

Product Performance: A Prediction Model for Compressive Strength of Composed Cements

T. Moriggi, G. Loch, and M. Marques

Abstract—As a result of a production process, it is important that the product meets the quality requirements defined by standards and specific customer needs. In order to verify the fulfillment of the requirements, the application of techniques to assist the evaluation of parameters throughout the production process and identification of possible deviations is important. Therefore, the available data need to be transformed into useful information and decision value, so that conclusions can be reached in a timely manner for possible maintenance and corrections. In the cement production flow, and in the consequent quality evaluation, it takes time between production and the availability of variable values. For this reason, the present study was developed aiming to predict, through the application of the Artificial Neural Networks (ANNs), the result of compressive strength at 28 days for the produced cements regarding parameters from the productive flow. ANNs have the ability to learn by mapping input data and their relationships with the output, as well as to synthesize and generate appropriate responses to a set of new inputs. The results obtained in this study led to a predictive model with a conservative profile and a strong correlation with the observed data, reinforcing the ability of this methodology to predictive problems.

Index Terms—Cement Performance, Artificial Neural Network, Compressive Strength, Prediction Model.

I. INTRODUÇÃO

O PRODUTO cimento é definido como um pó fino com propriedades ligantes que endurece em contato com água, desenvolvendo, assim, resistência mecânica [1]. Os diferentes tipos de cimento podem ser classificados de acordo com a Tabela I.

TABELA I
TIPOS DE CIMENTO PORTLAND [1]

Sigla	Nomenclatura
CP I	Cimento Portland comum
CP I-S	Cimento Portland comum com adição
CP II-E	Cimento Portland composto com escória de alto-forno
CP II-Z	Cimento Portland composto com material pozolânico
CP II-F	Cimento Portland composto com material carbonático
CP III	Cimento Portland de alto-forno
CP IV	Cimento Portland Pozolânico
CP V-ARI	Cimento Portland Alta Resistência Inicial

T. Moriggi está com o Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Paraná (UFPR), Curitiba, Paraná, Brasil (e-mail: tacius.moriggi@gmail.com).

G. V. Loch está com o Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Paraná (UFPR), Curitiba, Paraná, Brasil (e-mail: gvalentim@gmail.com).

M. M. Marques está com o Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Paraná (UFPR), Curitiba, Paraná, Brasil (e-mail: marrquesammarcos@gmail.com).

Corresponding author: Tacius Moriggi

Os cimentos ditos compostos possuem materiais (escórias, materiais pozolânicos e materiais carbonáticos) que substituem parte do clínquer, o principal insumo de sua composição, proporcionando variedades em relação às suas propriedades e fazendo com que diferentes tipos de cimento sejam mais adequados para determinadas aplicações. Além disso, os cimentos compostos com escórias e pozolanas apresentam potenciais vantagens ambientais e econômicas na medida em que representam menores emissões de CO₂ ao longo do processo produtivo e menores custos para o fabricante quando comparados com os cimentos comuns (CP I), o que torna o seu estudo fundamental e de grande interesse.

A garantia do desempenho dos cimentos é definida a partir da sua avaliação em determinadas características, definidas em normas técnicas regulamentadoras, cujo cumprimento é mandatório para que se verifique desempenho mínimo necessário [1, 2, 5]. Dentre estas características, uma de grande importância é a resistência à compressão aos 28 dias (R28) [3, 4].

O comportamento do desenvolvimento da resistência à compressão para os diferentes tipos de cimento é representado pela Figura 1. A partir do 28º dia não existem aumentos expressivos da resistência, assumindo-se, assim, a R28 como a resistência final do produto e suficiente para caracterizar o desempenho deste [1].

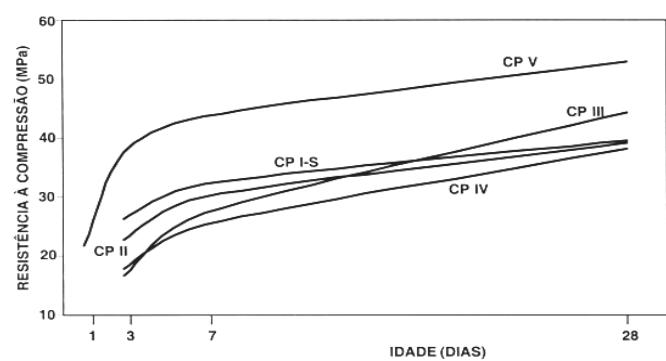


Fig. 1. Desenvolvimento da resistência à compressão para os diferentes tipos de cimento e para diferentes idades [1].

