

UNIVERSIDADE FEDERAL DO PARANÁ

TACIUS MORIGGI

PREDIÇÃO DE PERFORMANCE DE CIMENTOS COMPOSTOS POR MEIO DA
APLICAÇÃO DE REDES NEURAS ARTIFICIAIS VISANDO A GARANTIA DA
QUALIDADE

CURITIBA

2018

TACIUS MORIGGI

PREDIÇÃO DE PERFORMANCE DE CIMENTOS COMPOSTOS POR MEIO DA
APLICAÇÃO DE REDES NEURAIAS ARTIFICIAIS VISANDO A GARANTIA DA
QUALIDADE

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre em Engenharia de Produção, do Programa de Pós-Graduação em Engenharia de Produção, Setor de Tecnologia, Departamento de Engenharia de Produção da Universidade Federal do Paraná.

Orientador: Prof. Dr. Gustavo Valentim Loch

Coorientador: Prof. Dr. Marcos Augusto Mendes Marques

CURITIBA

2018

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

M856p

Moriggi, Taciús

Predição de performance de cimentos compostos por meio da aplicação de redes neurais artificiais visando a garantia da qualidade / Taciús Moriggi. – Curitiba, 2018.

143 p. : il. color.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação Engenharia de Produção, 2018.

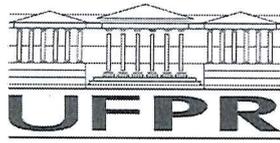
Orientador: Gustavo Valentim Loch – Coorientador: Marcos Augusto Mendes Marques.

Bibliografia: p. 118-125.

1. Cimento. 2. Controle Preditivo. 3. Redes neurais (Computação). I. Universidade Federal do Paraná. II. Loch, Gustavo Valentim. III. Marques, Marcos Augusto Mendes. IV. Título.

CDD: 624.15

Bibliotecário: Elias Barbosa da Silva CRB-9/1894



MINISTÉRIO DA EDUCAÇÃO
SETOR TECNOLOGIA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA DE
PRODUÇÃO

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA DE PRODUÇÃO da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **TACIUS MORIGGI** intitulada: **PREDIÇÃO DE PERFORMANCE DE CIMENTOS COMPOSTOS POR MEIO DA APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS VISANDO A GARANTIA DA QUALIDADE**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 24 de Maio de 2018.

GUSTAVO VALENTIM LOCH
Presidente da Banca Examinadora

JOSÉ ROBERTO FREGA
Avaliador Externo

FABIANO OSCAR DROZDA
Avaliador Interno

ANSELMO CHAVES NETO
Avaliador Externo

CASSIUS TADEU SCARPIN
Avaliador Interno

AGRADECIMENTOS

Agradeço a todos que colaboraram para a realização deste trabalho. O apoio de cada um foi fundamental e decisivo.

Ao meu orientador Gustavo Loch pela enorme paciência e pelos valiosos conselhos ao longo de todo o trabalho. Sem o seu apoio nada disso seria possível. Muito obrigado!

Obrigado ao Professor Marcos Augusto Mendes Marques pelas orientações e conselhos no desenvolvimento do trabalho. Seu apoio refinou a dissertação. Muito obrigado!

Agradeço também a todos os professores do Programa de Pós-Graduação em Engenharia de Produção (PPGEP) da UFPR cujas disciplinas frequentei. A experiência e a dedicação de cada um de vocês tiveram fundamental importância para que eu chegasse até aqui.

Agradeço muitíssimo a toda a equipe da Votorantim Cimentos, em especial a Silvia Regina Vieira pela confiança e apoio no desenvolvimento deste trabalho, bem como a todos os outros membros da equipe de P&D e Qualidade pela contribuição para a conclusão deste projeto. Meu carinho e respeito por cada um de vocês é imenso. Muito obrigado!

Aos meus pais Janice e Ulises pela imensurável dedicação, esforço e apoio ao longo destes anos. Vocês se dedicaram à minha educação e fizeram de mim o que eu sou hoje. Meus motivos para agradecer a vocês são inúmeros e nem todas as palavras são suficientes para descrever meu orgulho por vocês. Obrigado por tudo. Cada página deste trabalho tem um pouco de vocês.

“Always remember, your focus determines your reality.”

George Lucas

RESUMO

Avalia-se o resultado final de um processo produtivo a partir da aderência das características do produto aos requisitos de qualidade definidos por norma e necessidades específicas dos consumidores. Para que a avaliação não ocorra somente ao fim da produção, a aplicação de técnicas para auxiliar na avaliação de parâmetros ao longo do processo produtivo e identificação de possíveis desvios é importante. Para tal, é necessário que os dados disponíveis sejam transformados em informações úteis e com valor de decisão, tal que conclusões possam ser alcançadas em tempo hábil para manutenções e correções necessárias. Na produção de cimentos, e na consequente avaliação de qualidade, ocorre a verificação de características cujos intervalos de tempo entre sua análise e a disponibilização do resultado final são elevados. Nesse contexto o presente trabalho foi desenvolvido com o objetivo de prever, por meio da aplicação das Redes Neurais Artificiais (RNAs), o resultado de resistência à compressão aos 28 dias dos cimentos produzidos, a partir de parâmetros do fluxo produtivo. As RNAs apresentam a habilidade de aprender, por meio de um mapeamento de dados de entrada (*inputs*) e de suas relações com o resultado de saída (*output*), a sintetizar e gerar respostas apropriadas para um conjunto de novos *inputs*. Os resultados encontrados definem um modelo preditivo de perfil conservador e de forte correlação com os dados observados. Constata-se a vantagem da metodologia desse estudo em problemas de predição, visto a consideração de uma pequena quantidade de amostras para a realização do treinamento e da validação e a qualidade e potencial dos resultados finais.

Palavras-chave: modelo preditivo, redes neurais artificiais, resistência à compressão de cimentos, garantia de qualidade.

ABSTRACT

As a final 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 needs 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, some variables whose time intervals between their analysis and the availability of its final result is significant are verified. For this reason, the present study was developed with the objective of predict, through the application of the Artificial Neural Networks (ANN), the result of compressive strength at 28 days for the produced cements regarding parameters from the productive flow. ANN 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 define a predictive model with a conservative profile and with a strong correlation with the observed data, reinforcing the ability of this methodology to predictive problems, regarding the limitation of a small number of samples available for the training and the validation steps as well as the good and potential final results of this study.

Key-words: predictive model, artificial neural network, ANN, cement compressive strength, quality assurance.

LISTA DE FIGURAS

FIGURA 1 – FLUXO DE PRODUÇÃO DE CIMENTOS	25
FIGURA 2 – EMPILHAMENTO CIRCULAR E RETOMADA DO CALCÁRIO... 26	
FIGURA 3 – EMPILHAMENTO WINDROW DA ARGILA..... 27	
FIGURA 4 - EVOLUÇÃO MEDIA DA RESISTÊNCIA À COMPRESSÃO PARA OS DIFERENTES TIPOS DE CIMENTO	37
FIGURA 5 - APARELHO DE VICAT UTILIZADO NOS ENSAIOS DE TEMPO DE PEGA DO CIMENTO PORTLAND	38
FIGURA 6 – AGULHA DE LE CHATELIER..... 40	
FIGURA 7 - CONSTITUINTES DA CÉLULA NEURAL	57
FIGURA 8 - ESTRUTURA DE UM NEURÔNIO ARTIFICIAL..... 59	
FIGURA 9 - REDE FEEDFORWARD DE CAMADA ÚNICA	61
FIGURA 10 - REDE FEEDFORWARD COM MÚLTIPLAS CAMADAS	62
FIGURA 11 - REDE RECORRENTE SEM LAÇOS DE AUTO REALIMENTAÇÃO E SEM NEURÔNIOS OCULTOS	63
FIGURA 12 - REDE RECORRENTE COM NEURÔNIOS OCULTOS	64
FIGURA 13 - GRÁFICO DA FUNÇÃO DE LIMITE RÍGIDO	66
FIGURA 14 - GRÁFICO DA FUNÇÃO LINEAR	67
FIGURA 15 - GRÁFICO DA FUNÇÃO SIGMOIDAL	67
FIGURA 16 - ILUSTRAÇÃO DO ALGORITMO BACKPROPAGATION	69
FIGURA 17 – ENQUADRAMENTO DA PESQUISA	78
FIGURA 18 - ESTRUTURA DA METODOLOGIA APLICADA..... 80	

