

PREDICTING THE CONCRETE COMPRESSION STRENGTH BY THE APPLICATION OF SUPPORT VECTOR MACHINES

Vanderci F. Arruda¹, Gray F. Moita¹, Priscila F. S. Silva¹.

¹*Programa de Pós-graduação em Modelagem Matemática e Computacional
Centro Federal de Educação Tecnológica de Minas Gerais*

Av. Amazonas, 5.253, Nova Suíça, 30.421-169, Belo Horizonte, MG, Brasil.

vanderci-engcivil@hotmail.com; gray@dppg.cefetmg.br; 201422800040@aluno.cefetmg.br.

Abstract. The compressive strength of concrete is one of the most used parameters in structural engineering. In this study, the concrete compression strength is characterized by the presence and quantification of the following components: cement, blast furnace slag, fly ash, water, superplasticizer content, coarse aggregate, fine aggregate and age. This resistance is usually defined through destructive experimental tests, a process that requires time and money. Another way to obtain this parameter is to rely on computational intelligence techniques, especially with the use of an intelligent system. This study proposes the determination of the compressive strength of concrete with a computer science concept entitled support vector machines (SVM). SVMs technique is a machine learning method that has been used for pattern recognition and regression analysis, which is the current case. The database used in the study is obtained from the established and widely used studies by Yeh [1]. As performance parameters of the method, MSE and R^2 are used. The main objective of this investigation is to obtain an analytical equation relating the constituents to the compressive strength of concrete by means of an intelligent system.

Keywords: Concrete Compression Strength; Intelligent Systems; Support Vector Machine; Mechanics of the materials; Artificial intelligence.

1 Introdução

Devido sua versatilidade, o uso do concreto é amplamente difundido. Sua utilização pode ser vista em casas, rodovias, edifícios, pontes, em obras de saneamento, dentre outros. De acordo com pesquisa realizada pela Associação Brasileira de Cimento Portland [2] é possível ver o crescimento do consumo do concreto ao longo dos anos observando o consumo do cimento, elemento fundamental de sua composição. O concreto depois de endurecido, tem sua resistência é similar a das rochas naturais e, quando fresco, sua modelagem pode ser feita nas mais diversas formas e tamanhos. Conforme Meyer [3], o concreto é uma mistura de água, cimento e agregados. Nessa mistura, o cimento tem a finalidade de unir os agregados, atuando como aglomerante. Segundo Chopra [4], a resistência e durabilidade do concreto depende da proporção dos materiais constituintes, sendo que a quantidade e a qualidade destes definem as propriedades mecânicas do concreto.

Uma das propriedades mecânicas mais importante do concreto é sua resistência à compressão. Este fator aumenta conforme a idade. Sendo assim, a resistência característica ideal à compressão do concreto (f_c) utilizada no cálculo estrutural é a alcançada aos 28 dias. Essa resistência pode ser definida através de ensaios experimentais e, na ausência destes, podem ser usados os valores definidos por meio da NBR 6118:2014 [5]. Conforme Chopra [6], uma abordagem tradicional utiliza os constituintes do concreto como parâmetros na modelagem de suas propriedades mecânicas como impermeabilidade, módulo de elasticidade e resistência a tração e a compressão.

Nesse trabalho foi utilizado um método de aprendizado de máquina no processo de determinação da resistência à compressão do concreto, o Método de Máquinas de Vetores de Suporte. A partir deste método, é possível o cálculo da resistência à compressão do concreto sem a necessidade de ensaios laboratoriais e

considerando as particularidades dos materiais (britas, areia e água, principalmente) é possível verificar a eficiência deste método a partir de parâmetros de performance.

2 Resistência a compressão do concreto

A resistência à compressão do concreto é obtida experimentalmente quando um corpo de prova atinge a tensão máxima, mesmo sem sinais visíveis de ruptura. O corpo de prova é considerado rompido quando não suportar uma carga maior, conforme Mehta [7]. A resistência à compressão do concreto é determinada no Brasil pela NBR 5739:2018 [8], que prescreve um método de ensaio para corpos de prova cilíndricos de concreto, sendo calculada segundo Equação (1):

$$f_c = \frac{4F}{\pi D^2} \quad (1)$$

em que, f_c é a resistência à compressão (MPa), F é a força máxima alcançada (N) e D é o diâmetro do corpo de prova (mm).

