

REVISTA AIDIS

de Ingeniería y Ciencias Ambientales:
Investigación, desarrollo y práctica.

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA PREVISÃO DA RESISTÊNCIA À COMPRESSÃO DE CONCRETOS PRODUZIDOS COM AGREGADOS RECICLADOS

André Aparecido de Moraes¹

* Danilo Pereira dos Santos¹

APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN THE PREDICTION OF COMPRESSION STRENGTH OF CONCRETE PRODUCED WITH RECYCLED AGGREGATES

Recibido el 19 de enero de 2022. Aceptado el 8 de agosto de 2022

Abstract

Due to the growth of civil construction, an increase in the levels of generation of construction waste was observed, which caused significant environmental impacts. Thus, the use of recycled aggregates that present valid technical aspects have been highlighted for being considered a sustainable means for the conservation of natural resources. However, since it involves aggregates with characteristics different from the natural, it is necessary to adapt the models to predict the concrete strength. In this sense, the use of Artificial Neural Networks (ANNs), which are mathematical models capable of recognizing patterns through numerical training, is a valuable alternative. Nevertheless, due to the variability of materials, the challenge of obtaining satisfactory results with a reduced database is imposed. Therefore, to achieve this aim, it was necessary to survey a plural database with recycled concrete from different papers to drive the neural network to the desired degree of generalization. Finally, an ANN architecture capable of predicting the final strength of concrete with acceptable accuracy was proposed. The results obtained were promising, so that the proposed architecture, trained with the selected database, presented results with an average deviation of approximately 3 MPa for the set of validation samples.

Keywords: solid waste, recycling, recycled concrete, compressive strength, artificial neural networks.

¹ Departamento de Engenharia Civil da FHO (Fundação Hermínio Ometto), Brasil.

*Autor correspondente: Departamento de Engenharia Civil da FHO (Fundação Hermínio Ometto). Av. Dr. Maximiliano Baruto, 500 - Jardim Universitário, Araras - SP, 13607-339. Email: danielopereira.eng@live.com

Resumo

Com o crescimento do setor da construção civil, foi observado um aumento considerável dos níveis de geração de resíduos da construção e demolição (RCD), que causam grandes impactos ambientais, ficando evidente a necessidade de soluções para modificação desse cenário. Assim, o emprego de agregados reciclados (AR) provenientes dos RCDs que apresentem aspectos técnicos para sua utilização, de forma a garantir resistência ao novo concreto produzido, vem se destacando por ser considerado um meio sustentável para conservação dos recursos naturais. Entretanto, por se tratar da incorporação de agregados com características distintas do natural, e grande variabilidade, faz-se necessário adequar os modelos para previsão de resistência do concreto curado. Neste sentido, a utilização de Redes Neurais Artificiais (RNAs), que são modelos matemáticos capazes de reconhecer padrões através do treinamento numérico, se colocam como valiosa alternativa para um método de previsão da resistência à compressão de espécimes de concretos com agregados reciclados. Entretanto, em função da variabilidade dos materiais o desafio de se obter resultados satisfatórios com um banco de dados reduzido se impõe. Portanto, para alcançar tal objetivo, foi necessário o levantamento de uma base de dados plural com concretos reciclados de diferentes origens de modo a conduzir a rede neural ao grau de generalização desejado. Por fim, foi proposta uma arquitetura de RNA capaz de prever a resistência final do concreto com precisão aceitável. Os resultados obtidos foram promissores, de modo que a arquitetura proposta, treinada com o banco de dados selecionado, apresentou resultados com um desvio médio de aproximadamente 3 MPa quando comparada ao conjunto de amostras de validação.

Palavras-chave: resíduos sólidos, reciclagem, concretos reciclados, resistência à compressão, redes neurais artificiais.

Introdução

A indústria da construção civil se destaca no cenário mundial pelo seu potencial de crescimento e geração de vagas de emprego para grande parcela da população. Por outro lado, nesse crescimento é observado um aumento considerável dos índices de consumo de matérias-primas naturais e do nível de geração de resíduos da construção e demolição (RCD), que muitas vezes tem seu descarte em lugares inadequados dos centros urbanos (Ossa; García; Botero, 2016; Santos; Frantz; Masuero, 2021).

Segundo a Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais (2020) os RCDs coletados pelos municípios apresentaram um aumento significativo, passando de 33 milhões de toneladas, em 2010, para 44.5 milhões de toneladas, em 2019. Portanto, fica evidente a necessidade de se pensar em soluções para modificar esse contexto que cada vez mais contribui para os impactos ao meio ambiente. Desta forma, diversos trabalhos têm se empenhado em avaliar os impactos dessa geração, ferramentas de gestão e destinação destes resíduos (Castro *et al.*, 2021; Rodrigues Lima e Carvalho Júnior, 2019; Urban e Isaac, 2018, Angulo *et al.*, 2011).

Além disso, outras aplicações que se utilizam de resíduos industriais podem não só contribuir para gestão ambiental como atribuir novas características e/ou melhoramento ao concreto dosado. Este é o caso da aplicação resíduo da indústria de cerâmica vermelha estudado por Santos *et al.*

(2018) e Castro *et al.* (2017). Portanto, os benefícios advindos do estudo e aplicação de resíduos podem vir a abarcar não só uma melhor disposição final do material, mas também uma melhoria das propriedades do concreto dosado.

O emprego de agregados reciclados (AR) provenientes dos RCDs para a produção de concreto vem se destacando na indústria da construção civil, por ser considerado um importante minimizador dos impactos ambientais e consequente otimizador dos recursos naturais.

O concreto produzido com AR consiste na substituição total ou parcial dos agregados naturais pelos reciclados. Segundo a ABNT NBR 15116:2004 (Agregados Reciclados de Resíduos Sólidos da Construção Civil), o agregado reciclado pode ser caracterizado como o material granular oriundo de construções ou demolições de obras civis, que apresentem aspectos técnicos para sua aplicabilidade, garantindo assim, resistência ao concreto. Este texto normativo também classifica os agregados reciclados em dois grupos, sendo o primeiro o dos agregados de resíduos de concreto (ARC), que são compostos de no mínimo 90% em massa de fragmentos à base de cimento Portland e rochas; e o segundo, dos agregados de resíduos mistos (ARM) que em sua composição é observado menos de 90% de fragmentos à base de cimento Portland e rochas.

Dentre as propriedades do concreto reciclado no estado fresco, a trabalhabilidade é uma das mais afetadas pela empregabilidade dos AR, isso se explica pela forma irregular e textura áspera dos agregados e principalmente pela elevada taxa de absorção de água dos AR, que se justifica pelo alto índice de porosidade dos mesmos (Leite, 2001). Assim, durante a produção de concreto com agregados reciclados, medidas como a pré-saturação dos AR e a utilização de aditivos superplastificante, que minimizam o transporte interno de água da pasta de cimento para os agregados, são práticas que melhoram a trabalhabilidade do concreto (Quebaud; *et al.*, 1999; Pietersen; Fraay; Hendriks, 1998).

Já referente a propriedade no estado endurecido, especificamente em relação a resistência mecânica, pode-se afirmar que o concreto reciclado apresenta características que variam mais em relação ao convencional, pois além das variações associadas ao consumo de aglomerante e a relação água/cimento, também existem as alterações relacionadas com a composição e características físico-químicas dos AR (Lima, 1999). Ainda segundo Lima (1999), mesmo com todos esses fatores, ainda é possível obter concretos produzidos com agregados reciclados para diversas destinações dentro do setor da construção civil, desde que se tenha cautela nas escolhas, classificação, separação, qualidade e adoção de procedimentos corretos de aplicação para o agregado reciclado e consequentemente para o novo concreto produzido.