LISTA DE GRÁFICOS

GRÁFICO 1 – VARIÂNCIA INDIVIDUAL E ACUMULADA DOS COMPONENTE PRINCIPAIS.....	88
GRÁFICO 2 – RMSE DA ETAPA DE TREINO PARA AS PARAMETRIZAÇÕES DO CENÁRIO A.....	94
GRÁFICO 3 – RMSE DA ETAPA DE VALIDAÇÃO PARA AS PARAMETRIZAÇÕES DO CENÁRIO A	94
GRÁFICO 4 – CORRELAÇÃO DAS RESISTÊNCIAS PREDITAS E OBSERVADAS	95
GRÁFICO 5 – ERRO ABSOLUTO ENTRE AS RESISTÊNCIAS PREDITAS E OBSERVADAS	96
GRÁFICO 6 – RMSE DA ETAPA DE TREINO PARA AS PARAMETRIZAÇÕES DO CENÁRIO B.....	99
GRÁFICO 7 – RMSE DA ETAPA DE VALIDAÇÃO PARA AS PARAMETRIZAÇÕES DO CENÁRIO B	99
GRÁFICO 8 – CORRELAÇÃO DAS RESISTÊNCIAS PREDITAS E OBSERVADAS	100
GRÁFICO 9 – ERRO ABSOLUTO ENTRE AS RESISTÊNCIAS PREDITAS E OBSERVADAS	101
GRÁFICO 10 – RMSE DA ETAPA DE TREINO PARA AS PARAMETRIZAÇÕES DO CENÁRIO C	104
GRÁFICO 11 – RMSE DA ETAPA DE VALIDAÇÃO PARA AS PARAMETRIZAÇÕES DO CENÁRIO C	104
GRÁFICO 12 – CORRELAÇÃO DAS RESISTÊNCIAS PREDITAS E OBSERVADAS	105
GRÁFICO 13 – ERRO ABSOLUTO ENTRE AS RESISTÊNCIAS PREDITAS E OBSERVADAS	105
GRÁFICO 14 – RMSE DA ETAPA DE TREINO PARA AS PARAMETRIZAÇÕES DO CENÁRIO D	108
GRÁFICO 15 – RMSE DA ETAPA DE VALIDAÇÃO PARA AS PARAMETRIZAÇÕES DO CENÁRIO D	108

GRÁFICO 16 – CORRELAÇÃO DAS RESISTÊNCIAS PREDITAS E OBSERVADAS	109
GRÁFICO 17 – ERRO ABSOLUTO ENTRE AS RESISTÊNCIAS PREDITAS E OBSERVADAS	109

LISTA DE QUADROS

QUADRO 1 – NOMENCLATURA E COMPOSIÇÃO TÍPICA DA FARINHA	28
QUADRO 2 – ADIÇÕES NA PRODUÇÃO DE CIMENTOS	32
QUADRO 3 – CLASSIFICAÇÃO E NOMENCLATURA DOS CIMENTOS	33
QUADRO 4 – TEORES DOS COMPONENTES DO CIMENTO COMPOSTO.	34
QUADRO 5 – REQUISITOS FÍSICOS DOS CIMENTOS PORTLAND	36
QUADRO 6 – REQUISITOS FÍSICOS DE RESISTÊNCIA À COMPRESSÃO DOS CIMENTOS PORTLAND	36
QUADRO 7 - EXIGÊNCIAS QUÍMICAS DOS CIMENTOS PORTLAND	41
QUADRO 8 – PLANO DE AMOSTRAGEM DA VOTORANTIM CIMENTOS ...	43
QUADRO 9 - OBJETIVOS DAS AMOSTRAGENS DE CADA ETAPA.....	44
QUADRO 10 – VARIÁVEIS DE VERIFICAÇÃO E CONTROLE DAS ETAPAS CRÍTICAS	45
QUADRO 11 - INFLUÊNCIA DOS FATORES NO DESEMPENHO DOS CIMENTOS	46
QUADRO 12 – CONSOLIDAÇÃO DE TRABALHOS CORRELATOS.....	50
QUADRO 13 – PARAMETRIZAÇÃO DOS PRINCIPAIS TRABALHOS CORRELATOS	72
QUADRO 14– VARIÁVEIS CONSIDERADAS PARA A CARACTERIZAÇÃO DO CIMENTO.....	83
QUADRO 15 – VARIÁVEIS CONSIDERADAS PARA A CARACTERIZAÇÃO DO CIMENTO	85
QUADRO 16 – VARIÁVEIS SELECIONADAS PELO MÉTODO B2	88
QUADRO 17 – VARIÁVEIS SELECIONADAS PELO MÉTODO B4	89

LISTA DE TABELAS

TABELA 1 – AUTOVALORES E SELEÇÃO DOS COMPONENTES PRINCIPAIS	87
TABELA 2 – RESULTADO DA RNA PARA AS PARAMETRIZAÇÕES DO CENÁRIO A	93
TABELA 3 – MATRIZ DE CONFUSÃO PARA A PARAMETRIZAÇÃO DO CENÁRIO A	97
TABELA 4 – RESULTADO DA RNA PARA AS PARAMETRIZAÇÕES DO CENÁRIO B	98
TABELA 5 – MATRIZ DE CONFUSÃO PARA A PARAMETRIZAÇÃO DO CENÁRIO B	101
TABELA 6 – RESULTADO DA RNA PARA AS PARAMETRIZAÇÕES DO CENÁRIO C	103
TABELA 7 – MATRIZ DE CONFUSÃO PARA A PARAMETRIZAÇÃO DO CENÁRIO C	106
TABELA 8 – RESULTADO DA RNA PARA AS PARAMETRIZAÇÕES DO CENÁRIO D	107
TABELA 9 – MATRIZ DE CONFUSÃO PARA A PARAMETRIZAÇÃO DO CENÁRIO D	110
TABELA 10 – COMPARATIVO DOS CENÁRIOS.....	111

LISTA DE SIGLAS

AG – Algoritmo Genético

CQ – Controle de Qualidade

IA – Inteligência Artificial

RLM – Regressão Linear Múltipla

RNA – Redes Neurais Artificiais

SUMÁRIO

1	INTRODUÇÃO	16
1.1	TEMA E OBJETIVOS.....	18
1.1.1	Objetivo geral.....	19
1.1.2	Objetivos específicos.....	19
1.2	JUSTIFICATIVA.....	20
1.3	LIMITAÇÕES DO TRABALHO.....	21
1.4	ESTRUTURA DO TRABALHO.....	22
2	REVISÃO DA LITERATURA	23
2.1	PRODUTO CIMENTO.....	23
2.1.1	Conceituação.....	23
2.1.2	Fluxo produtivo.....	24
2.1.3	Adições.....	32
2.1.3.1	Escória de alto-forno.....	33
2.1.4	Controle de qualidade.....	34
2.1.5	Plano de amostragem.....	43
2.1.5.1	Etapas Críticas.....	44
2.2	TRABALHOS CORRELATOS.....	46
2.3	FUNDAMENTAÇÃO TEÓRICA.....	52
2.3.2	Inteligência Artificial.....	53
2.3.3	Aprendizagem de máquina.....	53
2.3.3.1	Redes Neurais Artificiais.....	55
2.3.3.1.1	Histórico.....	55
2.3.3.1.2	Cérebro humano.....	57
2.3.3.1.3	Neurônio Artificial.....	58
2.3.3.1.4	Arquiteturas de rede.....	60
2.3.3.1.5	Processos de aprendizado.....	64
2.3.3.1.6	Função de ativação.....	66
2.3.3.1.7	Treinamento.....	68
2.3.3.1.8	Medidas de erro de uma rede MLP.....	70
2.3.3.1.9	Redes neurais na avaliação de qualidade de cimentos.....	71
2.3.4	Análise de Componentes Principais (ACP).....	73
2.3.5	Seleção das variáveis.....	75

