

APLICAÇÃO DE MACHINE LEARNING NA PREDIÇÃO DA RESISTÊNCIA DO CIMENTO.

Karina Santana Negreiros
Amanda Oliveira Senna
Josiane Menezes
Sergio Araki

RESUMO

As empresas atuantes na indústria cimenteira no Brasil têm despendido expressivos valores monetários em ressarcimentos a clientes insatisfeitos com a qualidade do cimento adquirido. Uma possível não conformidade que este cimento pode apresentar é a baixa resistência à compressão, uma característica avaliada em ensaio mecânico após um intervalo de 28 dias, posterior à sua produção - tempo em que se assume que o material apresenta resistência próxima à definitiva. Entretanto, ao passo em que é realizada a análise de uma pequena amostra referente a determinado lote, o mesmo já foi distribuído ao consumidor final, que, por vezes, o utiliza antes mesmo que tenha sido atestada sua qualidade. Utilizando-se do método de análise de dados denominado *machine learning*, o presente estudo de caso avalia a aplicação do algoritmo *Support Vector Regression* (SVR) para a criação de um modelo preditivo para os resultados do teste de resistência à compressão aos 28 dias (R28) do cimento tipo CPII, produzido pela empresa Votorantim Cimentos, como forma de identificar com antecedência possíveis desvios de qualidade e por tabela evitar prejuízos financeiros e impacto negativos na credibilidade da marca em decorrência da venda de produtos fora dos padrões estabelecidos pelos órgãos regulamentadores do setor no Brasil.

PALAVRAS CHAVE: *machine learning*, cimento, resistência à compressão, *Support Vector Regression*, indústria 4.0.

ABSTRACT

Companies from cement industry in Brazil have spent meaningful monetary values on refunding unsatisfied customers because of quality of acquired cement. A possible failure that cement could present is low resistance to compression, a feature assessed by a mechanical test performed 28 days after cement production - period of time in which is assumed that the material reaches resistance similar to its definitive one. However, while the analysis of a small sample of a production lot is in progress, the same production lot is already being distributed to the end users, who, sometimes, use it even before its quality has been assured. By using the data analysis method known as machine learning, this case study discuss the application of Support Vector Regression (SVR) algorithm for the creation of a predictive model for 28 days resistance to compression test (R28) results of cement CPII, produced by Votorantim Cimentos, as a way of previously identifying on company's brand reliability as possible quality deviations and, additionally, avoid financial losses and negative impact result of selling products out of standards established by sector regulating organs in Brazil.

KEY WORDS: machine learning, cement, resistance to compression, Support Vector Regression, industry 4.0.

INTRODUÇÃO

Em 2011, durante a Feira de Hannover, na Alemanha, surgiu o termo “Indústria 4.0”, correspondente a um novo modelo de produção marcado pela conexão (entre máquinas ou sistemas), que permite às indústrias o controle de sua cadeia de valor por meio da implementação de fábricas inteligentes - capazes de “alcançar cada vez mais eficiência, de forma autônoma e customizável, para conseguir prever falhas, agendar manutenções, se adaptar ao que não foi planejado de maneira ágil e versátil” (HELABS, 2019). Neste contexto, o foco deste estudo incide sobre as concepções da utilização de dados para o aprendizado de máquina, analisando informações de amostras coletadas dos processos em indústrias e os métodos de checagem dos mesmos. O objetivo deste projeto é aplicar tecnologias emergentes no contexto da indústria 4.0 nos processos de qualidade industrial, por meio do estudo de caso sobre a aplicação de algoritmos de *machine learning* para realizar a predição de um dos principais indicadores de qualidade do cimento tipo CPII, a resistência mecânica.

1. JUSTIFICATIVA

As perdas por fabricação de produtos defeituosos estão associadas à produção de produtos acabados ou componentes que não atendem aos requisitos mínimos de qualidade, não cumprindo o padrão de conformidade requerido no projeto (ANTUNES, 2008). O desvio de qualidade, além de causar prejuízos monetários compostos pela matéria prima, mão de obra, energia e tempo utilizados na fabricação, pode acarretar em ocorrência de acidentes, impactando a vida de milhares de pessoas.