3 Conjunto de dados

Neste trabalho, a aquisição de dados foi possível a partir de uma pesquisa intensa em conjunto de dados disponíveis na literatura. Assim, optou-se pela utilização do conjunto de dados obtidos a partir de estudos feitos por Yeh [1]. Neste estudo, a tensão de compressão do concreto é caracterizada pelos seguintes componentes: teor de cimento, escória de alto forno, cinzas volantes, água, teor de superplastificante, quantidade de agregado graúdo, quantidade de agregado fino e idade.

Este conjunto de dados contém 1030 resultados de testes de resistência à compressão do concreto com base em diversas proporções de constituintes. Os atributos dos dados utilizados são explicitados na Tabela 3.1.

Tabela 3.1: Parâmetros dos atributos de entrada e saída do conjunto de dados

Atributos do modelo	Valores	
	Máximo	Mínimo
Cimento (kg/m ³)	540	102
Escória de alto forno (kg/m ³)	359,4	0
Cinzas volantes (kg/m ³)	200,1	0
Água (kg/m ³)	247	121,8
Superplastificante (kg/m ³)	32,2	0
Agregado graúdo (kg/m ³)	1145	801
Agregado fino (kg/m ³)	992,6	594
Idade (dias)	365	1
Resistência à compressão do concreto (MPa)	82,6	2,33

A seguir são apresentados, na Figura 3.1, os histogramas da distribuição de frequências e caixa de densidades do conjunto de dados de entrada e saída.