Desta forma, pesquisadores tem se dedicado a investigar o desempenho dos concretos com agregados reciclados do ponto de vista do seu desempenho mecânico. Por exemplo, os estudos

conduzidos por da Silva *et al.* (2021) e da Silva e Oliveira Andrade (2017) exploraram concretos com diferentes teores de agregados reciclados e relação água/cimento e determinaram correlações entre os traços e as propriedades alcançadas.

Diante disso, a proposição de modelos matemáticos, analíticos ou numéricos, que consigam prever algumas das características mecânicas dos concretos com agregados reciclados é de interesse prático e acadêmico, na medida em que contribuirão na previsibilidade do uso de algumas misturas.

Em função da acentuada não-linearidade envolvida nas relações entre constituintes e resistência do concreto dosado (Viana Neto *et al.*, 2018), o uso de Redes Neurais Artificiais (RNAs), que são modelos matemáticos inspirados nas estruturas neurais de organismos inteligentes, capazes de adquirir conhecimento e reconhecer padrões através do treinamento computacional, torna-se uma opção atrativa para realizar previsões de resistência de uma dosagem (Fleck *et al.*, 2016).

A aplicação de RNAs na previsão do comportamento físico e mecânico de espécimes de concreto tem sido um campo de acentuadas pesquisas (Araujo *et al.* 2016, Frotté *et al.* 2017, Tavares *et al.* 2020, Rocha *et al.* 2020, Felix *et al.*, 2021). Todas estas pesquisas têm sido exitosas, pois, conforme afirma Almeida (1995), a rede neural é capaz de ler todo um conjunto de amostras fornecido por uma base de dados, de modo que quanto maior o grau de aprendizado da rede e variabilidade dos conjuntos amostrados, melhores são os resultados apresentados por ela.

Portanto, este trabalho propõe uma arquitetura de rede neural capaz de prever com suficiente precisão a resistência de um espécime de concreto reciclado, ainda que treinada com um número limitado de amostras. Para isto foi realizado um levantamento bibliográfico com concreto reciclados de diferentes origens, na busca de informações que constituíssem um banco de dados adequado.

Materiais e métodos

Para a construção do modelo de predição da resistência à compressão de concretos produzidos com agregados reciclados, foi construída uma RNA por meio dos recursos disponibilizados pelo TensorFlow[®], uma biblioteca com recursos dedicados ao aprendizado de máquina desenvolvida para aplicações em Python[®].

Nesta seção do artigo serão apresentadas as características básicas de uma rede neural, a estratégia para treinamento da rede e a arquitetura que produziu os melhores resultados nesta pesquisa. Todos os dados estão cuidadosamente descritos e a base de dados construída está disponibilizada no Apêndice A para permitir a reprodutibilidade da pesquisa.

Rede neural artificial: visão geral

As redes neurais artificiais (RNAs) são algoritmos computacionais que apresentam um modelo matemático que busca trabalhar no processamento de dados, semelhante ao cérebro humano que organiza seus neurônios de forma a realizarem o processamento das informações. Posto isto, a RNA pode ser entendida como um modelo capaz de armazenar conhecimento através da aprendizagem e assim disponibilizar resultados para a aplicabilidade a qual se destina (Spörl *et al.*, 2011; Dacoregio, 2017).

O neurônio artificial é uma unidade fundamental na base do projeto de uma rede neural artificial, o qual recebe um determinado número de dados de entrada e os transforma em saídas previstas. O esquema de um neurônio artificial pode ser entendido na [Figura 1](#).

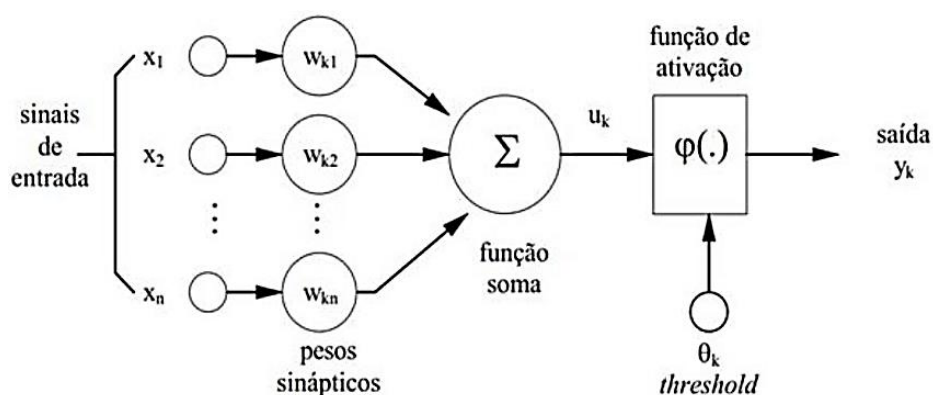


Figura 1. Representação esquemática de um neurônio artificial. Fonte: Adaptado de Haykin (1994)

Com base na Figura 1, é possível destacar alguns elementos fundamentais na estrutura de um neurônio artificial (Bocanegra, 2002):

- Peso sináptico (W_{kj}) que é um multiplicador do sinal X_j na entrada da sinapse j (1,2,3, ..., n), conectada a um neurônio k ;
- Um somatório que consiste num combinador linear das entradas ponderadas pelos seus respectivos pesos, ou seja:

$$u_k = \sum_{j=1}^n W_{kj} \cdot X_j$$

Equação 1

- Função de ativação que trabalha como um limitante na amplitude da saída do neurônio;
- E a saída do neurônio, Y_k , que é descrita pela seguinte função, onde φ é a função de ativação:

$$Y_k = \varphi(U_k - \theta_k)$$

Equação 2

Várias funções de ativação não lineares podem ser empregadas na construção da rede neural, dentre elas destacam-se as funções Sigmoides, muito utilizadas para produzir probabilidades em problemas de classificações, a ReLu que pode ser considerada uma das mais utilizadas nas camadas ocultas durante o treinamento de redes neurais, e a Linear que apresenta um bom desempenho quando empregada na camada de saída dos problemas de regressão, uma vez que fornece resultados em todo o domínio dos números reais.

Conforme descrito por Bocanegra (2002), o processo de aprendizagem da rede neural pode ser caracterizado como a aplicação contínua de vetores de entrada que, de forma simultânea, servem de parâmetros para o ajuste dos pesos sinápticos conforme o treinamento de modo que os dados de entrada sejam processados pela rede e convirjam em valores de saída. Portanto, o aprendizado da rede é atingido pelas alterações nos pesos sinápticos das interconexões e não pelas modificações feitas nos neurônios (Rezende, 2003).

Os procedimentos de treinamento podem ser divididos em duas classes, os não supervisionados e os supervisionados. Explanando o treinamento supervisionado, utilizado na construção da rede deste trabalho, evidencia-se que é necessário a inserção do conjunto de dados de entrada para que a rede calcule a saída prevista e a compare com a saída dos valores alvo, gerando um sinal de erro. Este erro é reinserido à rede, ocasionando o ajuste dos pesos de acordo com o algoritmo de treinamento utilizado para minimizar o mesmo. Esse processo é iterado várias vezes até os valores previstos apresentarem baixos níveis de erro em relação aos valores alvo (Haykin, 2001; Bocanegra, 2002).