2. METODOLOGIA

Segundo as definições de GIL (2010), a pesquisa classifica-se como descritiva, por “descrever as características do universo pesquisado” (*machine learning*, a indústria de cimento e sua importância), explanatória, por “ter como objetivo proporcionar maior familiaridade com o objeto de estudo ou problema” e bibliográfica, isto é, “elaborada a

partir de material já publicado, constituído principalmente de artigos de periódicos, livros e materiais disponibilizados na Internet” (VERGARA, 2009). Além disso, adotou-se abordagem quantitativa, pois o objetivo é verificar a aplicação de algoritmos de *machine learning* para realizar a predição dos indicadores de qualidade do cimento.

Este estudo de caso estabeleceu-se a partir de três etapas principais: pesquisa bibliográfica, análise exploratória dos dados disponibilizados pela Votorantim Cimentos sobre os testes de resistência à compressão R28 do cimento tipo CII e exploração de novas soluções para identificar com antecedência possíveis desvios de qualidade do cimento e apresentação do modelo proposto, desenvolvido a partir da utilização de bibliotecas do *python* e um conjunto de dados disponibilizado pela empresa com mais de 20.000 registros dos testes de qualidade.

3. MACHINE LEARNING

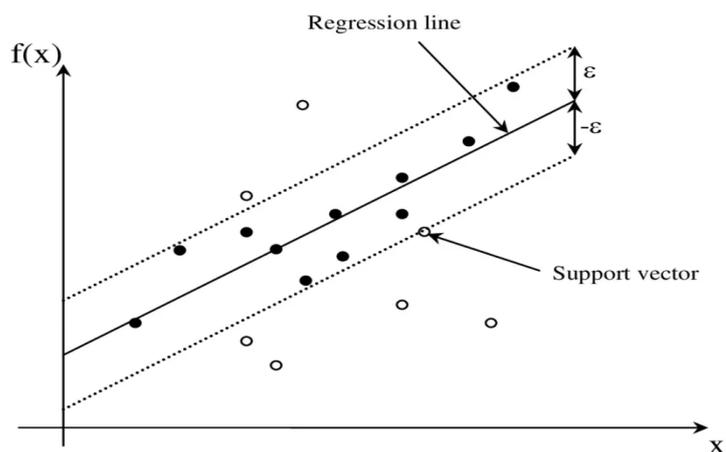
A partir da evolução do conceito de inteligência artificial, surgiu o termo *machine learning*, que segundo Shwartz e Ben-David (2014, p.7), refere-se à detecção automatizada de padrões em dados. Em suma, baseia-se na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana. Os métodos mais comumente empregados são: aprendizado supervisionado, aprendizado não-supervisionado, aprendizado semi-supervisionado e aprendizado por reforço. Hannun e Andrade (2018, p. 2) afirmam ainda que o *machine learning* desenvolve-se em etapas de aquisição de dados, limpeza e preparação (seleção e remoção de variáveis, *input* de dados), modelagem e implementação dos modelos - que podem ser dos tipos árvore de decisão, rede neural artificial, algoritmo do vizinho-mais-próximo e máquinas de vetores de suporte, por exemplo. Para a realização deste estudo, foi utilizado o método de aprendizado supervisionado e o modelo de máquinas de vetores de suporte, do inglês *support vector machines* (SVMs), cuja aplicação tem demonstrado resultados muitas vezes superiores aos obtidos por meio da utilização de Redes Neurais Artificiais (RNAs).

4. SUPPORT VECTOR MACHINES (SVMs)

Support vector machines (SVMs) são definidas como um conjunto de métodos de aprendizado supervisionado fundamentado na teoria de aprendizado estatístico, que foi

desenvolvida pelo matemático Vladimir Vapnik e seus colegas nos laboratórios da companhia de telecomunicações *AT&T Bell* e objetiva a proposição de técnicas de aprendizado que buscam maximizar a capacidade de generalização. Seu funcionamento é orientado essencialmente à resolução de problemas de classificação e detecção de *outliers* (valores atípicos). Para compreendê-lo, pode-se imaginar um conjunto de dados de duas classes distintas que deseja-se separar por meio da utilização de hiperplanos (conceito matemático que generaliza a noção de reta ou plano para várias dimensões). A SVM atua como a fronteira (hiperplano) que segrega estas duas classes da melhor maneira possível. Isso significa maximizar a margem, ou distância, entre os dois grupos, com o foco em minimização do erro, tendo em mente que parte dele é tolerada (RAY, 2017). Observa-se na figura 1 a representação gráfica do princípio de funcionamento das SVMs:

Figura 1: representação gráfica do princípio de funcionamento das SVMs.