Verificando o intervalo de tempo entre o fim da produção e a liberação dos resultados de R28 (período de 28 dias), torna-se importante predizer o valor de uma das principais variáveis de desempenho em um intervalo consideravelmente menor, possibilitando a identificação de desvios nos produtos e a atuação, de forma proativa, na correção do processo produtivo.

É importante destacar que o número de variáveis do processo que exercem influência na R28 é grande e, além disso, elas influenciam de diversas formas e com distintas

intensidades, de modo que o estabelecimento de relações matemáticas diretas se torna muito complexo [3].

Nesse sentido, o desenvolvimento de modelos preditivos que sejam capazes de entender essas relações complexas é de fundamental importância, uma vez que a predição de irregularidades pode evitar falhas de desempenho na aplicação final do produto, bem como sinalizar a necessidade de ajustes no fluxo produtivo, possibilitando correções nos pontos necessários a fim de que produtos irregulares não sejam continuados evitando perdas de tempo e de recursos [3, 6].

Devido à grande importância de predizer o R28, diversos estudos são apresentados na literatura com esse mesmo objetivo e permitem identificar oportunidades de pesquisa no que tange o tipo de cimentos e a seleção das variáveis de influência [3, 7-13]. Esses trabalhos podem ser divididos em dois grupos: o primeiro [7-12] considera variáveis de mistura do cimento com aditivos químicos e agregados para a produção de concretos e argamassas; O segundo [3, 13] considera variáveis do processo produtivo do cimento.

Ambos os grupos consideram cimentos comuns (CPI) para a realização dos estudos e poucos deles consideram as variáveis do processo como fonte de informações para a predição. Dessa forma, é reforçada a importância de se desenvolver a análise para os cimentos compostos (CP II), ponderando a criação de um novo conjunto de variáveis para que essa lacuna de pesquisa seja atendida.

Ainda nestes estudos, percebe-se o uso predominante do método de Redes Neurais Artificiais (RNAs) como ferramenta para reconhecimento de padrões e de predição. Isso se deve ao fato dela conseguir contemplar relações não lineares, o que permite identificar interações implícitas e complexas entre as variáveis analisadas. A principal vantagem dessa metodologia [14-16] é sua capacidade de generalização, ou seja, após realizado o treinamento, a RNA é capaz de atuar corretamente para um elevado número de casos.

Neste contexto, este trabalho apresenta o desenvolvimento de um modelo preditivo a partir da aplicação da metodologia das RNAs, considerando um cimento composto com adição de escória (CP II-E), tendo como principal objetivo a garantia de qualidade do produto final focando na mitigação de desvios ao longo da produção e no estabelecimento de um comportamento proativo da qualidade no que tange os resultados da R28.

No desenvolvimento do trabalho acompanhou-se, por meio de um estudo de caso realizado na unidade fabril de Santa Helena da Votorantim Cimentos no Brasil, o processo produtivo e as análises de qualidade dos cimentos entre os meses de agosto e outubro de 2017.

A Votorantim Cimentos está entre os oito maiores produtores globais de cimento, trabalhando também com concreto, agregados, argamassa, cal e calcário agrícola. No Brasil, possui 55 unidades de produção abrangendo quase todos os estados brasileiros e 103 centrais de concreto. Além disso, comercializa mais de 40 produtos, com destaque para as marcas Votoran, Itaú, Poty, Tocantins, Aratu, Votomassa, Matrix e Engemix.

A geração desse estudo contribui para a generalização das

soluções hoje existentes e destaca a grande possibilidade de replicação desse tipo de método para os demais tipos de cimento e condições fabris.

O resultado da aplicação da metodologia foi validado por meio da verificação do coeficiente de desempenho [17]. Os resultados comprovam acurácia, precisão e compatibilidade entre os métodos de predição e de ensaio físico de resistência.

Assim, esse trabalho é organizado da seguinte maneira: na Seção II é apresentada uma descrição detalhada do método proposto para predição da resistência à compressão de cimentos compostos. A Seção III apresenta os resultados e discussões dos cenários simulados e a Seção IV, por fim, apresenta as conclusões obtidas ao fim desse trabalho.

II. MATERIAIS E MÉTODOS

O objetivo desta seção é apresentar um modelo matemático para a predição da resistência à compressão aos 28 dias de cimentos compostos que seja compatível com o ensaio físico. Para isso, são definidas as variáveis consideradas no estudo, a criação de cenários a partir do tratamento e seleção dessas variáveis, o processo de amostragem e a parametrização das RNAs.

A. Identificação das Variáveis

Para a definição das variáveis que foram consideradas no presente estudo, foi realizada a verificação daquelas acatadas na literatura [3, 7-13], bem como aquelas selecionadas pelos especialistas em cimento (engenheiros responsáveis pelo controle de qualidade da empresa estudada) por meio de entrevistas.