2.3.6	K-fold.....	76
3	MÉTODO DE PESQUISA	77
3.1	CLASSIFICAÇÃO DA PESQUISA.....	77
3.2	MATERIAIS E MÉTODOS.....	79
4	DESENVOLVIMENTO E RESULTADOS	82
4.1	DELIMITAÇÃO DO PROBLEMA.....	82
4.2	SELEÇÃO DA AMOSTRA.....	84
4.3	CENÁRIOS AVALIADOS.....	84
4.4	TRATAMENTO INICIAL DOS DADOS.....	85
4.4.1	Normalização das variáveis.....	85
4.4.2	Redução da dimensionalidade.....	86
4.4.3	Seleção das variáveis.....	88
4.5	TREINAMENTO E TESTE.....	89
4.6	TÉCNICA DE REDES NEURAIS ARTIFICIAIS.....	90
4.6.1	Parametrização do modelo de RNA.....	91
4.7	RESULTADOS OBTIDOS E DISCUSSÃO.....	91
4.7.1	Cenário A.....	92
4.7.2	Cenário B.....	97
4.7.3	Cenário C.....	102
4.7.4	Cenário D.....	106
4.8	COMPARAÇÃO ENTRE OS CENÁRIOS.....	110
5	CONSIDERAÇÕES FINAIS E CONCLUSÃO	113
5.1	CONCLUSÃO.....	113
5.2	ESTUDOS FUTUROS.....	116
	REFERÊNCIAS	118
	APÊNDICE 1 – DADOS UTILIZADOS PARA O DESENVOLVIMENTO DA RNA PARA O CENÁRIO A	126
	APÊNDICE 2 – DADOS UTILIZADOS PARA O DESENVOLVIMENTO DA RNA PARA O CENÁRIO B	133
	APÊNDICE 3 – DADOS UTILIZADOS PARA O DESENVOLVIMENTO DA RNA PARA O CENÁRIO C	136
	APÊNDICE 4 – DADOS UTILIZADOS PARA O DESENVOLVIMENTO DA RNA PARA O CENÁRIO D	140

CAPÍTULO I

1 INTRODUÇÃO

Os processos produtivos possuem como um dos seus principais critérios de desempenho a qualidade de seus produtos e serviços finais, cuja implicação no fluxo de produção está associada às premissas de não cometer erros e atender às expectativas dos consumidores. Além disso, a garantia de produtos e serviços com qualidade auxilia na redução de custos, no aumento da estabilidade e na eficiência das plantas, bem como na confiabilidade frente aos consumidores (SLACK; CHAMBERS; JOHNSTON, 2009).

Considerando a produção de cimentos, foco deste trabalho, identifica-se nas normas técnicas regulamentadoras a existência de diversas características cujo cumprimento é mandatório para que se verifique qualidade e desempenho mínimos necessários. Dentre elas, a de maior importância é a resistência à compressão aos 28 dias (AKKURT, A. *et al.* 2002; ESKANDARI, NIK e EIDI, 2016; ESKANDARI-NADDAF e KAZEMI, 2017).

O ensaio de resistência à compressão de cimentos é realizado em um corpo de prova cilíndrico, no qual é imposta uma força de compressão e então é aferida a capacidade da peça em suportar esse esforço. O resultado desse ensaio é definido em unidades de pressão (MPa). Além disso, os corpos de prova podem ficar em cura durante 1, 3, 7 e 28 dias (ABCP, 2002; NBR 7215, 1996).

Devido o longo tempo para a obtenção da resistência à compressão aos 28 dias e pela sua elevada importância para a garantia da qualidade, diversos modelos preditivos foram desenvolvidos na literatura com o objetivo de adiantar essa resposta. No entanto, o número de variáveis do processo que exercem influência nesta característica de desempenho 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. Além disso, a definição das variáveis é condicionada às etapas do processo consideradas e ao tipo de cimento estudado (AKKURT, OZDEMIR, TAYFUR e AKYOL, 2003).

É possível encontrar na literatura a aplicação de metodologias com esse objetivo. Parassakis (1994) buscou a aplicação de Regressões Lineares Múltiplas (RLMs) a partir de 8 variáveis, considerando características mineralógicas, químicas e físicas das matérias-primas e do cimento produzido. Tango (1998) propôs um método de extrapolação baseado nas resistências à compressão em idades iniciais (2 e 7 dias). Akkurt *et al.* (2003) aplicaram as metodologias de Redes Neurais Artificiais (RNAs) e Algoritmos Genéticos (AGs) considerando vinte variáveis de influência do processo. Da mesma forma Fa-Liang (1994) e Akkurt, Tayfur e Can (2004) consideraram a lógica fuzzy e a metodologia de RNA para a previsão da resistência à compressão aos 28 dias de cimentos.

A maioria dos trabalhos citados partiram de considerações semelhantes e encontraram resultados satisfatórios para os objetivos por eles propostos. O que pode ser notado é que o avanço das metodologias permitiu a consideração de um maior número de variáveis e a consequente compreensão das relações de influência entre elas. Contudo, ainda existe espaço para melhorias no que tange a consideração de diferentes cenários quando se consideram cimentos com adições.

A possibilidade de substituição do clínquer na composição do cimentos é atrativa financeiramente e ambientalmente, uma vez que o clínquer representa a maior parcela, cerca de 70%, do custo dos cimentos, bem como é o principal responsável pela emissão de dióxido de carbono (CO₂) ao longo de todo o processo produtivo, o que pode ser reduzido com a consideração das adições.

Esse trabalho busca, portanto, uma indicação da qualidade da principal variável de desempenho dos cimentos, a resistência à compressão aos 28 dias, considerando as adições de escória, por meio de predição baseada em variáveis acessíveis às unidades produtoras, visto que nem todos os dados considerados em trabalhos anteriores estão disponíveis nestas. Assim, garantindo-se que o estudo esteja alinhado com as intenções do mercado cimenteiro atual e que possa ser implementado e replicado nas unidades produtoras da Votorantim Cimentos.

1.1 TEMA E OBJETIVOS

O início da inteligência artificial pode ser definido como um período de buscas ficcionais e imaginativas, visionadas pelas áreas da filosofia e engenharia na tentativa de definir o verdadeiro significado do ser humano. Tais tentativas objetivaram a resolução de problemas de aprendizagem, representação do conhecimento, inferência, bem como provas teóricas e criação de sistemas baseados em conhecimento. Contudo, apenas recentemente foi possível construir máquinas experimentais que testassem hipóteses sobre os mecanismos de pensamento e do comportamento inteligente, demonstrando, desta forma, mecanismos que anteriormente existiam apenas como possibilidades teóricas (BUCHANAN, 2006).

Com o início da neurocomputação, diversos estudos e teorias foram desenvolvidas. Destas, uma de grande influência foi a pesquisa de McCulloch e Pitts (1943), na qual os autores mostraram que tipos simples de redes neurais artificiais seriam capazes de computar qualquer função aritmética ou lógica.

De acordo com Gurney (2004), as RNAs são frequentemente usadas para análise estatística e modelagem de dados, em que seu papel é percebido como uma alternativa à RLM ou técnicas de análise de agrupamento. Assim, elas são tipicamente utilizadas em problemas que podem ser formulados em termos de classificação ou de previsão. Alguns exemplos incluem reconhecimento de imagem e fala (SILVA, VELLASCO e CATALDO, 2017; DOĞAN, ARSLAN E CEYLAN, 2015), diagnósticos médicos (PEREIRA *et al.*, 2016; ELSALAMONY, 2017) e modelos preditivos para desempenho (AKKURTA, TAYFURB e CANC, 2004; GHRITLAHRE e PRASAD, 2017).

De acordo com Bakircioğlu e Koçak (2000), devido à sua arquitetura, as RNAs podem superar a maioria das limitações computacionais, uma vez que são treinadas em dados de exemplos reais e, por esse motivo, se mostram mais adaptáveis às mudanças.

Neste estudo pretende-se trabalhar o conceito de RNA dentro do processo produtivo de cimentos, mais especificamente no modelo de previsão de desempenho para a garantia de qualidade. Diferentemente de muitos trabalhos que consideram cimentos puros (sem adições) para a previsão da

variável resposta, no presente trabalho foi considerada a adição de escória, bem como as interações da mesma na composição e desempenho final dos cimentos, criando um novo cenário para o número e categorias de variáveis que devem ser analisadas. Além disso, também foram consideradas as pesquisas e conhecimentos estabelecidos na Votorantim Cimentos como fonte de dados confiável para a seleção das variáveis de influência na resistência à compressão.

Nesse sentido, tem-se como problema de pesquisa a ser resolvido: “Como prever a resistência à compressão aos 28 dias de cimentos com adição de escória, considerando um conjunto de ensaios técnicos necessários e viáveis às unidades produtoras, de forma a prever a avaliação de desempenho e, por consequência, garantir a expedição de cimentos com qualidade? ”.

1.1.1 Objetivo geral

Desenvolver um modelo preditivo para a resistência à compressão aos 28 dias dos cimentos produzidos com adição de escória por meio da aplicação das RNAs, possibilitando o prognóstico do desempenho do produto em sua aplicação final para a garantia de qualidade.