Fonte: ResearchGate, 2019

As SVMs são treinadas normalmente a partir dos dados de entrada, gerando um classificador capaz de prever a classe ao indicar um valor de *score* com sinal para uma nova amostra de teste. Usando validação cruzada, são realizados diversos testes para prever o resultado com as diferentes amostras. Dependendo da qualidade do classificador, ele vai acertar algumas vezes e errar outras, e tais resultados são contabilizados. Segundo Lorena e Carvalho (2007, p. 43-44), este modelo pode ser aplicado à categorização de textos, análise imagens e bioinformática, por exemplo. Dentre as vantagens apresentadas, destacam-se sua efetividade e versatilidade, mesmo quando o número de dimensões é superior à quantidade de amostras. Embora, como mencionado anteriormente, seu

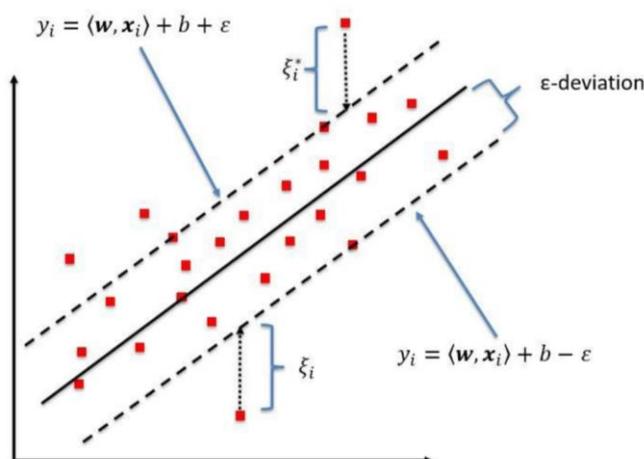
APLICAÇÃO DE MACHINE LEARNING NA PREDIÇÃO DA RESISTÊNCIA DO CIMENTO.

funcionamento seja orientado à resolução de problemas de classificação e detecção de *outliers*, pode-se utilizá-lo também para regressão. Para tal, realiza-se um passo de treinamento em que os valores da regressão são estimados a partir das probabilidades de pertinência às classes obtidas com testes adicionais.

5. SUPPORT VECTOR REGRESSION (SVR)

O método de classificação vetorial de suporte pode ser estendido para resolver problemas de regressão. Esse método é chamado de *Support Vector Regression* (SVR) e viabiliza o estudo com valores contínuos. Há três implementações diferentes de *Support Vector Regression*: SVR, *NuSVR* e Linear SVR. A versão utilizada neste trabalho foi a SVR. Na regressão simples, tenta-se minimizar a taxa de erro. Enquanto no SVR tentamos ajustar o erro dentro de certo limite, como pode ser observado na figura 2 a seguir.

Figura 2: Esquema do modelo de regressão vetorial de suporte unidimensional (SVR).



Fonte: Researchgate, 2019.

O objetivo da aplicação do SVR é basicamente considerar os pontos que estão dentro da linha limítrofe a função gerada pela regressão. A melhor linha de ajuste é o hiperplano de linha que tem o máximo número de pontos.

6. CIMENTO

De acordo com texto publicado pela Associação Brasileira de Cimento Portland (2002, p.5):

Cimento *portland* é a denominação convencionada mundialmente para o material usualmente conhecido na construção civil como cimento. O cimento *portland* é um pó fino com propriedades aglomerantes, aglutinantes ou ligantes, que endurece sob ação da água. Depois de endurecido, mesmo que seja novamente submetido à ação da água, o cimento *portland* não se decompõe mais.