Todos os ensaios necessários para obtenção das variáveis consideradas podem ser realizados na fábrica onde o estudo é desenvolvido. Contudo, como restrição da pesquisa, consideram-se as disponibilidades técnicas, humanas e financeiras no dimensionamento das amostras para que a rotina de qualidade fabril não seja afetada. Na Tabela II são identificadas as variáveis consideradas neste estudo.

TABELA II
VARIÁVEIS SELECIONADAS PARA O ESTUDO A PARTIR DE LEVANTAMENTO BIBLIOGRÁFICO E ENTREVISTAS COM ESPECIALISTAS EM CIMENTO [3, 13]

Ensaio	Variáveis analisadas
Composição química (%)	CaO, Fe ₂ O ₃ , Na ₂ O, SiO ₂ , MgO, TiO ₂ , Al ₂ O ₃ , K ₂ O, Mn ₂ O ₃ , SO ₃ , FSC, MS e MA.
Composição mineralógica (%)	Alita, belita, C ₃ A ortorrômbico, C ₃ A cúbico, ferrita, CaO livre, periclásio, arcana, aftalita, lagbeinita, calcita, dolomita, quartzo, gipsita, bassanita, escória, portlandita e fluorita.
Ensaios físicos	Perda ao fogo, início de pega, fim de pega, resistência à compressão aos 3 e aos 7 dias, água de consistência, resíduo insolúvel, Blaine e peneiras #325 e #400.

B. Seleção das Variáveis

Para que o melhor desempenho do modelo possa ser alcançado foram consideradas 3 metodologias para seleção de variáveis, visando a simplificação do processo de cálculo e a consideração das variáveis que de fato possuem influência na variável resposta (R28), uma vez que simplificações por colinearidade entre essas torna possível a redução do número

de variáveis.

Dessa forma, foram considerados 4 cenários para tratamento (A, B, C e D) definidos a partir da Análise de Componentes Principais (ACP). A ACP possui dois objetivos distintos, o primeiro deles é a redução da dimensionalidade do modelo por meio da substituição das variáveis pelas suas componentes principais. O outro é a seleção das variáveis de maior influência no modelo [18].

C. Análise de componentes principais (ACP)

A ACP é uma técnica estatística multivariada fundamentada na explicação da variância e covariância de um vetor aleatório composto por p variáveis aleatórias. Ela consiste na determinação de uma transformação ortogonal das p variáveis originais para um novo conjunto de componentes não correlacionadas obtidas por meio da construção de combinações lineares das variáveis originais. Essas combinações são chamadas de componentes principais e podem ser analisadas por meio de técnicas estatísticas usuais como a análise de regressão múltipla [19, 20].

A estrutura de uma ACP é definida a partir do cálculo dos autovetores e autovalores da matriz de correlação dessas p variáveis. A soma dos autovalores define a porcentagem da variância do modelo explicada pelas componentes e sobre esse valor são definidos critérios de corte, como o Critério de Kaiser, que permitem a simplificação do modelo, mantendo aproximadamente o mesmo desempenho do original, mas com menos variáveis [21].

D. Cenário A

Para o cenário A foram consideradas todas as variáveis para a criação do modelo (Tabela I).

E. Cenário B

Para a definição do cenário B foi considerada a redução da dimensionalidade por meio da aplicação do Critério de Kaiser para seleção das componentes principais resultantes da ACP, onde escolhe-se o número de componentes para se manter no modelo em função do número de autovalores maiores ou iguais a 1. O resultado dessa análise define 12 componentes principais, simplificando o processo de cálculo.

F. Cenário C

Para o cenário C foi considerada a metodologia B2 de seleção de variáveis para ser aplicada sobre os autovalores e autovetores das componentes principais definidos pela ACP [18]. Nesse método o número n de variáveis que deve ser retirado no modelo é igual ao número de autovalores cujo valor é menor que 0,7.

O método B2 seleciona as n variáveis de maior correlação com cada uma das últimas componentes principais, ordenadas de forma decrescente em relação aos autovalores, e exclui as mesmas. As variáveis selecionadas são descritas na Tabela III.

G. Cenário D

O cenário D foi definido a partir do método B4 de seleção de variáveis [18]. Esse método, complementar ao método B2, é baseado na preservação da variação da maioria dos dados e por esse motivo são selecionadas n variáveis das primeiras n componentes principais seguindo a mesma regra definida para o método B2, ou seja, selecionando as variáveis de maior correlação com a componente correspondente.

Para esse caso, as variáveis não selecionadas são descartadas. As variáveis selecionadas de acordo com esse procedimento são destacadas na Tabela IV.