Existe uma grande variedade de algoritmos de treinamento, tanto para o método supervisionado quanto para o não supervisionado. Contudo, um dos algoritmos mais difundidos e utilizados é o da “retropropagação do erro” (*backpropagation*), por sua capacidade de corrigir o erro durante o treinamento.

Em resumo, o processo pode ser dividido em duas etapas, a primeira é a “propagação adiante” (*feedforward*) dos dados de entrada pela rede, passando de camada para camada até gerar um conjunto de saídas, vale ressaltar que durante esse procedimento os pesos sinápticos são mantidos fixos. Já a segunda etapa consiste na então “retropropagação do erro”, onde os pesos sinápticos são ajustados de trás para frente de acordo com a regra da correção, e isso é evidenciado pelo fato da resposta fornecida pela rede ser subtraída da resposta desejada, gerando o sinal de erro, que por sua vez é propagado da saída em direção a entrada da rede. Assim, os pesos são corrigidos de forma a minimizar a distância entre as duas respostas (Medeiros, 2016; Bocanegra, 2002).

Levantamento da base de dados para treinamento da rede

A etapa de construção da base de dados para treinamento da rede neural é fundamental para que a rede neural seja validada e apresente bons índices de aprendizado após o seu treinamento. Portanto, este levantamento de dados, levou em consideração o concreto produzido por diferentes pesquisadores correlacionando as informações pertinentes às proporções do traço do concreto, à relação água/cimento, ao *slump*, à massa específica dos agregados utilizados e à resistência à compressão aos 28 dias.

Ainda no processo de coleta dos dados, houve a necessidade de padronizar os traços de concreto pelo fato de alguns estarem na proporção unitária e outros em quilogramas para obtenção de 1 m³ de concreto.

Em função da grande variabilidade nos traços de concreto reciclado, um dos desafios dessa pesquisa foi a construção de um banco de dados, de tamanho reduzido, entretanto que conseguisse cobrir uma gama suficiente de diferentes traços que conferisse à rede neural o grau de generalização desejado.

Com este objetivo delimitado foram selecionados na literatura um total de 186 amostras de concretos produzidos com agregados reciclados de variadas origens. Tal levantamento consta no Apêndice A desta publicação.

Determinação da arquitetura adequada para a rede neural

Diferentes arquiteturas de RNAs foram testadas até que se alcançasse uma capaz de entregar resultados satisfatórios. Em diferentes oportunidades as funções de ativações foram reavaliadas, bem como o número de camadas e o número de neurônios em cada uma delas. Portanto, neste item será apresentada a rede neural de melhor desempenho dentre as avaliadas.

A arquitetura proposta para a construção da RNA incluiu 11 neurônios na camada de entrada, tornando possível que as seguintes informações pudessem ser avaliadas pela rede:

- Proporção de cimento;
- Agregado miúdo natural;
- Agregado miúdo reciclado;
- Agregado graúdo natural;
- Agregado graúdo reciclado;
- Relação água/cimento;
- Abatimento do concreto em milímetros (*slump*);
- Massa específica do agregado miúdo natural (g/cm³);

- Massa específica do agregado miúdo reciclado (g/cm^3);
- Massa específica do agregado graúdo natural (g/cm^3);
- Massa específica do agregado graúdo reciclado (g/cm^3).

Após a camada de entrada, quatro camadas ocultas foram construídas. A primeira camada foi dotada de 100 neurônios e as demais com 120 neurônios cada. Por fim, uma camada de saída com 1 neurônio foi determinada para que a resposta final da rede fosse tratada. A

Figura 2 é uma representação esquemática da rede, entretanto, há de salientar que todos os neurônios da camada de entrada são conectados a todos os neurônios da camada oculta do mesmo modo que todos os neurônios das camadas ocultas se interconectam entre si.

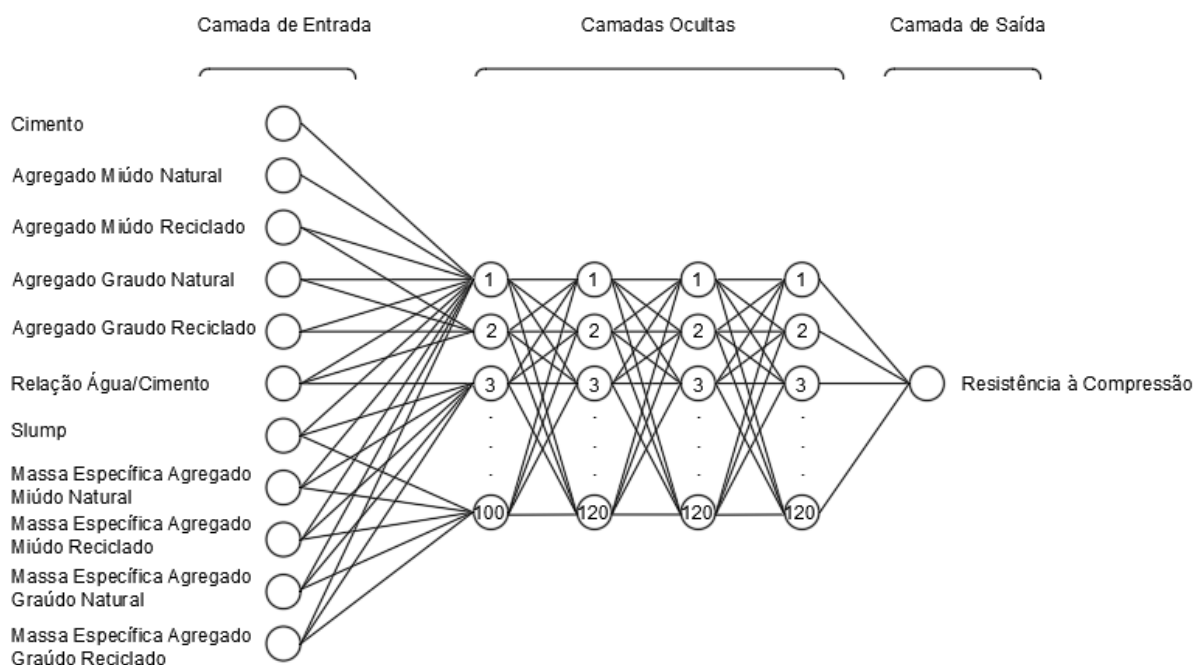


Figura 2. Arquitetura proposta para a rede neural artificial

Definiu-se que o algoritmo de “retropropagação do erro” foi o mais adequado para orientar o processo de treinamento pela sua capacidade de correção das imprecisões durante o procedimento. Portanto, foi estabelecido que o treinamento seria do tipo supervisionado, pois

um conjunto de resultados esperados foi fornecido a rede que por sua vez calculou o erro entre o resultado previsto e o esperado. Delimitou-se também, um número de 550 iterações (épocas), que representa a quantidade de vezes que se repete este processo de treinamento para aperfeiçoamento da rede.

Na sequência, o conjunto de 186 amostras de concreto produzidos com agregados reciclados foi dividido em dois subconjuntos: um com 160 amostras para dados de treino e outro com 26 amostras para dados de validação da rede. Esta divisão foi conduzida de modo a mesclar amostras de todos os artigos selecionados, de modo que a generalização procurada na seleção do grupo total de amostras se mantivesse nos grupos de treinamento e validação.