De acordo com o Sindicato Nacional da Indústria do Cimento (2019), até o mês de abril de 2018 foram produzidas ao todo 17.069.777 toneladas do material no Brasil. Estes são dados preliminares, sujeitos a revisão, e incluem estimativas do cimento fabricado no país por misturadores e fábricas não associadas ao Sindicato Nacional da Indústria do Cimento (PRODUÇÃO, 2019). No Brasil, há 8 tipos de cimento disponíveis. No entanto, neste estudo, são analisadas amostras do cimento tipo CPII.

7. ESTUDO DE CASO

A Votorantim Cimentos é uma empresa brasileira de capital fechado fundada em 1933 e presente atualmente em doze países, dentre eles estão: Brasil, Argentina, China, Espanha, Estados Unidos e Índia. Com o foco no setor de construção e alvenaria, a empresa atua no negócio de materiais básicos como o cimento, concreto, agregados e produtos complementares, estando em oitavo lugar globalmente no setor. Sua capacidade produtiva está em torno de 52,2 milhões de toneladas por ano. No Brasil, a empresa trabalha com mais de quarenta produtos (VOTORANTIM, 2018).

Segundo a fabricante Cimento Montes Claros (2019), o CPII é atualmente o cimento mais vendido no mercado brasileiro, o que representa um produto estratégico do portfólio da Votorantim Cimentos. No entanto, no ano de 2016, mais de R\$ 5,6 milhões foram despendidos em ressarcimentos deste produto, devido a não conformidade na qualidade do produto, o que causa um impacto negativo para a reputação da empresa, além dos prejuízos financeiros que englobam o desperdício de matéria prima, utilização das máquinas, mão de obra, ressarcimento do produto em si, além de retrabalho.

Dado o problema, foi necessário buscar pela sua causa raiz para então solucioná-lo, assim utilizou-se primeiramente a ferramenta ‘5 Porquês’, que, segundo Liker (2004),

permite encontrar a causa primária do problema, de modo a identificar o que aconteceu, o porquê de ter acontecido e mapear uma solução para reduzir a probabilidade de que o problema reincida. Desta forma, obteve-se a tabela 1:

Tabela 1: 5 Porquês.

Problema: Alto índice de reclamações sobre o produto (cimento CII) e pedidos de reembolso do material vendido.	
Por que?	Porque há venda de cimento fora dos padrões de qualidade exigidos.
Por que?	Porque o nível de resistência de alguns lotes não atende aos padrões exigidos.
Por que?	Porque o resultado do teste de resistência só fica pronto após a venda.
Por que?	Porque o período para completar o teste é de 28 dias – maior do que o período de estoque do produto.
Por que?	Porque a metodologia atual do teste exige que haja um corpo de prova de 28 dias de cura.

Fonte: Autoria própria.

Após a aplicação da ferramenta, foi possível concluir que o fator do problema é que o tempo atual do teste de resistência do cimento CII exige que haja um corpo de prova de 28 dias após a fabricação, ou seja, o tempo supera o ideal para as necessidades de produção, estoque e venda da empresa.

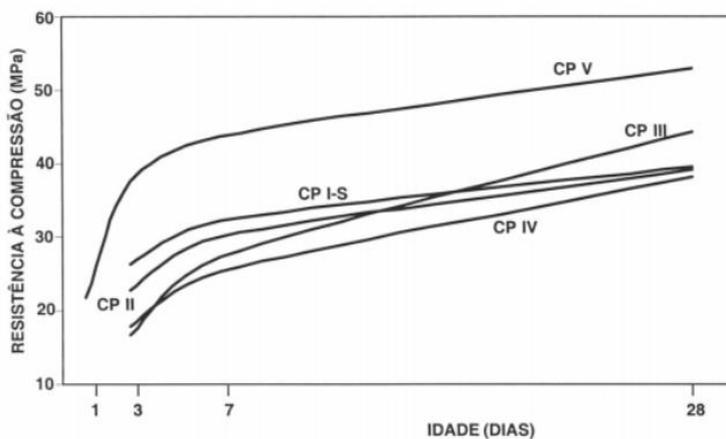
De forma a estruturar hierarquicamente as causas do problema identificando-as e, assim, relacionar com o efeito, compôs-se um diagrama espinha-de-peixe (*Ishikawa*), com intuito de representar os possíveis fatores e arquitetar um plano de ação com base na causa raiz identificada: metodologia do teste. Optou-se pela aplicação de algoritmos de *machine learning* como sistema de predição de falhas ou erros inerentes ao processo industrial.