TABELA IV
VARIÁVEIS SELECIONADAS PELO MÉTODO B4 DE JOLLIFFE

R7	MgO	Calcita	Teor de escória
Falsa pega	K ₂ O	Langbeinita	Fe ₂ O ₃
C ₂ S	MS	Resíduo insolúvel	Aftalilita
SiO ₂	C ₃ A cúbico	C ₃ A ortorrômbico	C ₃ S

H. Amostragem

O processo de amostragem dos cimentos expedidos ocorre de acordo com um padrão operacional estabelecido pela Votorantim Cimentos. São amostradas manualmente todas as carretas expedidas no dia e coletado, por meio de um amostrador “agulha”, material suficiente para a caracterização dos cimentos. As amostras são direcionadas para o laboratório de controle de qualidade e os ensaios mandatórios são realizados.

Para o desenvolvimento desse estudo foi considerada apenas uma amostra diária desse cimento para a realização de todos os ensaios de caracterização disponíveis, totalizando 27 resultados. Esse número reduzido de amostras é possível pela estabilidade das características do cimento armazenado no silo de expedição e necessário devido às restrições da planta considerada no estudo de caso.

I. K-fold Cross Validation

Para a obtenção de um bom resultado estatístico, tendo em vista o baixo volume de amostras, foram realizadas partições diferentes no mesmo conjunto de dados em diferentes conjuntos de treinamento. O método considerado nesse trabalho, denominado de *k-fold cross validation*, fornece uma estimativa mais realista do erro a ser cometido pelo método de predição utilizado [22].

Em *k-fold*, um conjunto de dados é aleatoriamente dividido em k partições mutuamente exclusivas (*folds*) e de tamanho aproximadamente iguais (n/k). Dessas partições, ($k-1$) folds são usadas para treinamento e o *fold* restante para teste. Esse processo é repetido k vezes, cada vez considerando um *fold* diferente para teste. A vantagem dessa metodologia reside na divisão dos dados.

Cada partição é testada exatamente uma vez para e está no conjunto de treinamento ($k-1$) vezes. A variância é reduzida a medida que o valor k é aumentado. A desvantagem é que o algoritmo de treinamento deve ser repetido k vezes, o que significa um custo operacional mais elevado [22, 23].

TABELA III

VARIÁVEIS SELECIONADAS PELO MÉTODO B2 DE JOLLIFFE

Perda ao fogo	Água de consistência	Gipsita	C ₃ S
R7	C ₃ A ortorrômbico	Portlandita	C ₂ S
RI	Periclásio	Teor de escória	C ₃ A cúbico
Al ₂ O ₃	Langbeinita	Dolomita	MgO

J. Normalização das Variáveis

A diferença de ordens de grandeza e nas unidades de medida das variáveis pode causar discrepância no tratamento dos dados, influenciando na avaliação das variáveis de maior variância no modelo. Para resolver o problema, realizou-se a normalização dos dados a partir da amplitude dos conjuntos de valores, redefinindo esses para o intervalo entre 0 e 1.

A transformação realizada padroniza as variáveis em uma mesma escala de medida e mitiga o efeito de evidência incoerente para variáveis de diferentes dimensões.

K. Redes Neurais Artificiais

As RNAs consistem em uma técnica para a solução de problemas de inteligência artificial que tenta simular o funcionamento do cérebro humano. Ela foi concebida para processar informações e adquirir conhecimento por meio de simulações computacionais [24-26]. Além disso, são capazes de detectar padrões e relações não explícitas em um conjunto de dados aparentemente desconexos [27-30].

De acordo com os trabalhos disponíveis na literatura [3, 7-13] e avaliando as metodologias aplicadas e os resultados alcançados, o presente trabalho selecionou a RNA como ferramenta de trabalho a ser aplicada pela sua aderência aos objetivos desta pesquisa e, sobretudo, pela sua habilidade de aprender com dados experimentais. Assim, reduzindo possíveis ruídos originários do processo e ainda garantindo boa proximidade com os dados experimentais.

Diversas topologias de rede são apresentadas na literatura para a solução de modelos preditivos sem existir, no entanto, uma indicação da melhor parametrização para cada caso estudado. Existe, no entanto, um modelo usualmente aplicado, e que foi o escolhido para este estudo, que consiste na topologia denominada MLP (*Multi Layer Perceptron*). Nessa topologia, cada um dos nós da camada de entrada está conectado a todo os nós da próxima camada adjacente [28]. No presente trabalho, particularmente, foram consideradas MLPs de apenas uma camada oculta.

A partir da informação contida em pares de entradas e saídas, as RNAs devem ajustar seus pesos de forma a encontrar a menor diferença entre as saídas desejadas e as saídas obtidas pela RNA. Dentre os diversos algoritmos de treinamento existentes, este trabalho utilizou o algoritmo *backpropagation*, devido à capacidade de realimentação e a boa capacidade de convergência [31].