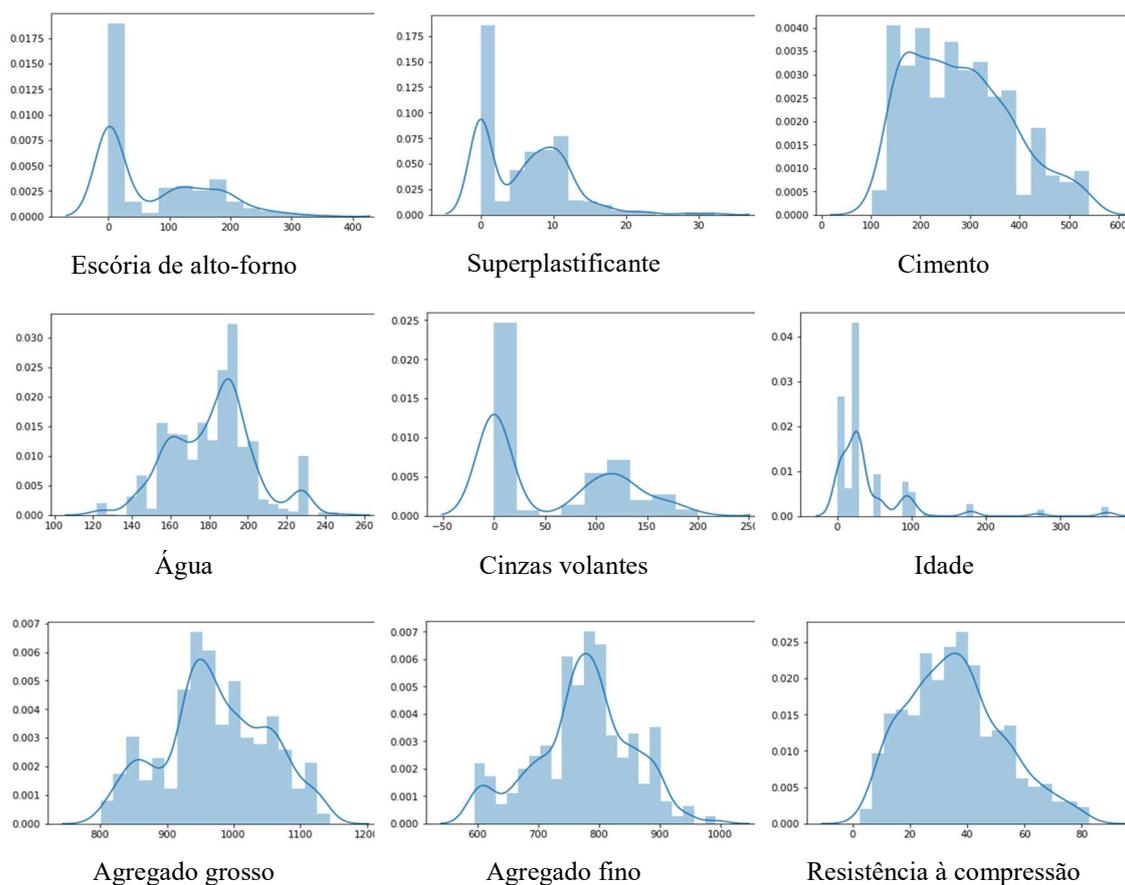


Figura.1: Histogramas e caixas de densidades para as variáveis da base de dados

Tem-se como parâmetro de entrada do modelo os constituintes do concreto e como parâmetro de saída é obtida a resistência a compressão do concreto.

3.1 Pré-processamento de dados

Os conjuntos de dados podem possuir valores que apresentam escalas diferentes, o que acarreta dificuldade para a visualização podendo piorar o desempenho preditivo de métodos computacionais. Dados não padronizados podem reduzir a velocidade da implementação ou mesmo impedir a convergência de estimadores [9].

Alguns modelos são construídos pela suposição de que seus parâmetros assumem valores próximos a zero, ou seja, em escalas comparáveis. Estimadores que utilizam métricas e gradiente assumem que os dados estejam padronizados [9]. Contudo, técnicas de pré-processamento se mostram eficazes e podem melhorar o desempenho de modelos computacionais.

Desta forma para padronizar os dados de entrada foi utilizado os seguintes métodos de pré-processamento de dados:

- StandardScaler
- Normalizer
- RobustScaler

4 Máquinas de Vetores Suporte

As Máquinas de Vetores de Suporte (SVMs) são uma técnica de aprendizado de máquina baseada na teoria de aprendizado estatístico, sua finalidade é obter uma classe de dados do mesmo domínio em que o aprendizado ocorreu. Conforme Lorena [10], as técnicas de aprendizado de máquina empregam um princípio denominado indução, onde é possível tirar conclusões genéricas a partir de um conjunto particular de exemplos. As SVMs podem obter resultados superiores aos obtidos por outros algoritmos de aprendizagem.

As SVMs são algoritmos de aprendizagem que funcionam em problemas de classificação e regressão. Além de realizar regressão linear e classificação, as SVMs também funcionam bem em dados não lineares [11]. No caso de classificação, nas SVMs o problema se reduz na obtenção de um hiperplano com a finalidade de maximizar a separação entre duas classes. Já a regressão de vetor de suporte (SVR) é uma técnica de regressão não paramétrica que depende exclusivamente de funções de kernel [12].

Os Kernel mais comumente usados são:

- Linear $K(X_i, Y_j) = X_i^T Y_j$
- Polinomial $K(X_i, Y_j) = [(X_i^T Y_j) + 1]^d$
- Função de base radial $K(X_i, Y_j) = e^{-\gamma |X_i - Y_j|^2}$
- Sigmoides $K(X_i, Y_j) = \tanh(\beta_0 X_i^T Y_j + \beta_1)$

No processo de regressão SVR, deve se encontrar um funcional f que possa realizar a tarefa de prever de forma assertiva dados não apresentados anteriormente.

Neste estudo serão utilizados como parâmetros de erro o erro quadrático médio (MSE) dado pela Equação (2), a raiz do erro quadrático médio conforme Equação (3) e o coeficiente de determinação (R^2) dado pela Equação (4):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2 \quad (2)$$