7.1 Teste de Qualidade do Processo (As Is)

O teste de qualidade realizado atualmente pela organização a fim de constatar a resistência do cimento CII dá-se de forma amostral. Conforme Mehta e Monteiro (2014), a resistência de um material pode ser definida como sua capacidade de resistir a um determinado esforço de tensão sem se romper. Assim, relaciona-se a qualidade do concreto e as demais resistências e propriedades diretamente com a sua resistência à compressão.

No final do processo de fabricação do cimento, seguindo as diretrizes da norma ABNT NBR 5739, são retiradas pequenas amostras para construir os corpos de prova, que demoram cerca de 28 dias para curarem. O processo de cura do cimento consiste basicamente em evitar que ocorra a saída de água de dentro do concreto em idades iniciais. Segundo Neville (1997), para obtenção da resistência característica à compressão do concreto adota-se como referência a idade de 28 dias. O autor conclui dizendo não haver uma explicação científica para determinação da resistência aos 28 dias de idade, de forma que este período ficou definido de acordo com o moroso ganho de resistência do concreto somado a necessidade de medir sua resistência com o cimento já hidratado. Na figura 3 temos o desenvolvimento da resistência do cimento, desde o primeiro dia até o vigésimo oitavo, quando atualmente, obtém-se o resultado do teste.

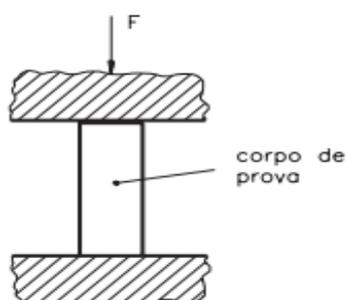
Figura 3: Desenvolvimento da resistência à compressão para os diferentes tipos de cimento para as idades de 1, 3, 7 e 28 dias.



Fonte: Associação Brasileira De Cimento Portland - ABCP, 2002.

Feito isto, os corpos de provas são direcionados aos laboratórios, enquanto o cimento segue sendo confeccionado em produção contínua e é direcionado a um estoque para virar carga a granel ou para ser ensacado para a venda de ensacados. Todavia, para ambos os casos, o tempo máximo de estoque do produto é de três dias, tendo em vista que só pode-se considerar que o cimento atingiu sua resistência característica (máxima) quando ele se estabiliza propriamente (no 28º dia), ou seja, o teste só deve ser executado após a estabilidade total do CII. O teste de resistência do concreto é feito pelo método do ensaio de compressão axial. Nos ensaios de compressão, os corpos de prova são submetidos a uma força axial para dentro, distribuída de modo uniforme em toda a seção transversal do corpo de prova, conforme figura 4.

Figura 4: Exemplo de força axial comprimindo corpo de prova.



Fonte: Ebah, 2011

Após o laboratório receber o corpo de prova da produção, este é armazenado em câmara úmida para cura. Vencido este prazo, o corpo de prova segue para setor do laboratório onde passa por nivelamento das superfícies para que encaixe perfeitamente na máquina que irá fazer o ensaio, e é então encaminhado para a última fase, chamada de rompimento. A máquina exerce uma força gradual de compressão sobre o CII até que haja o rompimento. Assim é calculado a força exercida no material, que é dividida pela área de topo do corpo de prova em cm^2 para obter a relação de kgf (quilograma força) exercido pela máquina por cm^2 , ou em MPa quando divide-se este valor por 10. É necessário que o cimento suporte uma força maior que 32 MPa para estar dentro do padrão de resistência e qualidade do concreto (COMO, 2015).