A quantidade de neurônios da camada de entrada é igual ao número de variáveis selecionadas, que no caso deste trabalho varia conforme o cenário considerado. A quantidade de neurônios na camada de saída é igual a 1 e a função de ativação utilizada foi a sigmoidal.

A técnica de RNA foi executada variando o número de neurônios na camada oculta de 3 até 10 neurônios e o número de folds, para a partição dos dados de treino e de teste, também variou entre 3 e 10.

L. Validação

Para a etapa de validação, foram utilizadas as diferenças de resultados entre o modelo preditivo e o ensaio físico, cujos valores são tidos como exato. Por impossibilidade de afirmar

qual o valor aceitável para essa diferença, calculou-se o índice de desempenho Cd [30]. Esse índice é definido matematicamente como o produto do índice de concordância (d) [33] pelo coeficiente de correlação de Pearson (r). Resultados iguais ou superiores a 66,0% são considerados bons (Tabela V).

TABELA V CLASSIFICAÇÃO DO ÍNDICE DE DESEMPENHO (CD) [31]		
Classificação	Mínimo	Máximo
Ótimo	86,0%	100,0%
Muito bom	76,0%	85,0%
Bom	66,0%	75,0%
Mediano	61,0%	65,0%
Sofrível	51,0%	60,0%
Mal	41,0%	50,0%
Péssimo	0,0%	40,0%

Além disso é avaliado o desempenho dos cenários em relação à raiz do erro quadrático médio (RMSE) dos valores preditos e da acurácia da classificação dos resultados preditos.

M. Ambiente de Implementação

O modelo de RNAs foi adaptado a partir de um modelo de MLP com o backpropagation como algoritmo de treinamento, desenvolvido no ambiente Visual Basic for Applications® [34]. Os dados foram consolidados e tratados em planilhas auxiliares no ambiente Microsoft Excel®.

N. Outros Métodos

Durante o projeto foram também consideradas as técnicas de Regressão Linear Múltipla (RLM) e *Support Vector Machine* (utilizando o pacote libsvm), mas os resultados não foram satisfatórios. A RLM apresentou baixo valor de R^2 e o SVM *overfitting*. Diante disso, no presente artigo, não são apresentadas comparações.

III. RESULTADOS E DISCUSSÃO

Os resultados obtidos para as 256 combinações realizadas (4 cenários de seleção de variáveis com variação de 3 a 10 neurônios na camada oculta e variação de 3 a 10 folds para divisão das amostras) foram avaliadas em relação ao RMSE da etapa de validação. Na Tabela VI são descritas as parametrizações com o melhor resultado de RMSE de cada cenário.

TABELA VI PARAMETRIZAÇÕES DE MELHOR DESEMPENHO PARA OS CENÁRIOS A, B, C E D		
Cenário	Nº de variáveis	Topologia
A	41	8 neurônios e 7 folds
B	41	10 neurônios e 10 folds
C	16	9 neurônios e 4 folds
D	16	4 neurônios e 3 folds

O desempenho das redes neurais na etapa de treinamento para cada parametrização selecionada em cada cenário foi semelhante. Já na etapa de validação a diferença de desempenho foi mais relevante (Tabela VII). Destaca-se, nesse sentido, o cenário C com o maior coeficiente de desempenho

(Cd), menor RMSE e melhor acurácia, demonstrando melhor generalidade e, portanto, desempenho para a predição da R28.

TABELA VII
MEDIDAS DE DESEMPEÑO PARA VALIDAÇÃO DOS CENÁRIOS

Cenário	<i>d</i>	<i>R</i>	<i>Cd</i>	RMSE	Acurácia
A	0,75	0,58	0,43	1,47	85,2%
B	0,91	0,74	0,68	1,10	85,0%
C	0,88	0,77	0,68	1,07	96,3%
D	0,58	0,44	0,25	1,84	85,2%

Para ilustrar o desempenho para o cenário C, são apresentadas as Figura 2 e 3. Na Figura 2 é apresentado o diagrama de dispersão entre os resultados preditos na etapa de validação e os obtidos por meio do ensaio físico, observando-se a forte correlação existente ($r = 0,77$) e a compatibilidade entre os métodos para obtenção do resultado da R28.

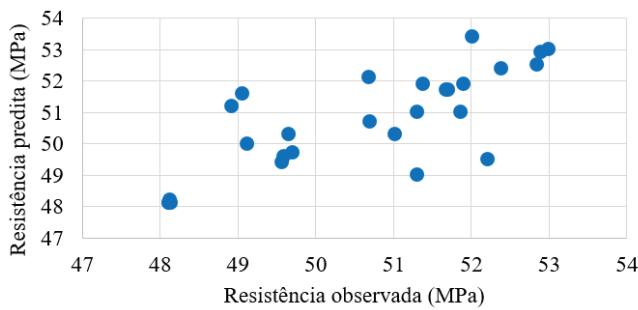


Fig. 2. Diagrama de dispersão entre os valores de resistência à compressão preditas e observadas para o CP II E 40 de Santa Helena.