1.1.2 Objetivos específicos

Os objetivos específicos constituem os passos necessários para formação do conhecimento requerido para o desenvolvimento do modelo preditivo de resistência à compressão de cimentos, e podem ser sumarizados nos seguintes pontos:

- Descrever o fluxo produtivo de cimentos identificando as etapas críticas e as variáveis de controle;
- Caracterizar as escórias por meio de dados da literatura, bem como as particularidades deste insumo na empresa estudada, identificando as suas influências nas principais características dos cimentos;
- Realizar uma avaliação das principais metodologias de predição de resistência de cimentos por meio de estudos destacados na literatura;

- Caracterizar a metodologia de RNAs, buscando a sua aplicação no trabalho estudado para gerar um modelo preditivo para os cimentos compostos da Votorantim Cimentos;
- Definir, a partir de referências da literatura e dos conhecimentos estabelecidos na companhia estudada, um conjunto de variáveis fundamentais e acessíveis às unidades produtoras;
- Avaliar, a partir da Análise de Componentes Principais, a possibilidade de redução do número de variáveis no modelo;
- Verificar a acurácia do modelo desenvolvido por meio da comparação dos resultados preditos com os valores reais;

1.2 JUSTIFICATIVA

A continuidade do processo produtivo conduz a verificações dos parâmetros de desempenho que garantem a qualidade final do produto. Para a produção de cimentos, objeto de estudo deste trabalho, são verificadas as suas características químicas e físicas perante aos valores estabelecidos por norma, e também exigências comerciais. Destas, a resistência à compressão aos 28 dias é a mais importante (AKKURT, S. *et al.* 2003; ZHANG, Y.M., NAPIER-MUNN, T. J., 1995).

Verificando o intervalo de tempo entre o final do processo produtivo e a liberação dos resultados de qualidade (período de 28 dias), sentiu-se a necessidade na Votorantim Cimentos de acelerar a obtenção da resposta da principal variável de desempenho. Desta forma, torna-se necessário prever, em tempo hábil, desvios no produto.

A identificação de tais desvios pode evitar falhas de desempenho na aplicação final do produto, bem como sinalizar ajustes no fluxo produtivo corrigindo os pontos necessários para que produtos irregulares não sejam continuados e para que não ocorram perdas de tempo e de recursos (KHEDER, GABBAN E ABID, 2003; AKKURT, S. *et al.* 2003).

Na literatura pesquisada, encontram-se estudos que abordam métodos de RLMs, lógica fuzzy, AGs e RNAs como técnicas de modelos de predição da resistência. Destas, a técnica de RNA é uma das indicadas para a previsão, pois

ao tentar simular o funcionamento do cérebro humano, adquirindo conhecimento para a solução do problema por meio do processo de aprendizado, torna-se capaz de lidar com dados ruidosos, incompletos ou imprecisos. Além disso, seu perfil interdisciplinar e sua habilidade de prever sistemas complexos faz com que a sua aplicação seja robusta e amplamente recomendável (FAUSETT, 1994; HAYKIN, 2001).

Como também afirmam os autores, os desvios da metodologia de RNA são minimizados pela sua habilidade de aprender de seu ambiente por meio de um processo iterativo, e com isso melhorar seu desempenho.

Os ganhos possíveis com o prognóstico da variável de resistência à compressão podem ser sumarizados em velocidade para correções no processo produtivo, garantia de qualidade dos cimentos entregues ao consumidor, redução de perdas monetárias por ressarcimentos devido a mal desempenho, e embasamento para tomada de decisões. Além disso, como afirmam Akkurt, S. *et al.* (2003) e que é particularmente válido no ambiente atual da Votorantim Cimentos, a geração dessas informações permite condições favoráveis para ajustes das variáveis de interesse de forma a obter a resistência à compressão desejável.

1.3 LIMITAÇÕES DO TRABALHO

A presente pesquisa se restringe a encontrar uma solução para o problema de predição da resistência à compressão de cimentos aos 28 dias. A implementação e eventuais decisões gerenciais e operacionais consequentes da predição, por limitação de tempo do escopo e realização, não são responsabilidade do trabalho aqui exposto.

Além disso, a validação dos resultados da presente pesquisa é limitada aos dados reais de apenas uma unidade produtiva, sabendo que o mesmo comportamento pode não ser necessariamente o mesmo em outras unidades e, portanto, entende-se a necessidade de replicação da metodologia aqui apresentada para outros casos a fim de encontrar a combinação de ensaios técnicos que forneça a melhor acurácia para a variável resposta estudada.

Também se limita à consideração de normas brasileiras, sem a intenção de comparar os resultados com metodologias internacionais.

1.4 ESTRUTURA DO TRABALHO

Com a finalidade de alcançar os objetivos previamente delineados, o presente trabalho se apresenta segmentado em seis capítulos.

O primeiro capítulo, já apresentado, é introdutório, onde se definem o problema abordado, os limites da pesquisa, os objetivos geral e específicos do trabalho, bem como a justificativa do estudo.

O segundo capítulo está concentrado no detalhamento do problema estudado, com o objetivo de proporcionar a compreensão do fluxo produtivo e as principais características dos cimentos, os requisitos de qualidade e a estrutura do controle de qualidade existente nas unidades da Votorantim Cimentos. Além disso descreve a fundamentação teórica sobre a metodologia das Redes Neurais Artificiais, bem como consolida os trabalhos correlatos encontrados na literatura.

No capítulo III são apresentados os aspectos metodológicos pertencentes ao trabalho, tais como a natureza e o enquadramento da pesquisa. Além disso, é retratado qual o sistema utilizado para a coleta de dados e ainda a descrição da implementação da técnica de predição ao problema estudado.

O capítulo IV demonstra a aplicação da metodologia deste estudo e exhibe os resultados alcançados, os quais são avaliados e comparados para a seleção do melhor desempenho.

Por fim, o capítulo V conclui os resultados do trabalho e sugere alguns pontos para desenvolvimento de trabalhos futuros.

CAPITULO II

2 REVISÃO DA LITERATURA

Neste capítulo tem-se por objetivo apresentar uma visão geral sobre os principais aspectos do produto cimento com foco na garantia de qualidade e de performance do produto. Além disso, visa expor uma consolidação das principais técnicas da Inteligência Artificial (IA) aplicadas em modelos preditivos de resistência à compressão por meio da pesquisa e análise de trabalhos correlatos. Na sequência é realizada a análise e seleção da melhor técnica, bem como a descrição detalhada desta por meio de pesquisas bibliográficas.

2.1 PRODUTO CIMENTO

Esta seção descreve o produto cimento, sua rota de produção e particularidades.

2.1.1 Conceituação

De acordo com a Associação Brasileira de Cimento Portland - ABCP (2002), o cimento Portland pode ser definido como um pó fino com propriedades ligantes que endurece sob a ação da água. A mistura deste insumo com água e outros materiais, como areia, pedra britada, cal e outros, resulta nos concretos e argamassas utilizados nos vários tipos de obras construtivas .

Segundo a NBR 5732, o cimento Portland é obtido pela moagem de clínquer ao qual se adiciona a quantidade necessária de uma ou mais adições de acordo com os teores especificados em normas regulamentadoras. As diferentes composições resultam em diferentes tipos de cimento, a maioria servindo para uso geral, mas alguns com certas características e propriedades que os tornam mais adequados para determinados usos, permitindo que se obtenha um concreto ou uma argamassa com a resistência e durabilidade adequadas e de forma econômica (ABCP, 2002).

Na seção seguinte são detalhadas as matérias-primas e os produtos intermediários do fluxo produtivo do produto estudado, bem como os diferentes tipos de cimento e seus requisitos normativos. As informações e dados apresentados se referem ao manual de operações da Votorantim Cimentos (VOTORANTIM, 2013).