Durante o processo de fabricação e realização dos testes de qualidade algumas variáveis são coletadas, dentre elas: consistência, início de pega, fim de pega, blaine (determinação da finura pelo método de permeabilidade ao ar), resistência à compressão aos 3 dias, resistência à compressão aos 7 dias, quantidade de resíduo insolúvel presente no cimento, perda ao fogo, expansibilidade, teste de finura na peneira #200, teste de finura na peneira #325, e também variáveis referentes à composição química, como quantidade de dióxido de silício (SiO₂), óxido de alumínio (Al₂O₃), óxido de cálcio (CaO), óxido de ferro III (Fe₂O₃), óxido de potássio (K₂O), óxido de magnésio (MgO), óxido de sódio (Na₂O), dióxido de titânio (TiO₂) e óxido sulfúrico (SO₃).

8. MODELO

Inicialmente, foi realizada uma análise exploratória dos dados. Foram avaliados alguns pontos específicos que podem trazer grande influência nos modelos resultantes dos algoritmos de *machine learning*, decidindo por utilizar o SVR. O primeiro ponto analisado foi a confiabilidade dos dados e dos processos de qualidade para sanear a base utilizada no treinamento do algoritmo de predição de resistência. Utilizou-se 26 variáveis, das quais 5 são apenas de identificação (data, fábrica, tipo de cimento, classe e expedição) e dentre as 21 variáveis válidas, 18 delas possuem alguma observação vazia. Desta forma, a quantidade de observações (amostras) úteis para estudo e modelagem reduz a quantidade de amostras válidas, que corresponderam a 23.305 linhas.

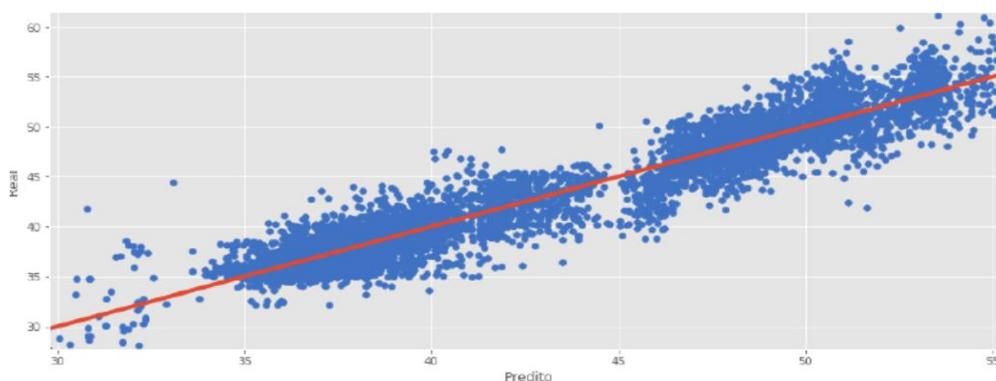
A falta de dados em alguns dos casos pode indicar a falta de padronização dos procedimentos de coleta, o que dificulta a generalização dos dados para formulação do modelo, pois esses não estão completos. Dada essa inconsistência, é necessário que as amostras com variáveis faltantes sejam removidas do modelo ou a própria variável seja excluída do treinamento, para criação de um modelo mais assertivo. A base de dados utilizada para esse teste foi um *excel.xlsx* chamado “dados consolidados.xlsx”. Esse arquivo com mais de 23.000 amostras simula a base da planta de um período de 3 meses para diversas plantas e diferentes tipos de cimentos. Para o tratamento do tipo de dados incluído nesse arquivo foi utilizada a biblioteca *pandas*, para fornecer análise de dados e suporte a modelagem para *Python*, *numpy*, para realizar cálculos em *Arrays* Multidimensionais, e *sklearn* que é uma biblioteca de aprendizado de máquina de código.

A execução do algoritmo completo ocorre em cerca de 4 minutos e 37 segundos, mas pode variar de acordo com a máquina que o processa. Antes da execução do algoritmo é importante que toda a base seja alimentada inclusive com os dados de tempo de pega e expansibilidade que são teste que demoram de 1 a 2 dias para ficarem prontos. Dessa forma, o tempo completo para disponibilizar o resultado da resistência seria de até 2 dias.