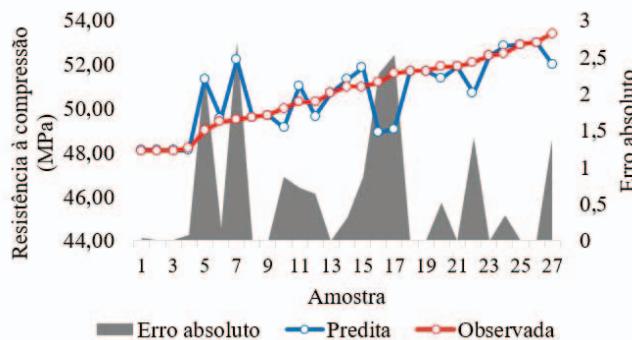


Fig. 3. Avaliação do erro absoluto da etapa de validação do cenário C.

Para a elaboração da Figura 3, os valores observados para resistência à compressão 28 dias (linha vermelha) são ordenados do menor para o maior. Já os valores preditos, para cada valor observado são apresentados na linha azul. Por fim, em cinza tem-se o erro absoluto entre os valores observados e preditos. É possível perceber que o erro do modelo é sutilemente influenciado pelo aumento da resistência, uma vez que se identifica uma tendência de diminuição do erro com o crescimento dessa, e que os valores preditos, em sua maioria, são iguais ou menores que os valores observados, conferindo ao modelo um perfil conservador.

A avaliação da classificação dos resultados gerados para a parametrização destaque do cenário C resulta em uma acurácia de 96,3% de acerto. Ao avaliar as categorizações por meio da matriz de confusão (Tabela VIII), é possível perceber que os

erros existentes estão relacionados à falsos positivos, ou alarmes falsos, reforçando novamente o perfil conservador do modelo. Destaca-se que operacionalmente falsos positivos podem ser considerados como de baixa criticidade

TABELA VIII

MATRIZ DE CONFUSÃO PARA CLASSIFICAÇÃO DOS RESULTADOS DO CENÁRIO C

		Conforme	Não conforme	% Correta
Conforme	22	1	95,7%	
Não conforme	0	4	100%	

Desta forma, a parametrização indicada para a predição de resistência à compressão considerando a metodologia de RNA, e a partir dos dados apresentados neste trabalho, considera 16 variáveis, selecionadas pela metodologia B2 [18] aplicadas em uma rede neural de topologia MLP com 9 neurônios na camada oculta e com divisão dos dados em 4 folds de treinamento.

IV. CONCLUSÃO

A predição de resistência à compressão de cimentos por meio da rede neural artificial se mostrou viável e com boa acurácia. Os erros existentes são considerados como alarmes falsos e o comportamento dos erros demonstra um perfil conservador para o modelo, conferindo maior segurança no uso da informação.

O resultado gerado por esse estudo apresenta alta correlação com os resultados obtidos pelos ensaios físicos, demonstrando compatibilidade entre os métodos. Esse fato cria a possibilidade de diversas ações gerenciais no que tange a garantia da qualidade dos cimentos expedidos. O prognóstico de possíveis desvios na qualidade do produto, especificamente da resistência à compressão, antes do mesmo ser entregue ao cliente, permite a redução de custos resultantes de resarcimentos provenientes de reclamação de clientes por falta de desempenho, bem como permite o início de um processo investigativo e de novas parametrizações do processo produtivo no intuito de mitigar esse tipo de impacto.

Com base nos históricos de reclamações disponibilizados pela Votorantim Cimentos para os anos de 2016 e 2017 e a identificação das causas, a possibilidade de redução de custos, no que tange o valor monetário dispendido em resarcimentos associados à desempenho de resistência à compressão, e considerando que as situações não conformes seriam identificadas pelo modelo preditivo com 96,3% de acurácia, é de aproximadamente 79% (valor obtido a partir da avaliação do número anual médio de reclamações e do valor monetário médio dos resarcimentos).

Além da redução de custo, a identificação de desvios permite que as correções necessárias no processo produtivo sejam mapeadas de forma proativa, melhorando a estabilidade na produção de cimento.

Outro resultado da implementação do modelo é obtenção dos possíveis valores da R28 em até 7 dias, reduzindo em 75% o tempo de espera pelos dados para avaliação final de desempenho.