Deste modo, o subconjunto de 160 amostras de treinamento foi inserido na RNA, contendo tanto os dados de entrada como também os dados de saída; para que a rede fosse capaz de prever os resultados, comparar com as resistências esperadas e corrigir os pesos. Por fim, o conjunto de 26 amostras de validação foi apresentado à rede.

Para avaliar o desempenho da RNA, utilizou-se o “erro médio quadrático” (MSE, *Mean Squared Error*), assim quanto menor o erro encontrado, melhor será a estimativa do modelo utilizado. Esse valor é determinado através da Equação 3.

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}_i)^2$$

Equação 3

Onde:

N = Número de amostras;

x_i = Valores previstos;

\bar{x}_i = Valores esperados.

Por meio do emprego desse método foi possível monitorar o comportamento de todo o sistema ao invés de inspecionar apenas um grupo de dados fornecido pela rede. Esta abordagem torna mais objetiva as definições dos números de camadas, de neurônios e de épocas utilizadas no processo de treinamento.

Resultados e discussões

A avaliação do desempenho da rede proposta foi realizada por meio do cálculo do MSE. A primeira verificação disse respeito ao conjunto de amostras de treinamento, isto é, das 160 amostras separadas para esta finalidade.

Por fim, o conjunto de 26 amostras, que foram anteriormente separados para verificar a capacidade de predição da RNA, foram utilizados. O resultado para estas amostras está reproduzido na Figura 3, que apresenta as resistências reais, extraídas de ensaios experimentais da literatura, e as resistências estimadas pela RNA.

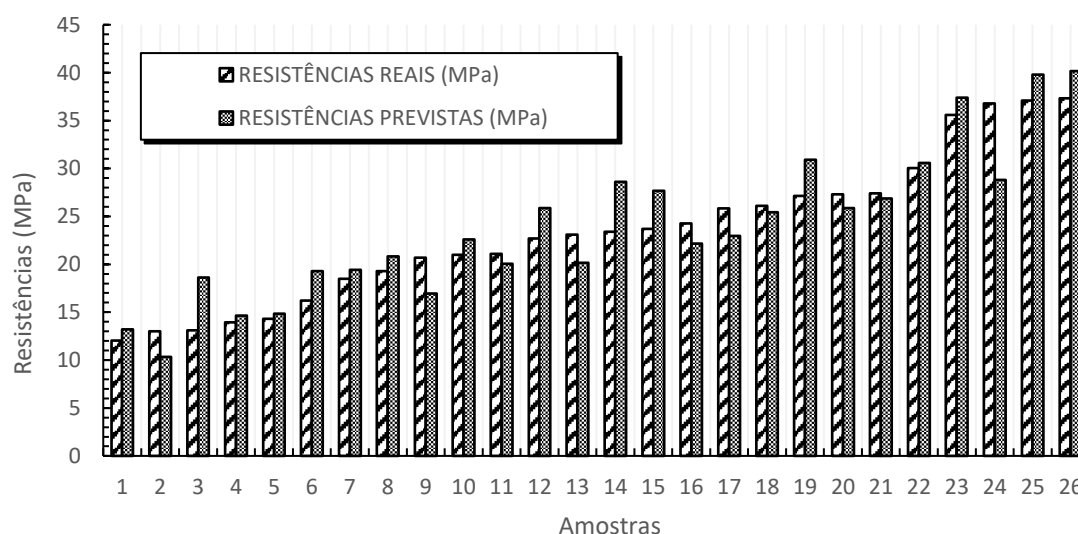


Figura 3. Comparação entre os resultados estimados pela RNA e os valores reais.

Para permitir a verificação do desempenho da rede, os resultados da **Figura 3** também estão dispostos na Tabela , de modo que é possível notar os pequenos desvios entre os valores experimentais e os preditos por ela.

Portanto, observa-se que a exceção das amostras de nº 3, 14 e 24, todas as demais apresentaram um desvio absoluto abaixo dos 2 MPa, o que representa um resultado muito promissor, sobretudo dada as incertezas relacionadas à dosagem de concretos.

Para uma métrica geral, foi calculado o MSE sobre este conjunto de resultados, o que resultou em um erro médio quadrático igual a 9.40, correspondendo a um desvio de 3.07 MPa. Assim, há de ser salientado que a variabilidade das amostras não impediu que a rede neural atingisse um desempenho satisfatório na previsão das resistências.

Tabela 1. Comparação das resistências estimadas pela RNA e seus respectivos valores reais.

Número da Amostra	Resistência Real (MPa)	Resistência Estimada (MPa)	Desvio Absoluto (MPa)
1	12.05	13.20	0.58
2	13.02	10.35	1.34
3	13.10	18.63	2.76
4	13.93	14.64	0.35
5	14.30	14.85	0.28
6	16.20	19.29	1.55
7	18.50	19.41	0.45
8	19.29	20.83	0.77
9	20.70	16.96	1.87
10	21.00	22.59	0.79
11	21.10	20.06	0.52
12	22.70	25.88	1.59
13	23.10	20.15	1.48
14	23.40	28.61	2.61
15	23.70	27.67	1.99
16	24.25	22.16	1.05
17	25.84	22.96	1.44
18	26.10	25.43	0.34
19	27.12	30.91	1.90
20	27.30	25.86	0.72
21	27.40	26.88	0.26
22	30.04	30.57	0.27
23	35.60	37.38	0.89
24	36.80	28.81	3.99
25	37.10	39.78	1.34
26	37.32	40.15	1.41

Conclusões

Este trabalho objetivou a construção de uma rede neural treinada com um banco de dados com suficiente variedade de amostras capaz de prever com precisão aceitável a resistência de concretos reciclados.

O modelo de rede proposto obteve um desempenho adequado na previsão da resistência dos concretos reciclados. Quando o estudo avaliou amostras inéditas, isto é, amostras não empregadas no conjunto de treinamento, a rede neural obteve um MSE igual a 9.40. Portanto, a respeito dos bons resultados apresentados pela rede, há de se destacar que, embora o desvio médio tenha ficado na ordem dos 3 MPa, o maior desvio absoluto registrado em todas as análises de validação foi de 3.99 MPa. Tal resultado indica, de fato, o bom desempenho da metodologia.

Os resultados obtidos demonstraram que um banco de dados com boa variedade de exemplares é capaz de auxiliar a rede na aquisição da generalização desejada, ainda que o número de exemplares não seja extenso. Tal conclusão deve ser levada em consideração na realização de estudos futuros que pretendam expandir a base de dados empregada, de modo que tal expansão deve, na medida do possível, guardar o grau de variedade apresentado nesta pesquisa.

Há de se destacar que as variadas origens dos agregados reciclados consistem em um complicador ao desempenho de RNAs. Esta dificuldade foi minorada nesta pesquisa ao incluir a massa específica destes agregados nos vetores de entrada da rede neural. Todavia, pesquisas futuras podem se lançar ao estudo de agregados reciclados de determinada origem, que seja mais comum à região de interesse. Uma abordagem dessa natureza tem o potencial de conduzir a melhores resultados em seu universo de aplicação.

