.
- Montgomery, D.C. and Peck, E.A. and Vining, G.G. (2012), “*Introduction to Linear Regression Analysis*”, 5^o ed., Wiley.
- Portal Action. Disponível em: <http://www.portalaction.com.br/analise-de-regressao/16-coeficiente-de-determinacao>. Acesso em: 21 de junho de 2018.
- Tabachnick, B. G. and Fidell, L. S. (2007), *Using multivariate statistics*. [S.l.]: Allyn & Bacon/Pearson Education, 2007.
- Wang, W. and Xu, Z (2004), A heuristic training for support vector regression. *Neurocomputing*, Elsevier, v. 61, p. 259–275.
- Yeh, I. C. (1998), *Modeling of strength of high-performance concrete using artificial neural networks*. *Cement and Concrete research*, Elsevier, v. 28, n. 12, p. 1797-1808.

PREDICTING CONCRETE'S COMPRESSION RESISTENCE: A COMPARISON BETWEEN THREE REGRESSION METHODS

Abstract. *Concrete is the most important material in Civil Engineering and it is very important to know its strength to mixtures and under specific age (days). This paper proposes the creation and comparison of regression models that are capable of predicting concrete compressive strength. A database containing the components used in the making of concrete was used to adjust three regression models: Linear Regression, Multilayer Perceptron and Support Vector Regression. These models were tested considering the Mean Squared Error and the R^2 value. The Multilayer Perceptron and Support Vector Regression models achieved excellent performance compared to Linear Regression model. In addition, the highest R^2 value obtained by Multilayer Perceptron indicated that this method was able to better explain the observed values.*

Keywords: *Concrete compressive strength, Computational Intelligence, Linear Regression, Multilayer Perceptron, Support Vector Regression*