9. RESULTADOS

O modelo foi treinado com 2/3 dos dados selecionados aleatoriamente, e foi testado contra o 1/3 que não foi selecionado. O resultado do teste é visível na figura 5.

Figura 5: Comparação entre os resultados obtidos pelo algoritmo e resultados reais.



Fonte: autoria própria.

Os resultados apresentaram alta correlação com os resultados obtidos pelos ensaios físicos, demonstrando compatibilidade entre os métodos. Conseguimos observar também que para as predições onde temos maior número de amostras mais concentradas, indicando maior precisão do modelo criado e analogamente, quando o número de amostras é menor (próximo a região -30;-30), as predições ficam com um maior erro. Os pontos se mostram concentrados próximos à linha, indicando que o resultado predito ficou próximo do real. Com base nos dados testados, o modelo mostrou uma raiz de erro quadrático médio relativo de aproximadamente 5%, o que indica uma precisão na predição do modelo de 95%. Este fato abre a possibilidade de diversas ações gerenciais no que tange à garantia da qualidade dos cimentos expedidos.

Em um ambiente de produção, após a fabricação do lote de cimento, é necessário gerar a base de dados que alimenta o programa para realizar o teste. Os valores das variáveis: início de pega, fim de pega, expansibilidade e consistência, ficam prontos em até 24 horas e os das demais variáveis, captura-se no relatório químico da composição do cimento, que fica pronto em poucas horas após a produção. Ou seja, o modelo para predição da resposta do teste utilizando *machine learning* consegue mensurar o resultado da resistência à compressão do cimento produzido em um período entre um e dois dias, satisfazendo, assim, a necessidade da empresa, que possui um tempo de estoque do produto de 3 dias. Em relação ao teste atual - que leva 28 dias para ser aplicado, o modelo apresentado neste estudo de caso reduz em aproximadamente 92% o tempo. Além da redução de custo e otimização do processo, a identificação de desvios permite que as correções necessárias no processo produtivo possam ser feitas de forma proativa, melhorando a estabilidade de desempenho do cimento.

CONCLUSÃO

Com o surgimento da Indústria 4.0, uma transformação que é alimentada por evoluções tecnológicas que atribuem cada vez mais inteligência aos meios de produção em diversos níveis de uma corporação, as inovações nos mais diversos setores cresceram vigorosamente na última década. Tendo em vista estas inovações tecnológicas, esse estudo apresentou como a aplicação de algoritmos de *machine learning* pode acelerar a disponibilização dos resultados de qualidade do produto e conseqüentemente a elevação do nível de serviço prestado e garantia de satisfação dos clientes, além da economia financeira gerada a partir da redução de erros de produção. A utilização do SVR para criação de um modelo de predição para resistência do cimento demonstra muito potencial e obteve uma raiz de erro quadrático médio relativo de apenas 5%. Tendo como referência as reclamações procedentes relacionadas à baixa resistência à compressão para os anos de 2016 e 2017 e considerando a probabilidade de erro do modelo preditivo, seria possível a redução de 95% do valor monetário despendido por ano, que em 2016, representou aproximadamente R\$ 5,6 milhões.

Embora o índice de assertividade seja alto (95%), a análise de dados revela que a amostra de variáveis disponíveis atualmente não está tão completa quanto o desejado para a criação de modelos de predição ainda mais assertivos, ou seja, faz-se necessária uma

avaliação mais rigorosa dos resultados gerados pelo modelo. É, ainda sim, primordial realizar uma avaliação dos processos de qualidade executados em cada fábrica para entendimento se são equivalentes e se os dados podem, portanto, ser combinados para composição de modelos. Em suma, foi possível concluir que a predição da resistência de cimento por meio de algoritmos de *machine learning* é uma técnica válida, promissora e com alta capacidade de replicabilidade da abordagem para outras fábricas de fabricação de cimento, mas que precisa ser amadurecida e utilizada com conjuntos de dados suficientemente grandes para treinamento dos algoritmos e, assim, o aprimoramento da sua precisão.