Por fim, a realização deste trabalho indicou que a utilização de Redes Neurais Artificiais para previsão da resistência à compressão de concretos produzidos com ARs se mostra como uma alternativa viável. Tal constatação fornece mais uma valiosa ferramenta para o estudo e uso do concreto reciclado contribuindo para a sua popularização.

Referências bibliográficas

- Associação Brasileira de Normas Técnicas. (2004) *NBR 15116: Agregados reciclados de resíduos sólidos da construção civil: Utilização em pavimentação e preparo de concreto sem função estrutural: Requisitos*. Rio de Janeiro: ABNT, p. 12.
- Almeida, F. C. (1995) Desenvolvendo o uso de redes neurais em problemas de administração de empresas: Uma visão geral do potencial e do funcionamento do uso de redes neurais em administração, através de exemplos e ilustrações mais acessíveis ao leitor não-familiarizado com conceitos de informática. São Paulo: *Revista de Administração de Empresas*, 35(1), 46-55. <https://doi.org/10.1590/S0034-75901995000100007>
- Angulo, S. C., Teixeira, C. E., Castro, A. L. D., Nogueira, T. P. (2011). Resíduos de construção e demolição: avaliação de métodos de quantificação. *Engenharia Sanitária e Ambiental*, 16, 299-306. <https://doi.org/10.1590/S1413-41522011000300013>
- Araújo, D. L., Felix, L. P., Silva, L. C., Santos, T. M. (2016). Influência de Agregados Reciclados de Resíduos de Construção em Propriedades Mecânicas do Concreto. *REEC-Revista Eletrônica de Engenharia Civil*, 11(1), <https://doi.org/10.5216/reec.V11i1.35467>
- Associação brasileira de empresas de limpeza pública e resíduos especiais. Panorama dos resíduos sólidos no Brasil 2020. São Paulo, 2020.
- Bocanegra, C. W. R. (2002). *Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes*. Dissertação (Mestre em Engenharia Civil) - Escola de Engenharia de São Carlos/ Universidade de São Paulo. São Carlos, p. 108.
- Castro, A. L. D., Santos, R. F. C. D., Gonçalves, K. M., Quarcioni, V. A. (2017). Caracterização de cimentos compostos com resíduo da indústria de cerâmica vermelha. *Cerâmica*, 63, 65-76. <https://doi.org/10.1590/0366-69132017633652036>
- Castro, L. C. D., Bernardini, C. S. M., Sales, R. J. D. M., Silva, F. J. A. D., Cavalcante, A. Y. S. S., Alencar, I. F. D. O. (2021). Concreto a partir de agregado graúdo reciclado: uma avaliação na produção de blocos intertravados em Fortaleza/ce. *Revista AIDIS de Ingeniería y Ciencias Ambientales. Investigación, desarrollo y práctica*, 14(3), 1123-1138. <http://dx.doi.org/10.22201/iingen.0718378xe.2021.14.3.75860>

- da Silva, S. R. de Oliveira Andrade, J. J. (2017). Investigation of mechanical properties and carbonation of concretes with construction and demolition waste and fly ash. *Construction and Building Materials*, **153**, <https://doi.org/10.1016/j.conbuildmat.2017.07.143>
- da Silva, S. R., Cimadon, F. N., Borges, P. M., Schiavon, J. Z., Possan, E., de Oliveira Andrade, J. J. (2021). Relationship between the mechanical properties and carbonation of concretes with construction and demolition waste. *Case Studies in Construction Materials*, e00860. <https://doi.org/10.1016/j.cscm.2021.e00860>
- Dacoregio, F. A. (2017). *Estimativa preliminar de custos de obras utilizando redes neurais artificiais*. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Santa Catarina. Florianópolis, p. 276.
- Felix, E. F., Possan, E., Carrazedo, R. (2021). A New Formulation to Estimate the Elastic Modulus of Recycled Concrete Based on Regression and ANN. *Sustainability*, **13**(15), 8561. <https://doi.org/10.3390/su13158561>
- Fleck, L., Tavares, M. H. F., Eyng, E., Helmann, A. C., Andrade, M. D. M. (2016). Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, **1**(13), 47-57.
- Frotté, C., Nubila, C. S. A. D., Nagalli, A., Mazer, W., Macioski, G., Oliveira, L. O. S. D. (2017) Estudo das propriedades físicas e mecânicas de concreto com substituição parcial de agregado natural por agregado reciclado proveniente de RCD. *Matéria (Rio de Janeiro)*, **22**(2), e11811. <https://doi.org/10.1590/S1517-707620170002.0143>
- Haykin, S. (1994) *Neural networks - A comprehensive foundation*. Pearson.
- Haykin, S. (2001) *Redes neurais: princípios e prática*. Porto Alegre: Editora Bookman.
- Leite, M. B. (2001) *Avaliação de propriedades mecânicas de concretos produzidos com agregados reciclados de resíduos de construção e demolição*. Tese de Doutorado em Engenharia Civil, Departamento de Engenharia Civil - Universidade Federal do Rio Grande do Sul. Porto Alegre (RS), p. 270.
- Lima, J.A.R. (1999) *Proposição de diretrizes para produção e normalização de resíduo de construção reciclado e de suas aplicações em argamassas e concretos*. Programa de pós-graduação da Escola de Engenharia de São Carlos. Dissertação de mestrado. Universidade de São Paulo. São Carlos, p. 240.
- Medeiros, R. A. O. (2016) *Previsão de demanda no médio prazo utilizando redes neurais artificiais em sistemas de distribuição de energia elétrica*. Programa de pós-graduação em Engenharia Elétrica. Dissertação de mestrado. Universidade Federal da Paraíba. p. 85.
- Ossa, A.; García, J. L.; Botero, E. (2016) Use of recycled construction and demolition waste (CDW) aggregates: a sustainable alternative for the pavement construction industry. *Journal of Cleaner Production*, **135**, 379-386. <https://doi.org/10.1016/j.jclepro.2016.06.088>
- Pietersen, H. S.; Fraay, A. L. A.; Hendriks, C. F. (1998) Application of recycled aggregates in concrete: experiences from the Netherlands. *International Symposium on Sustainable Development of the Cement and Concrete Industry*. Ottawa - Canadá, p. 146.
- Quebaud, M. R.; Buyle-bodin, F. (1999) A reciclagem de materiais de demolição: utilização dos agregados reciclados no concreto. In: *Congresso Brasileiro de Cimento (CBC)*. Bahia, Brasil.
- Rezende, S. O. (2003) *Sistemas inteligentes - fundamentos e aplicações*. São Paulo: Editora Manole, p. 525.
- Rocha, S. O. N., Maia, N. A., de Carvalho Júnior, Á. B., Dias, M. P. A., Veloso, R. R. (2020). Utilização de redes neurais para estimativa da resistência à compressão do concreto simples. *Brazilian Journal of Development*, **6**(10), 79910-79922. <https://doi.org/10.34117/bjdv6n10-424>
- Rodrigues Lima, T. B., Carvalho Júnior, F. H. (2019) Análise do gerenciamento de resíduos da construção civil no município de fortaleza. *Revista AIDIS de Ingeniería y Ciencias Ambientales. Investigación, desarrollo y práctica*, **12**(1), 104-119. <http://dx.doi.org/10.22201/iingen.0718378xe.2019.12.1.61478>
- Santos, I. L.; Frantz, L. V.; Masuero, A. B. (2021) Influence of hydraulic jiggling of construction and demolition waste recycled aggregate on hardened concrete properties. São Paulo: *Revista IBRACON de Estruturas e Materiais*, **14**(6). <https://doi.org/10.1590/S1983-41952021000300014>