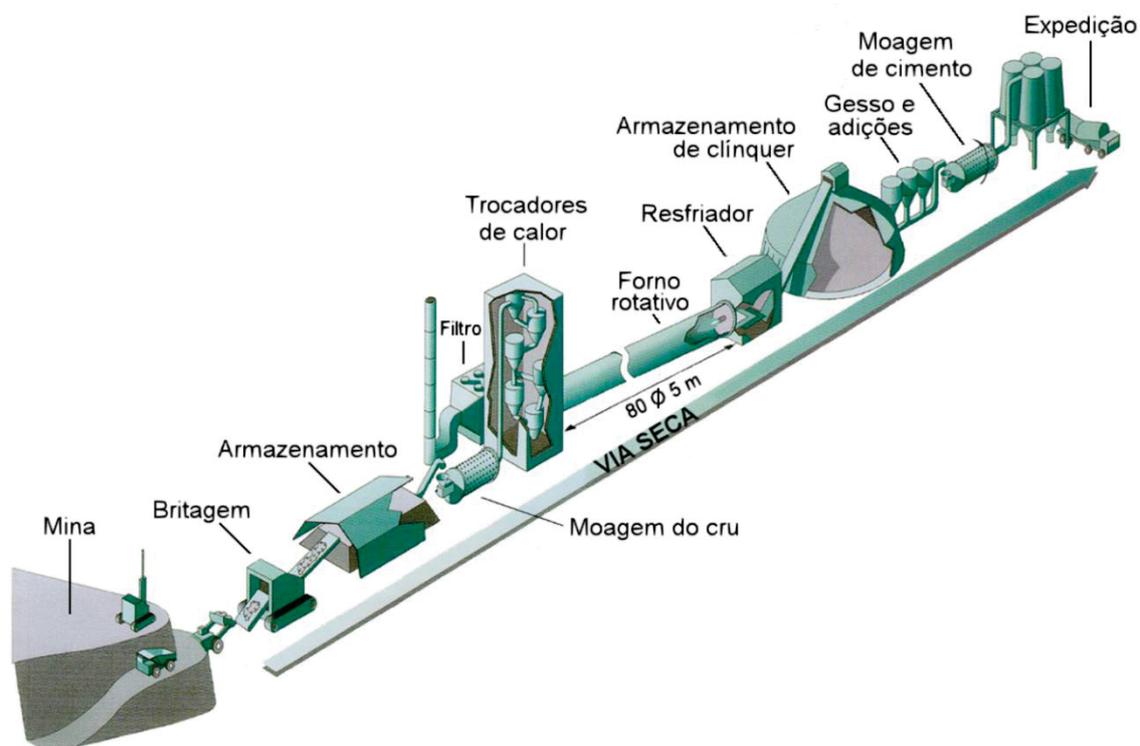
2.1.2 Fluxo produtivo

O fluxo produtivo de cimento, ilustrado na FIGURA 1, consiste no processo de transformação físico-químico de matérias-primas de origem mineral em uma mistura de minerais sintéticos com características ligantes que, quando misturado com água, desenvolvem resistência mecânica à compressão.

De forma simplificada, pode-se separar o processo produtivo do cimento em 6 etapas principais:

- **Mineração:** etapa de extração dos minerais (calcário, argila e corretivos), britagem primária, classificação granulométrica e transporte para a unidade.
- **Pré-homogeneização:** operações de empilhamento e retomada dos materiais.
- **Moagem de cru:** dosagem e moagem dos materiais para composição da farinha.
- **Clinkerização:** transformação da farinha em clínquer, material intermediário na produção de cimento.
- **Moagem de cimento:** moagem do clínquer produzido com gesso e demais adições.
- **Ensacamento e expedição:** os cimentos produzidos são armazenados em silos e posteriormente expedidos de acordo com a necessidade do mercado.

FIGURA 1 – FLUXO DE PRODUÇÃO DE CIMENTOS



FONTE: Votorantim Cimentos, 2013.

Sendo o cimento um produto de mineração, sua qualidade e propriedades são intrinsecamente dependentes da composição e homogeneidade dos minérios que o compõem, e por esse motivo as etapas identificadas devem apresentar um controle de qualidade eficiente.

Na etapa de mineração é realizada a extração dos minerais que serão utilizados para a produção de cimentos. Materiais compostos por sílica (SiO_2), alumina (Al_2O_3), óxido de ferro III (Fe_2O_3) e óxido de cálcio (CaO) são válidos para a produção de cimento, observando-se não somente a sua composição química, mas também a mineralogia desses materiais.

Os minérios que proporcionam essa composição química e estrutural necessária à produção de clínquer são o calcário e a argila. Diferentes minérios, como o minério de ferro, a bauxita, a areia e outros são também utilizados como corretivos, de forma a retificar a deficiência de composição dos elementos principais.

Após a extração, ocorre o processo de britagem para a redução da granulometria por meio de equipamentos que causam cisalhamento e abrasão

nas rochas. Esse processo é também denominado como britagem primária, e ocorre ainda na jazida a fim de facilitar o transporte dos materiais para a fábrica. Após a britagem primária, o material é classificado granulometricamente por um peneirador mecânico, atingindo assim as especificações de uso. Com o fim dessa etapa, as matérias-primas são transportadas até a fábrica.

Nesta etapa, o Controle de Qualidade (CQ) define as metas de composição química do material, denominado como cru, que seguirá para fábrica e alimentará o fluxo, garantindo que as propriedades tanto químicas como físicas do produto final sejam alcançadas.

A etapa de pré-homogeneização do calcário é realizada em duas fases:

- Empilhamento: o calcário é empilhado em linha, à céu aberto, seguindo um padrão de camadas contínuas formando uma pilha. Quanto mais alta for a pilha, ou seja, quanto mais camadas contínuas tiver, mais homogêneo será o material e menor o desvio das características químicas.
- Retomada: é o processo de coleta do material em coluna, para que todas as camadas da fase de empilhamento sejam alcançadas ao mesmo tempo, coletando o cru da forma mais homogeneizada possível.

Na FIGURA 2 é possível observar, como exemplo, o padrão de empilhamento circular integrado com a atividade de retomada.

FIGURA 2 – EMPILHAMENTO CIRCULAR E RETOMADA DO CALCÁRIO



FONTE: Votorantim Cimentos, 2013.

A pré-homogeneização da argila, por sua vez, segue um padrão específico de empilhamento pelo fato desta matéria-prima necessitar de armazenamento em local coberto para controle de sua umidade. No padrão denominado *Windrow*, o material é empilhado em camadas longitudinais, reduzindo consideravelmente a segregação do material. Na FIGURA 3 é possível observar este padrão de empilhamento.

FIGURA 3 – EMPILHAMENTO WINDROW DA ARGILA



FONTE: Votorantim Cimentos, 2013.

A realização do empilhamento e a conseqüente retomada, reduzem a variação das matérias-primas, garantindo que o processo subsequente receba um material de características estáveis. Nesta etapa, o CQ realiza o monitoramento das características químicas dos materiais homogeneizados, evitando flutuações na composição das matérias-primas e garantindo a estabilidade das etapas subsequentes.

Após o processamento e homogeneização inicial das matérias-primas, é realizada a dosagem dos materiais por meio de balanças automatizadas, e envio destes para os moinhos de cru. Essa etapa, moagem de cru, tem por objetivo a produção da farinha, resultante da moagem fina da mistura dosada de calcário, argila e corretivos. Após a moagem, a farinha é enviada para um silo de homogeneização que, na etapa seguinte, alimenta o forno para a produção de clínquer.

A composição química ideal da farinha e sua nomenclatura na indústria cimenteira são apresentadas no QUADRO 1.

QUADRO 1 – NOMENCLATURA E COMPOSIÇÃO TÍPICA DA FARINHA

Constituinte		Símbolo na indústria cimenteira	Farinha (%)
Sílica	SiO_2	S	12 ~ 15
Alumina	Al_2O_3	A	2 ~ 4
Óxido de ferro	Fe_2O_3	F	1 ~ 3
Óxido de cálcio	CaO	C	40 ~ 44
Óxido de magnésio	MgO	M	1 ~ 4
Anidrido sulfúrico	SO_3	SO3	0 ~ 1
Óxido de potássio	K_2O	K	0,1 ~ 1
Óxido de sódio	Na_2O	N	0 ~ 0,3

FONTE: Votorantim Cimentos, 2013.

Nesta etapa, é fundamental o controle da granulometria e da composição química da farinha. Para tal, são controlados três importantes parâmetros químicos que auxiliam na detecção de irregularidades e possíveis problemas nas etapas seguintes.

- Fator de Saturação do Cal (FSC): fator obtido por meio da expressão 1. Mede a relação entre o óxido de cálcio e os demais óxidos da farinha. Seu valor define a produção de minerais do clínquer, e seu resultado ideal deve estar entre 95% e 105%.

$$FSC = \frac{CaO}{2,8 * SiO_2 + 1,18 * Al_2O_3 + 0,65 * Fe_2O_3} * 100 \% \quad (1)$$

- Módulo de Sílica (MS): módulo obtido por meio da expressão 2 e que mede a relação entre a sílica e os óxidos de alumínio e ferro. Seu resultado controla a quantidade de fase líquida, um parâmetro operacional importante do processo de clínquerização. Seu valor ideal deve estar entre 2,3 e 2,7.

$$MS = \frac{SiO_2}{Al_2O_3 + Fe_2O_3} \quad (2)$$

- Módulo de Alumina (MA): módulo obtido por meio da expressão 3. Mede a relação entre os principais elementos fundentes (alumínio e ferro). Seu resultado indica a viscosidade da fase líquida formada no forno na etapa de clinquerização e seu valor ideal deve estar entre 1,3 e 1,6.

$$MA = \frac{Al_2O_3}{Fe_2O_3} \quad (3)$$

A clinquerização, processo que ocorre em um forno rotativo em altas temperaturas, é a reação de formação do clínquer, produto intermediário do cimento que quando moído com sulfato de cálcio e adições compõe o produto final.