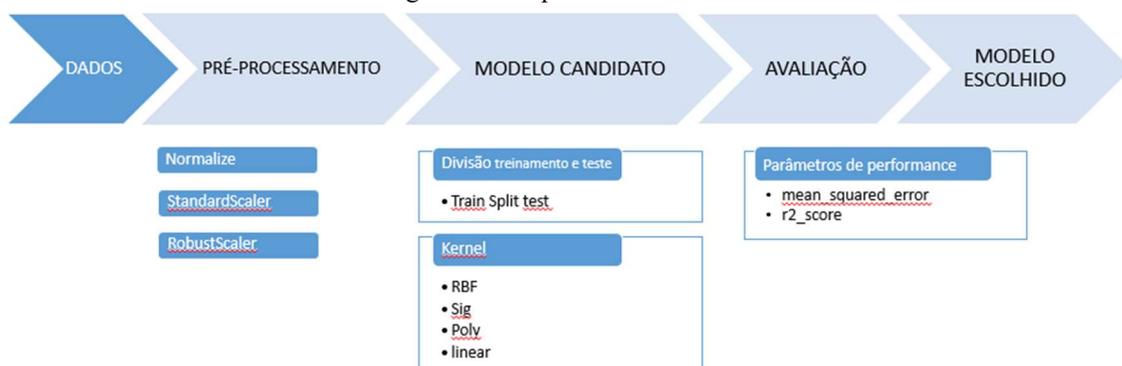
$$RMSE = \sqrt{MSE} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (4)$$

onde y_i é o valor observado, \bar{y} é a média das observações, \hat{y} é o valor previsto de y_i e N é o número total de amostras no conjunto de dados.

Na implementação do método de Máquinas de Vetores de Suporte seguiu o Fluxograma 1:

Fluxograma 1: Sequência do Método SVR



A sequência do estudo foi a seguinte: escolhido o conjunto de dados, optou-se por uma estratégia de pré-processamento (Normalize, StandardScaler e RobustScaler) utilizando como o método de divisão de treinamento e teste o Train Split Test. Com o uso de distintos Kernel, foi medida a qualidade destes através dos parâmetros de performance (mean squared error, R^2) com os resultados apresentados na Tabela 5.2.

5 Resultados e Análise

No uso de técnicas de aprendizado de máquina, como o SVR, é primordial a escolha de melhores parâmetros a serem utilizados na implementação. No presente trabalho, o método de GridSearchCV foi empregado para auxiliar na escolha. Assim, uma vez definida a estratégia de pré-processamento e o Kernel, faz-se o uso do GridSearchCV para a escolha dos melhores parâmetros para o modelo. A saída do GridSearchCV define os parâmetros “ótimos” para cada Kernel e a implementação com tais parâmetros resulta nas melhores entradas para o método. Os parâmetros de entrada do GridSearchCV estão colocados na Tabela 5.1, sendo possível verificar os que obtiveram o melhor desempenho na mesma Tabela.

Tabela 5.1: Parâmetros de entrada do GridSearchCV

Kernel	Parâmetros				Escolhido
	RBF	Poly	Linear	Sigmoide	RBF
C	1_1000	1_1000	1_1000	1_1000	1000
Degree	-	2_5	-	-	-
Epsilon	0.1_1	0.1_1	0.1_1	0.1_1	0.1
Gamma	scale/auto	scale/auto	scale/auto	scale/auto	scale

Os resultados obtidos das implementações são descritos na Tabela 5.2.

Tabela 5.2: Resultados do SVR com tipo de pré-processamento e kernel distintos

Tipo de pré-processamento	Standard Scaler	Kernel	RBF	LIN	POLY	SIG
		MSE	35,76	123,75	54,24	162,55
		RMSE	5,98	11,12	7,36	12,75
		R^2	0,89	0,62	0,83	0,50
	Normalizer	Kernel	RBF	LIN	POLY	SIG
		MSE	37,78	113,32	58,70	136,18
		RMSE	6,15	10,65	7,66	11,67
		R^2	0,88	0,65	0,82	0,58
	Robust Scaler	Kernel	RBF	LIN	POLY	SIG
		MSE	58,03	113,89	75,26	193,65
		RMSE	7,62	10,67	8,68	13,92
		R^2	0,82	0,65	0,77	0,40

O uso da técnica de aprendizado de máquina SVR se mostrou eficaz na previsão da resistência à compressão do concreto. A partir da Tabela 5.2, é possível verificar que a estratégia de pré-processamento não resultou em melhoria significativa nos parâmetros de performance (MSE, RMSE, R^2). Dentre os resultados obtidos, a estratégia de pré-processamento que resultou em melhores parâmetros de performance foi o StandardScaler com o Kernel função de base radial, obtendo o RMSE de 5,98 MPa e o coeficiente de determinação de 0,89.