A qualidade do modelo, aferida pelo coeficiente de desempenho, pode ser aprimorada a partir de um novo

treinamento da RNA considerando um maior número de amostras. Além disso, novas situações, como por exemplo, a troca de algum insumo ou variação das características do clínquer, devem ser consideradas na atualização do modelo, melhorando a capacidade de generalização das RNAs.

A metodologia apresentada neste estudo é facilmente replicável para os demais cimentos da Votorantim, reforçando seu grande potencial para redução de custo e otimização do processo produtivo. Além disso, sua acurácia e perfil conservador fornecem aos responsáveis informações confiáveis para que possam tomar decisões de forma segura.

REFERÊNCIAS

- [1] Associação Brasileira De Cimento Portland - ABCP. Guia básico de utilização do Cimento Portland, 7^a ed., São Paulo, 2002.
- [2] Associação Brasileira De Normas Técnicas - ABNT. Cimento Portland comum NBR 5732, 1991.
- [3] Akkurt, S.; Ozdemir, S.; Tayfur, G.; Akyo, B. The use of GA-ANNs in the modelling of compressive strength of cement mortar. *Cement and Concrete Research*, vol. 33, p. 973–979, 2003.
- [4] Zhang, Y.M.; Napier-Munn, T.J. Effects of particle size distribution, surface area and chemical composition on Portland cement strength. *Powder Technology*, vol. 83, p. 245–252, 1995.
- [5] Associação Brasileira De Normas Técnicas - ABNT. Cimento Portland - Determinação da resistência à compressão. NBR 7215, 1997.
- [6] Kheder, G.F.; Al Gabban, A.M.; Abid, S.M. Mathematical model for the prediction of cement compressive strength at the ages of 7 and 28 days within 24 hours. *Materials and Structure*, vol. 36, p. 693–701, 2003.
- [7] Topcu, I. B.; Karakurt, C.; Saridemir, M. Predicting the strength development of cements produced with different pozzolans by neural network and fuzzy logic. *Materials and design*, vol. 29, p. 1986-1991, 2008.
- [8] Mousavi, S. M.; Aminian, P.; Gandomi, A. H.; Alavi, A. H.; Bolandl, H. A new predictive model for compressive strength of HPC using gene expression programming. *Advances in Engineering Software*, vol. 45, p. 105-114, 2012.
- [9] Motamedl, S.; Shamshirband, S.; Petković, D.; Hashim, R. Application of adaptive neuro-fuzzy technique to predict the unconfined compressive strength of PFA-sand-cement mixture. *Powder technology*, vol. 278, p. 278-285, 2015.
- [10] Eskandari, H.; Tayyebinia, M. Effect of 32.5 and 42.5 cement grades on ANN prediction of fibrocement compressive strength. *Procedia Engineering*, vol. 150, p. 2193-2201, 2016.
- [11] Eskandari, H.; Kazemi, R. ANN prediction of cement mortar compressive strength, influence of cement strength class. *Construction and building materials*, vol. 138, p.1-11, 2017.
- [12] Hong-guang, N.; Ji-Zong, W. Prediction of compressive strength of concrete by neural networks. *Cement and Concrete Research*, vol. 30, p. 1245–1250, 2000.
- [13] Baykasoglu A., Dereli T., Tanis S. Prediction of Cement Strength Using Soft Computing Techniques. *Cement and Concrete Research*, vol. 34, p. 2083–2090, 2004.
- [14] M. A. Al-Shaher, M. M. Sabry, A. S. Saleh, “Fault location in multi-ring distribution network using artificial neural network”, *Elect. Power Syst. Research*, vol. 64, pp. 87-92, May 2002.
- [15] Y. Aslan, “An alternative approach to fault location on power distribution feeders with embedded remote-end power generation using artificial neural networks”, *Elect. Eng.*, vol. 94, no. 3, pp. 125-134, Sep. 2012.
- [16] Zayandehroodi, H., Mohamed, A., Farhoodne, M., Mohammadjafari, M., “An Optimal Radial Basis Function Neural Network for Fault Location in a Distribution Network with High Penetration of DG Units”, *Measurement*, vol. 46, no. 9, pp. 3319-3327, May. 2013
- [17] Camargo, A.P. and Sentelhas, P. C. Avaliação do desempenho de diferentes métodos de estimativas da evapotranspiração potencial no Estado de São Paulo, Brasil. *Revista Brasileira de Agrometeorologia*, Santa Maria, v.5, n.1, p.89-97, 1997.
- [18] Jolliffe, I. T. Principal Component Analysis. Springer Science & Business Media, 2^a edição, 2002
- [19] Mingoti, S. A. Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada. Editora UFMG, 2007.
- [20] Varella, C. A. A. Análise de componentes principais. 2008. Disponível em: <http://www.ufrj.br/institutos/it/deng/varella>. Acesso em novembro de 2017.
- [21] Fávero, L.P.; Belfiore, P.; Silva, F.L.; Chan, B.L. Análise de dados: modelagem multivariada para tomada de decisões. Rio de Janeiro, Elsevier, 2009.
- [22] Martineli, E. Extração de conhecimento de Redes Neurais Artificiais. Dissertação (Mestrado em Ciências) – USP, São Paulo, 1999.
- [23] Alpaydin, E. Introduction to Machine Learning. ISBN 026201243X. MIT Press, 2010.
- [24] Barreto, J. M. Introdução às redes neurais artificiais. Florianópolis: Universidade Federal de Santa Catarina, 2002.
- [25] Mello, M. T. Aplicação de redes neurais artificiais no processo de precificação de ações. Monografia em Ciência da computação. Instituto de Física e Matemática, Universidade Federal de Pelotas, Pelotas, 2004.
- [26] Braga, A. P.; Carvalho, A. P. L. F.; Ludermir, T. B. Redes neurais artificiais: teoria e aplicações. 2^a ed., Rio de Janeiro, LTC, 2011.
- [27] Fausett, L. Fundamentals of Neural Networks: architectures, algorithms and applications. Ed Prentice-Hall, New Jersey, 1994.
- [28] Haykin, S. Redes neurais: princípios e práticas. Tradução de Paulo Martins Engel, 2^a ed., Bookman, Porto Alegre, 2001.
- [29] R.P. Lippmann, "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine*, vol. 4, no. 2, pp. 4-22, Apr. 1987.
- [30] Rumelhart, D. E., Hinton, G. E., Williams, R. J. “Learning representations by back-propagating errors”, *Nature*, vol. 323, pp. 533–536, 1986.
- [31] A.K. Jain, Jianchang Mao , K.M. Mohiuddin, Artificial neural networks: a tutorial, *IEEE Computer Society* , vol. 29 , pp. 31-44 , Mar. 1996 .
- [32] Camargo, A.P; Sentelhas, P. C. Avaliação do desempenho de diferentes métodos de estimativas da evapotranspiração potencial no Estado de São Paulo, Brasil. *Revista Brasileira de Agrometeorologia*, Santa Maria, v.5, n.1, p.89-97, 1997.
- [33] Willmott, C. J. et al. Statistics for the evaluation and comparison of models. *Journal of Geophysical Research*, Ottawa, v.90, n.C5, p.8995-9005. 1985.
- [34] Rutyna, B. B.; Aplicativo de redes neurais artificiais com interface para usuário desenvolvido em VBA. Monografia de matemática industrial, Universidade Federal do Paraná. Curitiba, julho de 2015.