O processo de clinquerização pode ser dividido em quatro etapas: torre de pré-aquecimento, pré-calcinação, calcinação e resfriamento, as quais são resumidas como segue.

- Pré-aquecimento: Para um melhor aproveitamento da energia térmica do forno, é utilizada uma torre de ciclones que tem como função pré-aquecer a farinha que alimentará o forno a partir dos gases quentes da saída deste. A temperatura alcançada nas torres de ciclone é, em média, de 800° C. Nessa etapa ocorrem a evaporação da água livre, remoção da água adsorvida e remoção da água quimicamente combinada.
- Pré-calcinação: Início da calcinação da farinha e início da geração de compostos intermediários do clínquer (C₂S e C₃A). A farinha, que após essa etapa fica 90% descarbonatada, alimenta o forno que está com uma temperatura próxima aos 950°C, o que aumenta a velocidade do processo fazendo com que o tempo de calcinação no forno diminua.
- Calcinação: Término da calcinação da farinha e formação dos compostos do clínquer. Com o fim desta etapa, o clínquer segue nodularizado e com aproximadamente 1200° C para a etapa de resfriamento.

- Resfriamento: O clínquer sofre um resfriamento por meio de uma corrente de ar para reduzir a sua temperatura para aproximadamente 100°C, com o objetivo de finalizar as reações químicas de formação do clínquer e possibilitar o seu transporte e armazenamento.

Após o resfriamento, o clínquer produzido passa por britadores para garantir um tamanho regular do material e segue até os silos de armazenamento.

O processo de clinquerização é alimentado com os óxidos que compõem a farinha e como resultado se obtêm C_2S e C_3S (silicatos cálcicos), C_3A (aluminato cálcico) e C_4AF (ferroaluminato cálcico), compostos sintéticos do clínquer, bem como os minerais óxido de cálcio (CaO) e óxido de magnésio (MgO). A importância e função de tais compostos são detalhadas nos tópicos a seguir.

- Belita (C_2S): É um elemento muito importante devido a sua reatividade mais lenta com a água, contribuindo para as resistências mecânicas em idades avançadas.
- Alita (C_3S): Principal constituinte requerido no cimento (40% a 70% da composição do clínquer) porque além de reagir com a água de forma quase imediata, ele também é o principal responsável pela resistência aos 28 dias.
- Aluminato tricálcico (C_3A): É um elemento importante pois reage rapidamente com a água e é o maior responsável pelo endurecimento da pasta de cimento, também conhecido como “tempo de pega”.
- Ferro-aluminato tetracálcico (C_4AF): Possui baixa reatividade e tem pequena participação na resistência mecânica do cimento. Sua principal participação é na cor, deixando o cimento acinzentado devido à presença de ferro.
- Óxido de cálcio (CaO livre): Teores acima de 2,5% podem causar expansibilidade nas argamassas e concretos.
- Óxido de Magnésio (MgO - Periclásio): A presença deste mineral pode causar expansibilidade tardia nas argamassas e concretos.

Como pode ser notado, todos os constituintes do clínquer possuem diferentes impactos no desempenho do cimento, sendo de extrema importância que o mesmo apresente todos os compostos na quantidade e qualidade adequadas.

Além disso, o clínquer é o principal insumo da composição do cimento, ou seja, é responsável pelas principais propriedades químicas e físicas deste, e por esse motivo o CQ deve controlar de forma rigorosa as suas características. Neste sentido, o CQ monitora os parâmetros químicos FSC, MS e MA, bem como os compostos C_3S , C_2S , C_3A , C_4AF , CaO e MgO do clínquer.

O processo de moagem do cimento, também definido como processo de cominuição, possui duas funções básicas: obter uma boa homogeneização entre os insumos; bem como controlar o tamanho das partículas para garantir a qualidade do cimento produzido.

Nesta etapa, o clínquer britado, o sulfato de cálcio e as adições (escória, material pozzolânico e material carbonático) devidamente dosados, são alimentados em moinhos que, por impacto e cisalhamento, reduzem a granulometria dos insumos e homogenizam a mistura, resultando nos diferentes tipos de cimento.

Ainda nessa etapa, podem ser adicionados aditivos químicos com o objetivo de otimizar o processo de cominuição, reduzindo o consumo energético e aumentando a produtividade da planta. Ao término da cominuição, o cimento produzido é armazenado em silos preparados para o processo final de expedição. O CQ atua nessa etapa coletando amostras dos cimentos produzidos a fim de verificar o atendimento dos seus desempenhos químico e físico finais em relação aos requisitos normativos.

O fluxo produtivo dos cimentos se encerra na etapa de ensacamento e expedição, onde se consideram duas formas de expedição para os produtos: cimentos ensacados ou à granel.

Os cimentos ensacados passam por um processo automatizado de ensacamento. O produto é fluidizado em tanques rotativos que alimentam as sacarias de papelão. Estas são fechadas e demarcadas com a data de expedição. Por sua vez, a expedição de cimentos à granel abastece caminhões para atendimento direto dos clientes.

Nesta etapa são coletadas amostras dos materiais expedidos e são verificadas as variáveis de desempenho finais dos diferentes cimentos a fim de garantir o atendimento às normas e às expectativas dos consumidores.

2.1.3 Adições

Os diferentes tipos de cimentos recebem diferentes tipos de adições, que podem ser material carbonático, escória ou material pozolânico. Cada uma dessas adições apresenta características particulares e proporciona ao cimento variedades em relação às suas propriedades, fazendo com que cada tipo de cimento seja mais adequado para uma determinada aplicação (VOTORANTIM, 2013). As adições estão caracterizadas no QUADRO 2.

QUADRO 2 – ADIÇÕES NA PRODUÇÃO DE CIMENTOS

Adição	Caracterização
Material carbonático (fíler)	Material finamente dividido que, em decorrência da sua ação física, melhora algumas propriedades físicas do cimento como as resistências iniciais (R1 e R3).
Escória	Subproduto da fundição de minérios em siderúrgicas. Sua consideração nos cimentos pode influenciar o tempo de pega, o calor de hidratação, a cor e a resistência à compressão.
Material pozolânico	Materiais que, sozinhos, apresentam pouca ou nenhuma atividade ligante, mas que quando finamente moídos e na presença de água, reagem para formar compostos com propriedades ligantes

FONTE: ABCP (2002), Votorantim Cimentos (2013).

O tipo de adição é nomeado no cimento de acordo com a norma brasileira (QUADRO 3).

QUADRO 3 – CLASSIFICAÇÃO E NOMENCLATURA DOS CIMENTOS

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

FONTE: Adaptado de ABCP (2002)

Na seção seguinte é detalhada a escória de alto-forno, adição considerada neste trabalho para o modelo preditivo de resistência à compressão.

2.1.3.1 Escória de alto-forno

De acordo com a Norma Brasileira NBR 5735 (1991), escórias de alto-forno são subprodutos do tratamento de minério de ferro em alto-forno, obtido sob forma granulada por resfriamento brusco, constituído em sua maior parte de silicatos e aluminos-silicatos de cálcio. Em relação á sua composição química, o material deve obedecer a relação apresentada na expressão 4.

$$\frac{CaO + MgO + Al_2O_3}{SiO_2} > 1 \quad (4)$$

A classificação dos cimentos com base em sua composição, bem como os teores mínimos e máximos estipulados em norma são apresentados no QUADRO 4.

QUADRO 4 – TEORES DOS COMPONENTES DO CIMENTO COMPOSTO

Classificação do cimento	Componentes (% em massa)			
	Clínquer + sulfato de cálcio	Escória	Material pozolânico	Material carbonático
CP-I	100	-	-	-
CP-II-E	94-56	6-34	-	0-10
CP-II-Z	94-76	-	6-14	0-10
CP-II-F	94-90	-	-	6-10
CP-III	65-25	35-70	-	0-5
CP-IV	85-45	-	15-50	0-5
CP-V-ARI	95-100	-	-	0-5

FONTE: NBR 11578 (1991)

A qualidade das escórias é feita, na Votorantim Cimentos, no momento de recebimento do material uma vez que suas características são estáveis para todo o lote recebido. Nos casos em que lotes apresentam desvios passíveis de correção, escórias de diferentes características são misturadas e se mantêm a parametrização ideal para alimentar os processos subsequentes.