- Santos, R. F. C. D., Castro, A. L. D., Gonçalves, K. M. (2018). Produção de concreto autoadensável incorporado com resíduo da indústria de cerâmica vermelha. *Matéria (Rio de Janeiro)*, **23**. <https://doi.org/10.1590/S1517-707620180003.0500>
- Spörl, C.; Castro, E. G.; Luchiari, A. (2011) Aplicação de Redes Neurais Artificiais na construção de modelos de fragilidade ambiental. *Revista do Departamento de Geografia*, **21**(1), 113-135. <https://doi.org/10.7154/RDG.2011.0021.0006>
- Tavares, D. S., Junior, T. Y., Lacerda, W. S., Ribeiro, D. A. (2020). Uso de Redes Neurais Artificiais na Predição da Resistência à Compressão do Concreto. *Brazilian Journal of Development*, **6**(7).
- Urban, R. C., Isaac, R. D. L. (2018) Ferramenta espacial para gerenciamento de resíduos: elaboração de uma metodologia qualitativa para identificar áreas de destinação final de lodos de ETA e ETE. *Revista AIDIS de Ingeniería y Ciencias Ambientales. Investigación, desarrollo y práctica*, **12**(1), 52-64. <http://dx.doi.org/10.22201/iingen.0718378xe.2019.12.1.61160>
- Viana Neto, L. A. C. V.; Sales, A. T. C.; Sales, L. C. (2018) Efeitos da variabilidade de agregados de RCD sobre o desempenho mecânico do concreto de cimento Portland. *Matéria (Rio de Janeiro)*, **23**(1), e-11958. <https://doi.org/10.1590/S1517-707620170001.0294>

Apêndice A

Nº	C	A.M.N	A.M.R	A.G.N	A.G.R	A/C	S.T	R	M.E.A.M.N	M.E.A.M.R	M.E.A.G.N	M.E.A.G.R
1	1	1.195	1.195	2.9	0	0.57	70	25.50	2.64	2.40	2.65	0
2	1	0	2.39	2.9	0	0.57	70	23.50	0	2.40	2.65	0
3	1	2.39	0	1.45	1.45	0.57	70	18.50	2.64	0	2.65	2.51
4	1	2.39	0	0	2.9	0.57	70	19.50	2.64	0	0	2.51
5	1	1.195	1.195	1.45	1.45	0.57	70	21.00	2.64	2.40	2.65	2.51
6	1	0	2.39	0	2.9	0.57	70	17.00	0	2.40	0	2.51
7	1	2.175	0.725	2.81	0	0.645	50	22.50	2.63	2.54	2.74	0
8	1	1.45	1.45	2.81	0	0.645	35	26.80	2.63	2.54	2.74	0
9	1	0.83	0.83	1.84	0	0.55	100	31.00	2.62	2.54	2.70	0
10	1	1.27	1.27	2.46	0	0.71	100	22.70	2.62	2.54	2.70	0
11	1	1.715	1.715	3.07	0	0.91	100	14.30	2.62	2.54	2.70	0
12	1	0	1.84	1.66	0	0.61	100	27.90	0	2.54	2.70	0
13	1	0	2.78	2.22	0	0.83	100	20.90	0	2.54	2.70	0
14	1	0	3.73	2.77	0	1.01	100	12.80	0	2.54	2.70	0
15	1	1.63	0	1.4	0.47	0.47	55	36.73	2.55	0	2.63	2.31
16	1	2.48	0	1.89	0.63	0.63	50	26.58	2.55	0	2.63	2.31
17	1	3.33	0	2.38	0.79	0.78	50	19.29	2.55	0	2.63	2.31
18	1	1.72	0	0.89	0.89	0.48	70	27.12	2.55	0	2.63	2.31
19	1	2.6	0	1.2	1.2	0.65	65	20.85	2.55	0	2.63	2.31
20	1	3.48	0	1.51	1.51	0.72	70	19.13	2.55	0	2.63	2.31
21	1	1.83	0	0.42	1.25	0.52	75	30.88	2.55	0	2.63	2.31
22	1	2.72	0	0.57	1.71	0.62	60	25.40	2.55	0	2.63	2.31
23	1	3.66	0	0.71	2.13	0.78	55	14.83	2.55	0	2.63	2.31
24	1	1.9	0	0	1.6	0.5	70	29.19	2.55	0	0	2.31
25	1	2.84	0	0	2.16	0.71	65	19.80	2.55	0	0	2.31
26	1	3.79	0	0	2.71	0.83	45	15.79	2.55	0	0	2.31
27	1	0	2.508	0	2.773	0.67	45	19.50	0	2.50	0	2.08

Nº	C	A.M.N	A.M.R	A.G.N	A.G.R	A/C	S.T	R	M.E.A.M.N	M.E.A.M.R	M.E.A.G.N	M.E.A.G.R
28	1	0	2.508	0	3.000	0.67	50	22.50	0	2.50	0	2.27
29	1	2.689	0	0	2.773	0.67	55	20.70	2.68	0	0	2.08
30	1	2.689	0	0	3.000	0.67	185	23.40	2.68	0	0	2.27
31	1	0	1.675	0	2.080	0.5	60	28.30	0	2.50	0	2.08
32	1	0	1.675	0	2.250	0.5	125	30.80	0	2.50	0	2.27
33	1	1.796	0	0	2.080	0.5	150	30.30	2.68	0.00	0	2.08
34	1	1.796	0	0	2.250	0.5	175	28.50	2.68	0.00	0	2.27
35	1	0	1.175	0	1.664	0.4	85	33.60	0	2.50	0	2.08
36	1	0	1.175	0	1.800	0.4	75	42.50	0	2.50	0	2.27
37	1	1.260	0	0	1.664	0.4	105	36.00	2.68	0	0	2.08
38	1	1.260	0	0	1.800	0.4	70	44.60	2.68	0	0	2.27
39	1	1.73	0.22	2.72	0.29	0.45	35	35.60	2.632	2.529	3.09	2.51
40	1	3.42	0.43	4.48	0.47	0.75	20	16.05	2.632	2.529	3.09	2.51
41	1	0.22	1.66	2.72	0.29	0.45	45	37.32	2.632	2.529	3.09	2.51
42	1	0.44	3.28	4.48	0.47	0.75	15	27.50	2.632	2.529	3.09	2.51
43	1	1.73	0.22	0.35	2.2	0.45	20	30.90	2.632	2.529	3.09	2.51
44	1	3.42	0.43	0.58	3.63	0.75	5	18.40	2.632	2.529	3.09	2.51
45	1	0.22	1.66	0.35	2.2	0.45	5	29.82	2.632	2.529	3.09	2.51
46	1	0.44	3.28	0.58	3.63	0.75	0	20.95	2.632	2.529	3.09	2.51
47	1	1.45	1.4	4.06	0	0.6	25	24.55	2.632	2.529	3.09	0
48	1	1.45	1.4	0	3.3	0.6	5	23.83	2.632	2.529	0.00	2.51
49	1	2.91	0	2.03	1.65	0.6	10	23.85	2.632	0	3.09	2.51
50	1	0	2.79	2.03	1.65	0.6	5	26.15	0	2.529	3.09	2.51
51	1	0.82	0.78	1.37	1.11	0.4	25	37.37	2.632	2.529	3.09	2.51
52	1	2.09	2.01	2.7	2.19	0.8	15	16.10	2.632	2.529	3.09	2.51
53	1	1.45	1.4	2.03	1.65	0.6	20	26.00	2.632	2.529	3.09	2.51
54	1	1.435	0	1.625	0.375	0.45	85	41.23	2.53	0	2.65	2.58
55	1	1.435	0	1.140	0.861	0.45	95	39.60	2.53	0	2.65	2.58
56	1	1.435	0	0.500	1.500	0.45	215	35.79	2.53	0	2.65	2.58
57	1	1.435	0	0	2.000	0.45	70	38.30	2.53	0	0	2.58
58	1	1.435	0	1.479	0.521	0.45	85	37.82	2.53	0	2.65	2.70
59	1	1.4	0	0	2.4	0.45	50	47.70	2.68	0	0	2.46
60	1	1.4	0	0	2.4	0.48	70	45.30	2.68	0	0	2.40
61	1	1.4	0	0	2.4	0.45	50	49.20	2.68	0	0	2.43
62	1	1.4	0	0	2.4	0.48	50	42.50	2.68	0	0	2.39
63	1	1.25	0	0	1.45	0.41	75	21.89	2.60	0	0	1.81
64	1	1.95	0	0	1.88	0.568	70	16.47	2.60	0	0	1.81
65	1	2.75	0	0	2.42	0.78	78	11.08	2.60	0	0	1.81
66	1	1.25	0	1.13	0.73	0.4	78	30.04	2.60	0	2.81	1.81
67	1	1.95	0	1.46	0.94	0.548	90	25.84	2.60	0	2.81	1.81
68	1	1.25	0	1.88	1.21	0.73	85	18.52	2.60	0	2.81	1.81
69	1	1.385	0	1.586	0.529	0.48	90	25.26	2.62	0	2.74	1.87
70	1	1.385	0	1.058	1.058	0.48	80	22.70	2.62	0	2.74	1.87
71	1	1.385	0	0.529	1.586	0.48	80	20.94	2.62	0	2.74	1.87
72	1	1.385	0	0	2.115	0.48	55	18.60	2.62	0	2.74	1.87
73	1	2.18	0	2.115	0.705	0.64	90	15.08	2.62	0	2.74	1.87
74	1	2.18	0	1.41	1.41	0.64	75	13.98	2.62	0	2.74	1.87
75	1	2.18	0	0.705	2.115	0.64	75	13.03	2.62	0	2.74	1.87
76	1	2.18	0	0	2.82	0.64	50	12.15	2.62	0	2.74	1.87