Tacius Moriggi possui graduação em Engenharia de Produção pela Universidade Federal do Paraná (2015) e mestrado em Engenharia de Produção na Universidade Federal do Paraná (2018). Atua como analista de projetos na Votorantim Cimentos no departamento de P&D & Qualidade. Tem experiência na área controle de qualidade, análises estatísticas de viabilidade técnica, desenvolvimento de aplicações para controle produtivo, banco de dados e gestão de projetos.



Gustavo Valentim Loch Possui graduação em Matemática Industrial pela Universidade Federal do Paraná (2007), graduação em Ciências Contábeis pela Universidade Positivo (2011), mestrado em Métodos Numéricos em Engenharia pela Universidade Federal do Paraná (2010) e doutorado em Métodos Numéricos em Engenharia pela Universidade Federal do Paraná (2014). Atualmente é professor do Departamento de Administração Geral e Aplicada da Universidade Federal do Paraná, atuando principalmente nos seguintes temas: Otimização combinatória,

Problema de Transporte, Engenharia da Qualidade e métodos de auxílio à decisão. Em 2015 foi premiado com Menção Honrosa no Prêmio Capes de Tese 2015



Marcos Augusto Mendes Marques possui graduação em Engenharia Elétrica pela Universidade Federal do Paraná (2003) e doutorado em Métodos Numéricos em Engenharia pela Universidade Federal do Paraná (2015). Atualmente é professor adjunto A do Departamento de Engenharia de Produção da Universidade Federal do Paraná. Tem experiência na área de Matemática e Estatística, com ênfase em Análise Numérica e Simulação, atuando principalmente nos seguintes temas: otimização, métodos estatísticos, regressão linear múltipla, descarte de variáveis, simulação, engenharia da qualidade e energia elétrica. Atualmente leciona as disciplinas de Engenharia da Qualidade, Manutenção e Confiabilidade, Sistemas de Medição e Metrologia, para o Departamento de Engenharia de Produção do Setor de Tecnologia da Universidade Federal do Paraná.