2.1.4 Controle de qualidade

A utilização de um sistema de controle de qualidade, em qualquer setor industrial, é prática vital para a manutenção da qualidade dos produtos obtidos e para a perfeita operação dos equipamentos. Sua adoção gera resultados como a redução dos custos de fabricação, redução de perdas, resíduos e refugos, e também a redução de paradas nas linhas de produção (SLACK; CHAMBERS; JOHNSTON, 2009).

Neste sentido, as fábricas de cimento da Votorantim têm instalado em seu processo de produção, desde a mineração até a expedição, um sistema de controle de qualidade de forma que as exigências feitas pelas normas brasileiras aos cimentos Portland sejam cumpridas.

A qualidade do cimento Portland é avaliada por meio de suas características físico-químicas e inclui propriedades como o comportamento do cimento em relação à pega, o desenvolvimento das resistências mecânicas, a estabilidade de volume e durabilidade, sendo que grande parte desse

desempenho depende da qualidade de seu principal constituinte, o clínquer (NBR 5732, 1990).

As propriedades físicas do cimento Portland são analisadas de acordo com três aspectos: propriedades do produto em sua condição natural (anidra), da mistura de cimento e água (pasta), e da mistura da pasta com um agregado padronizado (argamassa). As propriedades da pasta e da argamassa são relacionadas com o comportamento do cimento quando utilizado e definem as suas propriedades potenciais para a elaboração de concretos e argamassas. Por outro lado, as propriedades químicas do cimento Portland impactam no produto hidratado final, no mecanismo de hidratação e no seu desempenho.

As exigências físicas e químicas para as diferentes classificações de cimento são apresentadas nas seções seguintes.

2.1.4.1 Exigências físicas para os cimentos Portland

As exigências físicas definidas em normas regulamentadoras brasileiras são aferidas durante e após o processo de hidratação do cimento. Os ensaios, bem como seus limites normativos para cada classificação de cimento, são apresentados nos QUADROS 5 e 6 e detalhados nas seções seguintes.

QUADRO 5 – REQUISITOS FÍSICOS DOS CIMENTOS PORTLAND

Tipo de cimento Portland	Classe de resistência (MPa)	Finura		Tempo de pega (h)		Expansibilidade (mm)	
		Resíduo na peneira 75 $\mu\text{m}(\%)$	Área específica (m^2/kg)	Início	Fim	A frio	A quente
CP-I CP I-S	25	≤ 12	≥ 240	≥ 1	≤ 10	$\leq 5,0$	$\leq 5,0$
	32		≥ 260				
	40	≥ 280					
CP II-E CP II-Z CP II-F	25	≤ 12	≥ 240	≥ 1	≤ 10	$\leq 5,0$	$\leq 5,0$
	32		≥ 260				
	40	≥ 280					
CP III	25	≤ 8	-	≥ 1	≤ 12	$\leq 5,0$	$\leq 5,0$
	32						
	40						
CP IV	25	≤ 8	-	≥ 1	≤ 12	$\leq 5,0$	$\leq 5,0$
	32						
CP V-ARI		≤ 6	≥ 300	≥ 1	≤ 10	$\leq 5,0$	$\leq 5,0$

FONTE: Adaptado de ABCP (2002)

QUADRO 6 – REQUISITOS FÍSICOS DE RESISTÊNCIA À COMPRESSÃO DOS CIMENTOS PORTLAND

Tipo de cimento Portland	Classe de resistência (MPa)	Resistência à compressão (MPa)			
		1 dia	3 dias	7 dias	28 dias
CP-I CP I-S	25	-	$\geq 8,0$	$\geq 15,0$	$\geq 25,0$
	32		$\geq 10,0$	$\geq 20,0$	$\geq 32,0$
	40		$\geq 15,0$	$\geq 25,0$	$\geq 40,0$
CP II-E CP II-Z CP II-F	25	-	$\geq 8,0$	$\geq 15,0$	$\geq 25,0$
	32		$\geq 10,0$	$\geq 20,0$	$\geq 32,0$
	40		$\geq 15,0$	$\geq 25,0$	$\geq 40,0$
CP III	25	-	$\geq 8,0$	$\geq 15,0$	$\geq 25,0$
	32		$\geq 10,0$	$\geq 20,0$	$\geq 32,0$
	40		$\geq 12,0$	$\geq 23,0$	$\geq 40,0$
CP IV	25	-	$\geq 8,0$	$\geq 15,0$	$\geq 25,0$
	32		$\geq 10,0$	$\geq 20,0$	$\geq 32,0$
CP V-ARI		$\geq 14,0$	$\geq 24,0$	$\geq 34,0$	-

FONTE: Adaptado de ABCP (2002)

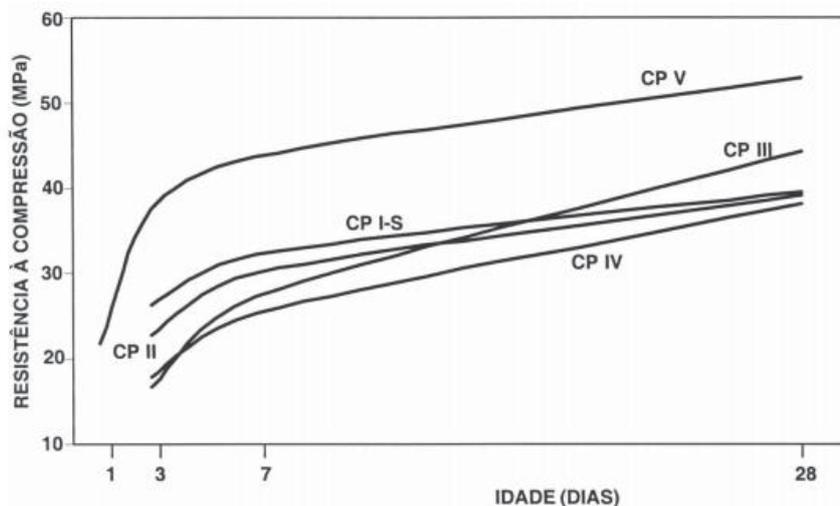
2.1.4.1.1 Resistência à compressão

Os ensaios para determinar a resistência à compressão do cimento são especificados pela norma NBR 7215 da ABNT, e consistem em moldar e testar corpos de prova padrão (corpos de prova cilíndricos de 10 cm de altura e com 5 cm de diâmetro, conservados em uma câmara úmida por 24 horas e, após esse tempo, imersos em água até a data do rompimento). O rompimento dos corpos ocorre quando estes possuem idades de 1, 3, 7 e 28 dias, quando estes são submetidos a uma força de compressão numa prensa até o ponto de romper, e a força empregada para levá-los à ruptura é a medida da capacidade do cimento de suportar cargas (NBR 7215, 1996).

A norma brasileira NBR 5732, estabelece valores mínimos que estas resistências devem apresentar em cada uma destas idades, para cada tipo de cimento (QUADRO 6).

A resistência é especificada em relação à área do corpo que está sendo solicitada pelo esforço, então a tensão de compressão de um corpo será a força aplicada dividida pela área do corpo de prova. A unidade de medida de força é o quilograma força (kgf) e a área é dada em centímetros quadrados (cm²). Logo, fazendo-se as devidas conversões tem-se a unidade comum para ensaios de resistência em cimento como sendo MPa - mega Pascal (NBR 7215, 1996).

FIGURA 4 - EVOLUÇÃO MEDIA DA RESISTÊNCIA À COMPRESSÃO PARA OS DIFERENTES TIPOS DE CIMENTO



FONTE: ABCP, 2002.

De forma prática, a resistência do cimento aumenta conforme o tempo passa, e pode-se considerar que a resistência aos 28 dias representa, de forma confiável, a resistência final do cimento uma vez que esta tende a não ter mais aumentos significativos após esta idade, como pode ser visto na FIGURA 4, onde se verifica a tendência de estabilidade nos ganhos de resistência para os diferentes tipos de cimento (ABCP, 2002).

2.1.4.1.2 Tempo de pega

O fenômeno de pega do cimento, definido como o momento em que a pasta (mistura de cimento com água) adquire certa consistência, compreende a evolução das propriedades mecânicas da pasta no início do processo de endurecimento, consequência do processo químico de hidratação, até o seu endurecimento total, tornando o material impróprio para uso (ABCP, 2002; NBR NM 65, 2003).

A caracterização da pega dos cimentos é feita pela determinação de dois tempos distintos, o tempo de início e de fim de pega. Os ensaios são feitos com pasta de consistência normal (mistura padronizada de cimento e água com propriedade reológica constante) e com o aparelho de Vicat (FIGURA 5). Neste aparelho, mede-se a resistência à penetração de uma agulha na pasta de cimento (NBR NM 65, 2003; NBR NM 43, 2002).