Nº	C	A.M.N	A.M.R	A.G.N	A.G.R	A/C	S.T	R	M.E.A.M.N	M.E.A.M.R	M.E.A.G.N	M.E.A.G.R
77	1	2.975	0	2.644	0.881	0.83	90	10.62	2.62	0	2.74	1.87
78	1	2.975	0	1.763	1.763	0.83	90	9.81	2.62	0	2.74	1.87
79	1	2.975	0	0.881	2.644	0.83	70	9.00	2.62	0	2.74	1.87
80	1	2.975	0	0	3.525	0.83	50	8.20	2.62	0	2.74	1.87
81	1	1.25	0	0	1.73	0.66	85	23.70	2.62	0	0	2.06
82	1	1.25	0	0	1.64	0.72	87	22.40	2.62	0	0	1.95
83	1	1.25	0	0	1.92	0.59	78	27.30	2.62	0	0	2.29
84	1	1.25	0	0	1.85	0.6	87	26.10	2.62	0	0	2.20
85	1	2.25	0	0	2.5	1	87	15.60	2.62	0	0	2.06
86	1	2.25	0	0	2.36	1.08	82	14.70	2.62	0	0	1.95
87	1	2.25	0	0	2.78	0.87	90	18.10	2.62	0	0	2.29
88	1	2.25	0	0	2.67	0.87	70	16.60	2.62	0	0	2.20
89	1	2.75	0	0	2.88	1.13	75	14.80	2.62	0	0	2.06
90	1	2.75	0	0	2.73	1.21	70	13.40	2.62	0	0	1.95
91	1	2.75	0	0	3.2	1	75	16.20	2.62	0	0	2.29
92	1	2.75	0	0	3.08	0.97	80	14.70	2.62	0	0	2.20
93	1	1.705	0	2.292	0.574	0.4	240	41.80	2.68	0	2.57	2.27
94	1	2.150	0	2.581	0.645	0.45	190	41.70	2.68	0	2.57	2.27
95	1	2.454	0	2.786	0.697	0.5	220	35.80	2.68	0	2.57	2.27
96	1	2.674	0	2.939	0.735	0.55	80	31.50	2.68	0	2.57	2.27
97	1	2.600	0	2.891	0.726	0.6	140	27.40	2.68	0	2.57	2.27
98	1	2.526	0	2.850	0.712	0.65	210	25.00	2.68	0	2.57	2.27
99	1	1.747	0	1.364	1.362	0.4	200	43.60	2.68	0	2.57	2.27
100	1	2.205	0	1.530	1.528	0.45	110	41.80	2.68	0	2.57	2.27
101	1	2.516	0	1.648	1.648	0.5	195	37.20	2.68	0	2.57	2.27
102	1	2.756	0	1.737	1.732	0.55	100	30.90	2.68	0	2.57	2.27
103	1	2.680	0	1.706	1.706	0.6	140	28.20	2.68	0	2.57	2.27
104	1	2.604	0	1.680	1.680	0.65	210	24.30	2.68	0	2.57	2.27
105	1	1.616	0	0	2.677	0.4	250	41.30	2.68	0	0	2.27
106	1	2.074	0	0	2.990	0.45	230	36.00	2.68	0	0	2.27
107	1	2.395	0	0	3.209	0.5	240	34.40	2.68	0	0	2.27
108	1	2.630	0	0	3.370	0.55	145	30.30	2.68	0	0	2.27
109	1	2.556	0	0	3.319	0.6	175	26.30	2.68	0	0	2.27
110	1	2.482	0	0	3.268	0.65	225	22.80	2.68	0	0	2.27
111	1	1.566	0	2.049	0.498	0.55	100	45.30	2.62	0	2.62	2.49
112	1	1.566	0	1.278	1.234	0.55	100	42.50	2.62	0	2.62	2.49
113	1	1.566	0	0	2.480	0.55	100	38.10	2.62	0	2.62	2.49
114	1	1.026	0	1.549	0.377	0.44	100	42.80	2.62	0	2.62	2.49
115	1	1.026	0	0.968	0.940	0.44	100	41.70	2.62	0	2.62	2.49
116	1	1.026	0	0	1.879	0.44	100	36.80	2.62	0	2.62	2.49
117	1	0.865	0	1.518	0.369	0.40	100	41.00	2.62	0	2.62	2.49
118	1	0.865	0	0.947	0.914	0.40	100	37.10	2.62	0	2.62	2.49
119	1	0.865	0	0	1.837	0.40	100	25.20	2.62	0	2.62	2.49
120	1	1.29	0	0	2.21	0.44	50	17.50	2.63	0	0	2.26
121	1	1.47	0	0	2.03	0.44	50	20.60	2.63	0	0	2.26
122	1	1.65	0	0	1.85	0.44	50	28.10	2.63	0	0	2.26
123	1	1.83	0	0	1.67	0.44	50	26.20	2.63	0	0	2.26
124	1	1.29	0	0	2.21	0.44	50	16.20	2.63	0	0	2.16
125	1	1.47	0	0	2.03	0.44	50	25.00	2.63	0	0	2.16