REFERÊNCIAS

ANDRADE, L. M.; HANNUN, P. C. *The future is coming: promising perspectives regarding the use of machine learning in renal transplantation*. Artigo publicado em 2018. Universidade Estadual Paulista, Departamento de Medicina Interna, São Paulo. Disponível em:<http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0101-28002018005003703&lang=pt> Acesso em: 22 jan. 2019

ANTUNES, J. **Sistemas de Produção: Conceitos e práticas para projeto e gestão de produção enxuta**. Porto Alegre: Bookman, 2008.

ASSOCIAÇÃO BRASILEIRA DE CIMENTO PORTLAND - ABCP. **Guia básico de utilização do Cimento Portland**, 7ª ed., São Paulo, 2002.

COMO é feito o teste de resistência do concreto?, Incopre. Publicado em 22 de maio de 2015, Online. Disponível em<<http://incopre.com.br/index.php/como-e-feito-o-teste-de-resistencia-do-concreto/>> Acesso em: 11 mar. 2019

GIL, A. C., 2010, **Como elaborar projetos de pesquisa**. 5 ed. Atlas. São Paulo,

INDÚSTRIA 4.0: a nova era da tecnologia de ponta já começou!. Helabs. Online.

Disponível em: <<https://helabs.com/blog/industria-4-0-a-nova-era-da-tecnologia-de-ponta-ja-comecou/>> Acesso em 28 nov. 2018

LIKER, J. O Modelo Toyota: **14 Princípios de Gestão do Maior Fabricante do Mundo**. Bookman, Porto Alegre, 2007

LORENA, A.C; CARVALHO, A. C. P.L. F. **Uma Introdução às Support Vector Machines**. Artigo publicado em 2017, Universidade Federal do Rio grande do Sul. Disponível em <https://seer.ufrgs.br/rita/article/viewFile/rita_v14_n2_p43-67/3543> Acesso em: 05 abr. 2019

MEHTA, P. K.; MONTEIRO, P. J. M. **Concreto. Microestrutura, propriedades e materiais**. 2 ed .São Paulo: IBRACON, 2014. 751 p.

NEVILLE, A. M. **Propriedades do Concreto**. São Paulo: Pini, 1997.

OS tipos de cimento corretos para cada obra, Cimento Montes Claros, publicado em 21 de Julho de 2017, Online. Disponível em: <<https://cimentomontesclaros.com.br/tipos-de-cimento-para-cada-obra/>> Acesso em: 10 mar. 2019

PRODUÇÃO Nacional de cimento por Regiões e Estados 2018, SNIC, 2019. Online. Disponível em: <<http://snic.org.br/assets/pdf/numeros/1556548378.pdf>> Acesso em: 15 abr 2019

RAY, S. *Understanding Support Vector Machine algorithm from examples (along with code)*. *Analytics Vidhya*. Publicado em 13 de Setembro de 2017. Online. Disponível em:<<https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/>> Acesso em: 04 abr. 2019

RESEARCHGATE. *Example of linear SVM regression with-tube*. Disponível em: <https://www.researchgate.net/figure/Example-of-linear-SVM-regression-with-tube_fig7_316351306> Acesso em: 27 mar. 2019

RESEARCHGATE. *Schematic of the one-dimensional support vector regression (SVR) model*. Disponível em: <https://www.researchgate.net/figure/Schematic-of-the-one-dimensional-support-vector-regression-SVR-model-Only-the-points_fig5_320916953> Acesso em: 27 mar. 2019

SHWARTZ, S.S.; DAVID-BEN, S. *Understanding Machine Learning: From Theory to Algorithms*. *Cambridge University Press*. 2014. Online. Disponível em: <<https://www.cs.huji.ac.il/~shais/UnderstandingMachineLearning/understanding-machine-learning-theory-algorithms.pdf>> Acesso em: 27 mar. 2019

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. 10 ed. Atlas, São Paulo, 2009.

VOTORANTIM Cimentos em números. Votorantim, 2018. Online. Disponível em: <<https://www.votorantimcimentos.com.br/institucional/vc-em-numeros/>> Acesso em: 11 mar. 2019.