A Figura 5.1 mostra os targets e os valores previstos pela melhor implementação SVR.

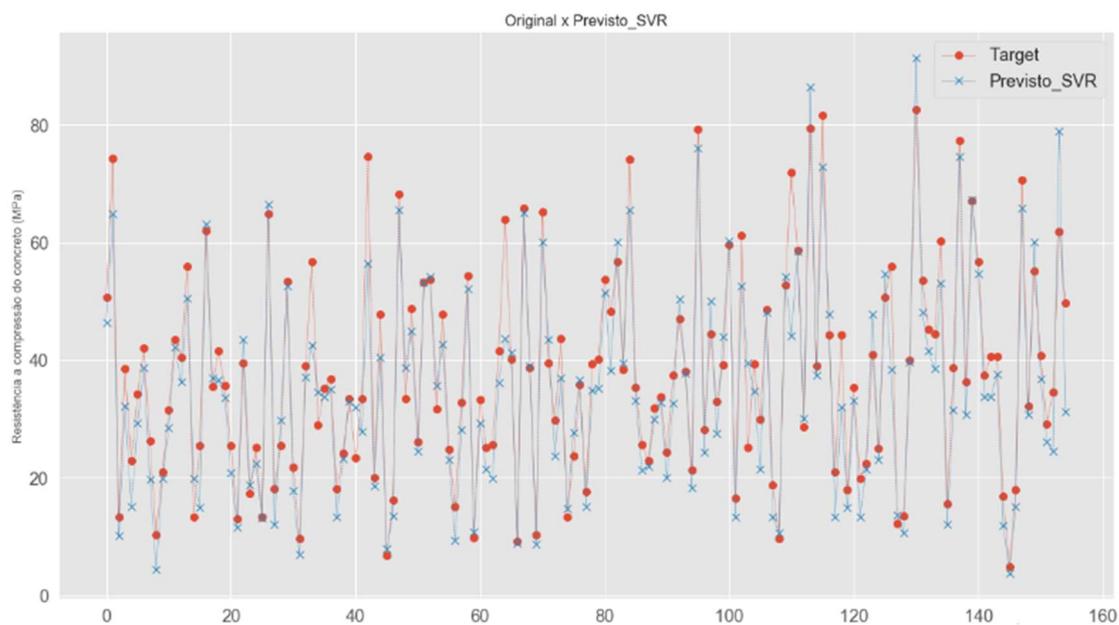


Figure 5.1: Target e Previsto SVR

Na Tabela 5.3 é possível verificar resultados dos parâmetros de performance em estudos que utilizaram o mesmo conjunto de dados de Yeh [1]. Estes estudos utilizaram os algoritmos SVM e ANN.

Tabela 5.3: Comparação com os resultados para o mesmo conjunto de dados em estudos anteriores

Pesquisa	Algoritmo	R ²	RMSE (MPa)
Yeh [1]	ANN	0,91	-
Chou et al. [13]	ANN	0,88	-
	SVM	0,91	-
Chou et al. [14]	ANN	-	7,90
	SVM	-	5,50
Young et al. [15]	ANN	0,82	6,30
	SVM	0,83	6,40
Nessa pesquisa	SVM	0,89	5,98

Conforme os valores apresentados na Tabela 5.3, é possível concluir que os resultados obtidos nesta pesquisa são consistentes com os encontrados na literatura explicitada. De outra maneira, comparado os resultados do coeficiente de determinação e do RMSE verifica-se que o estudo apresenta o segundo melhor valor de ambos os parâmetros.

6 Conclusão

Neste trabalho, o uso de inteligência computacional e, em especial, de uma técnica de aprendizado de máquina na determinação da resistência a compressão do concreto se mostrou eficaz. A partir de uma base de dados obtida e consagrada da literatura foi possível a realização da previsão da resistência compressão do concreto sem que fosse necessário o uso de ensaios laboratoriais.