Nº	C	A.M.N	A.M.R	A.G.N	A.G.R	A/C	S.T	R	M.E.A.M.N	M.E.A.M.R	M.E.A.G.N	M.E.A.G.R
126	1	1.65	0	0	1.85	0.44	50	26.20	2.63	0	0	2.16
127	1	1.83	0	0	1.67	0.44	50	23.70	2.63	0	0	2.16
128	1	1.82	0	0	3.18	0.52	50	18.50	2.63	0	0	2.26
129	1	2.06	0	0	2.94	0.52	50	23.10	2.63	0	0	2.26
130	1	2.30	0	0	2.70	0.52	50	25.50	2.63	0	0	2.26
131	1	2.54	0	0	2.46	0.54	50	21.20	2.63	0	0	2.26
132	1	2.78	0	0	2.22	0.54	50	20.50	2.63	0	0	2.26
133	1	1.82	0	0	3.18	0.52	50	13.10	2.63	0	0	2.17
134	1	2.06	0	0	2.94	0.53	50	16.20	2.63	0	0	2.17
135	1	2.30	0	0	2.70	0.53	50	21.10	2.63	0	0	2.17
136	1	2.54	0	0	2.46	0.54	50	23.10	2.63	0	0	2.17
137	1	2.78	0	0	2.22	0.54	50	21.80	2.63	0	0	2.17
138	1	1.82	0	0	3.18	0.52	50	13.70	2.63	0	0	2.16
139	1	2.06	0	0	2.94	0.53	50	18.70	2.63	0	0	2.16
140	1	2.30	0	0	2.70	0.53	50	23.10	2.63	0	0	2.16
141	1	2.54	0	0	2.46	0.55	50	19.30	2.63	0	0	2.16
142	1	2.78	0	0	2.22	0.54	50	16.20	2.63	0	0	2.16
143	1	1.82	0	0	3.18	0.53	50	16.80	2.63	0	0	2.17
144	1	2.06	0	0	2.94	0.53	50	20.30	2.63	0	0	2.17
145	1	2.30	0	0	2.70	0.53	50	22.00	2.63	0	0	2.17
146	1	2.54	0	0	2.46	0.54	50	20.20	2.63	0	0	2.17
147	1	2.78	0	0	2.22	0.55	50	17.50	2.63	0	0	2.17
148	1	0	1.8	2.58	0	0.57	90	23.55	0	2.40	2.85	0
149	1	1.8	0	0	2.58	0.55	90	20.00	2.62	0	0	2.40
150	1	0	1.8	0	2.58	0.60	80	18.15	0	2.40	0	2.40
151	1	0	3.1	3.78	0	0.76	90	14.00	0	2.40	2.85	0
152	1	3.1	0	0	3.78	0.79	80	13.17	2.62	0	0	2.40
153	1	0	3.1	0	3.78	0.93	80	10.20	0	2.40	0	2.40
154	1	0.9	0.9	1.29	1.29	0.55	90	23.65	2.62	2.40	2.85	2.40
155	1	1.55	1.55	1.89	1.89	0.76	80	15.43	2.62	2.40	2.85	2.40
156	1	2.45	0	1.59	1.59	0.67	80	17.15	2.62	0	2.85	2.40
157	1	1.225	1.225	0	3.18	0.65	85	15.40	2.62	2.40	0	2.40
158	1	0	2.45	1.59	1.59	0.71	80	17.25	0	2.40	2.85	2.40
159	1	1.225	1.225	3.18	0	0.63	85	21.70	2.62	2.40	2.85	0
160	1	1.225	1.225	1.59	1.59	0.65	85	17.30	2.62	2.40	2.85	2.40
161	1	0	1.8	2.58	0	0.60	100	24.25	0	2.40	2.85	0
162	1	1.8	0	0	2.58	0.61	100	20.35	2.62	0	0	2.45
163	1	0	1.8	0	2.58	0.70	110	15.13	0	2.40	0	2.45
164	1	0	3.1	3.78	0	0.85	120	12.05	0	2.40	2.85	0
165	1	3.1	0	0	3.78	0.93	95	13.93	2.62	0	0	2.45
166	1	0	3.1	0	3.78	1.01	80	13.02	0	2.40	0	2.45
167	1	0.9	0.9	1.29	1.29	0.61	80	24.23	2.62	2.40	2.85	2.45
168	1	1.55	1.55	1.89	1.89	0.84	120	13.63	2.62	2.40	2.85	2.45
169	1	2.45	0	1.59	1.59	0.68	105	20.40	2.62	0	2.85	2.45
170	1	1.225	1.225	0	3.18	0.78	95	15.95	2.62	2.40	0	2.45
171	1	0	2.45	1.59	1.59	0.80	90	16.67	0	2.40	2.85	2.45
172	1	1.225	1.225	3.18	0	0.66	105	20.27	2.62	2.40	2.85	0
173	1	1.225	1.225	1.59	1.59	0.74	105	15.20	2.62	2.40	2.85	2.45
174	1	0	1.8	2.58	0	0.56	110	20.02	0	2.44	2.85	0

Nº	C	A.M.N	A.M.R	A.G.N	A.G.R	A/C	S.T	R	M.E.A.M.N	M.E.A.M.R	M.E.A.G.N	M.E.A.G.R
175	1	1.8	0	0	2.58	0.65	100	16.98	2.62	0	0	2.58
176	1	0	1.8	0	2.58	0.63	90	17.07	0	2.44	0	2.58
177	1	0	3.1	3.78	0	0.76	100	12.25	0	2.44	2.85	0
178	1	3.1	0	0	3.78	0.86	90	12.53	2.62	0	0	2.58
179	1	0	3.1	0	3.78	0.85	90	11.33	0	2.44	0	2.58
180	1	0.9	0.9	1.29	1.29	0.57	100	19.80	2.62	2.44	2.85	2.58
181	1	1.55	1.55	1.89	1.89	0.83	90	12.40	2.62	2.44	2.85	2.58
182	1	2.45	0	1.59	1.59	0.69	100	17.10	2.62	0	2.85	2.58
183	1	1.225	1.225	0	3.18	0.72	85	15.68	2.62	2.44	0	2.58
184	1	0	2.45	1.59	1.59	0.68	100	13.45	0	2.44	2.85	2.58
185	1	1.225	1.225	3.18	0	0.61	90	25.10	2.62	2.44	2.85	0
186	1	1.225	1.225	1.59	1.59	0.68	100	16.00	2.62	2.44	2.85	2.58

Legenda

C = Cimento

A.M.N = Agregado Miúdo Natural

A.M.R = Agregado Miúdo Reciclado

A.G.N = Agregado Graúdo Natural

A.G.R = Agregado Graúdo Reciclado

A/C = Relação Água/Cimento

S.T = Slump Test (mm)

R = Resistencia (MPa)

M.E.A.M.N = Massa Específica Agregado Miúdo Natural

M.E.A.M.R = Massa Específica Agregado Miúdo Reciclado

M.E.A.G.N = Massa Específica Agregado Graúdo Natural

M.E.A.G.R = Massa Específica Agregado Graúdo Reciclado