O SVM utilizou três estratégias de pré-processamento de dados para melhorar os resultados. Também foi utilizado o GridSearchCV com a finalidade de encontrar os melhores parâmetros de desempenho deste método. No final, o método utilizado apresentou resultados compatíveis com resultados obtidos em estudos anteriores. O melhor resultado do presente estudo utilizou como estratégia de pré-processamento o

StandardScaler com o Kernel a função de base radial, obtendo o RMSE de 5,98 MPa e o coeficiente de determinação de 0,89.

Comparando os parâmetros de performance do método utilizado neste estudo com as ANNs de trabalhos anteriores, é possível concluir que foram obtidos parâmetros de performance superiores aos dos demais estudos citados. Com relação às SVMs de estudos prévios, o presente trabalho apresentou o segundo melhor resultado.

A partir dos parâmetros obtidos nesta implementação é possível concluir que o método utilizado pode prever de forma assertiva a resistência à compressão do concreto, tendo um coeficiente de desempenho confiável levando-se em consideração os critérios de segurança de engenharia.

7 Agradecimentos

CAPES e CEFET-MG apoiaram os trabalhos descritos neste artigo.

References

- [1] I.-C. Yeh. “Modeling of strength of high-performance concrete using artificial neural networks”. *Cement and Concrete Research*, Vol. 28, No. 12, pp. 1797–1808, 1998.
- [2] Associação Brasileira de Cimento Portland, “Pesquisa inédita e exclusiva revela cenário do mercado brasileiro de concreto”. Disponível em: <<https://abcp.org.br/imprensa/noticias/pesquisa-inedita-e-exclusiva-revela-cenario-do-mercado-brasileiro-de-concreto>>. Acesso em: 13/08/2020.
- [3] C. Meyer. “The greening of the concrete industry”. *Cement and concrete composites*, v. 31, n. 8, p. 601-605, 2009.
- [4] P. Chopra, R. K. Sharma, M. Kumar. “Prediction of compressive strength of concrete using artificial neural network and genetic programming”. *Advances in Materials Science and Engineering*, v. 2016, 2016.
- [5] ABNT, NBR. 6118. “*Design of concrete structures: procedure*”, Rio de Janeiro, Brazil, 2014.
- [6] P. Chopra, R. K. Sharma, M. Kumar. “Regression models for the prediction of compressive strength of concrete with & without fly ash”. *International Journal of Latest Trends in Engineering and Technology (IJLTET)*, v. 3, n. 4, p. 400-406, 2014.
- [7] P. K. Mehta, P. J. M. Monteiro, P. H. Mehta, P. H. Mehta. *Concreto, microestrutura, propriedades e materiais*. 2008.
- [8] ABNT, NBR. 5739. “Concreto—Ensaio de compressão de corpos-de-prova cilíndricos”. Rio de Janeiro, 2018.
- [9] L. Wang, G. Wang, C. A. Alexander, “Big data and visualization: methods, challenges and technology progress”. *Digital Technologies*, v. 1, n. 1, p. 33–38, 2015.
- [10] A. C. Lorena, A. De Carvalho, “Uma introdução as support vector machines”. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43-67, 2007.
- [11] C.-F. Lin, S. D. Wang, “Fuzzy support vector machines”. *IEEE transactions on neural networks*, v. 13, n. 2, p. 464–471, 2002.
- [12] H. Drucker, H. et al. “Support vector regression machines”. 1997, [S.l: s.n.], 1997. p. 155–161.
- [13] J. Chou, C. Chiu, M. Farfoura, I. Al-taharwa. “Optimizing the prediction accuracy of concrete compressive strength based on a comparison of data-mining techniques”. *J. Comput. Civ. Eng.*, 25(3). 2011.
- [14] J. S, Chou, C. F. Tsai, A. D. Pham, Y. H. Lu. “Machine learning in concrete strength simulations: Multi-nation data analytics”. *Constr. Build. Mater.*, 73:771–780, 2014.
- [15] B. A. Young, A. Hall, L. Pilon, P. Gupta, G. Sant. “Can the compressive strength of concrete be estimated from knowledge of the mixture proportions?: New insights from statistical analysis and machine learning methods.” *Cem. Concr. Res.*, 115:379–388, 2019.