FIGURA 5 - APARELHO DE VICAT UTILIZADO NOS ENSAIOS DE TEMPO DE PEGA DO CIMENTO PORTLAND



FONTE: Solotest (2017)

A amostra é ensaiada periodicamente à penetração pela agulha de Vicat, determinando-se o tempo de início de pega quando esta deixar de penetrar 1mm do fundo da pasta, e o tempo de fim de pega quando a agulha não penetra mais na amostra, deixando apenas uma imperceptível marca superficial (NBR NM 65, 2003; NBR NM 43, 2002).

2.1.4.1.3 Finura

Na fabricação do cimento Portland, as matérias-primas argila e calcário são submetidas a operações de cominuição para atingirem uma determinada finura, ou seja, é necessário que suas partículas tenham um diâmetro suficientemente pequeno para que seja possível a ocorrência das reações químicas no forno, resultando um clínquer de boa qualidade (VOTORANTIM, 2013).

Uma vez obtido o clínquer, este será também submetido a operações de cominuição, juntamente com as adições (gesso, pozolana, escória, etc), até que seja obtido um material fino e homogêneo. Novamente a finura terá um papel importante, mas agora ligado aos fenômenos da pega e do endurecimento do cimento (VOTORANTIM, 2013; SAJED e RAZAK, 2011).

A finura do material é definida de duas maneiras distintas: pelo tamanho máximo do grão, quando as especificações estabelecem uma proporção em peso do material retido na operação de peneiramento, e, alternativamente, pelo valor da superfície específica (soma das superfícies dos grãos contidos em um grama de cimento) também denominado de Blaine (NBR 11579, 1991; NBR NM 76, 1998).

Além disso, a finura é o fator que governa a velocidade da reação de hidratação do cimento e tem também sua influência comprovada em muitas qualidades nas argamassas e nos concretos. O aumento desta, em geral, melhora a resistência à compressão, particularmente a resistência da primeira idade (SAJED e RAZAK, 2011).

Este parâmetro do cimento é determinado e controlado durante o processo de fabricação do mesmo, e as especificações brasileiras NBR 5732 (1990) e NBR 5733 (1991) prescrevem os limites mínimos.

2.1.4.1.4 Expansibilidade

A reação química entre o cimento e a água produz inicialmente um enrijecimento e a seguir um endurecimento da pasta de cimento. Nos cimentos considerados normais estas reações químicas provocam ligeiras mudanças no volume da pasta, ou seja, a soma do volume absoluto do cimento mais o volume da água adicionada inicialmente não é rigorosamente o mesmo que a pasta apresenta após certo tempo de hidratação.

Nos cimentos que podem ser denominados anormais, além da redução de volume, pode existir um aumento considerável do volume da pasta ao longo do tempo devido às reações químicas de alguns compostos. Este aumento pode dar origem a um volume final maior que o volume inicial, e pode gerar desde trincas superficiais até chegar a uma desagregação completa da pasta de cimento.

Esta medida é obtida mediante a realização do ensaio de expansibilidade por meio de um aparelho denominado agulha de Le Chatelier (FIGURA 6) em duas modalidades: em água fria ou em água em ebulição.

FIGURA 6 – AGULHA DE LE CHATELIER



FONTE: Solotest (2017)

No método NBR 11582 da ABNT esse ensaio é descrito em detalhe e é constituído, em linhas gerais, da moldagem, cura do corpo-de-prova imerso em água durante 12 horas, e subsequente aquecimento do corpo-de-prova em água

conduzida lentamente à fervura (para ensaio a quente) durante cinco horas ou mais. O valor da expansibilidade é medido nas pontas das agulhas em milímetros, não podendo ultrapassar os limites descritos pelas especificações de qualidade do cimento (NBR 5732, NBR 5733).

O aumento de volume da pasta serve como indicação da possível expansão que se dará nos concretos e argamassas feitos com o mesmo cimento. Dependendo do aumento do volume identificado, podem ocorrer patologias que comprometam a qualidade da obra (VOTORANTIM, 2013).

2.1.4.2 Exigências químicas para os cimentos Portland

As exigências químicas definidas em normas regulamentadoras brasileiras são aferidas para garantir que o processo de hidratação e o desempenho final dos cimentos ocorram como o esperado (VOTORANTIM, 2013). Os ensaios, bem como seus limites normativos para cada classificação de cimento são apresentados no QUADRO 7 e detalhados nas seções seguintes.

QUADRO 7 - EXIGÊNCIAS QUÍMICAS DOS CIMENTOS PORTLAND

Tipo de cimento Portland	Resíduo insolúvel (%)	Perda ao fogo (%)	MgO (%)	SO ₃ (%)	CO ₂ (%)	S (%)
CP I	≤ 1,0	≤ 2,0	≤ 6,5	≤ 4,0	≤ 1,0	-
CP I-S	≤ 5,0	≤ 4,5			≤ 3,0	-
CP II-E	≤ 2,5	≤ 6,5	≤ 6,5	≤ 4,0	≤ 5,0	-
CP II-Z	≤ 16,0					-
CP II-F	≤ 2,5					-
CP III	≤ 1,5	≤ 4,5	-	≤ 4,0	≤ 3,0	≤ 1,0
CP IV	-	≤ 4,5	≤ 6,5	≤ 4,0	≤ 3,0	-
CP V-ARI	≤ 1,0	≤ 4,5	≤ 6,5	≤ 3,5	≤ 3,0	-

FONTE: Adaptado de ABCP (2002)

2.1.4.2.1 Perda ao fogo

O ensaio de perda ao fogo, descrito na norma NBR NM 18 (2012) verifica a perda de massa do cimento a 950°C, perda esta equivalente à descarbonatação e à umidade do produto. O objetivo principal é a indicação do teor de material carbonático dos cimentos e da sua umidade para que se veifiquem os ajustes necessários no teor de calcário. Os teores máximos estabelecidos em norma são identificados no QUADRO 7.

2.1.4.2.2 Resíduo insolúvel

O ensaio de resíduo insolúvel, com procedimento estabelecido nas normas NBR NM 15 (2012) e NBR NM 22 (2012) (para cimentos com adições de materiais pozolânicos), indica o teor de adição nos cimentos, bem como a existência de contaminação nas adições.

Seu resultado, expresso em %, permite identificar a necessidade de ajustes no teor das adições consideradas no cimento, bem como selecionar os materiais com valores de resíduo insolúvel fora da normalidade, ou seja, contaminados (VOTORANTIM, 2013). Os teores máximos estabelecidos em norma são identificados no QUADRO 7.

2.1.4.2.3 Espectrometria de raios X

A espectrometria de raios X é um método instrumental não destrutivo de análise qualitativa e quantitativa de elementos químicos. Na verificação da qualidade de cimentos, é utilizada para determinar quais os componentes químicos que estão presentes nos materiais, assim como a quantidade em que eles ocorrem (VOTORANTIM, 2013).

Esta prática é utilizada para a determinação dos teores de óxido de magnésio (MgO) e trióxido de enxofre (SO_3). O MgO presente no cimento tem origem principal do clínquer e do calcário, e seu controle é necessário pois o mesmo é responsável por gerar expansões em concretos e argamassas. Por sua vez, o SO_3 , proveniente principalmente do clínquer e do sulfato de cálcio, deve

ser controlado pois afeta a pega do cimento (VOTORANTIM, 2013). Os teores máximos estabelecidos em norma são identificados no QUADRO 7.

2.1.5 Plano de amostragem

O plano de amostragem estabelecido pela Votorantim Cimentos, empresa fornecedora dos dados deste estudo, é definido a partir das necessidades das etapas destacadas nas seções anteriores. Para tal, todos os requisitos normativos são considerados no conjunto de análises mandatórias, bem como a avaliação de características que contribuem para um bom controle e andamento do processo como um todo.

Neste sentido, pode-se resumir, de acordo com as etapas identificadas neste trabalho, os materiais avaliados em cada operação, assim como os pontos de amostragem e o objetivo das análises em cada etapa. Tais informações se apresentam consolidadas nos QUADROS 8 e 9.

QUADRO 8 – PLANO DE AMOSTRAGEM DA VOTORANTIM CIMENTOS

Item	Etapa	Material	Ponto de amostragem
A	Mineração	Calcário	Mina
B		Argila	Mina
C	Pré-homogeneização	Cru	Pilha de calcário e pilha de argila
D	Moagem de cru	Farinha produzida	Saída do moinho de farinha
E	Clinquerização	Farinha alimentada	Entrada do forno de clínquer
F		C clínquer produzido	Saída do forno de clínquer
G	Moagem de cimento	Adições	Balança dosadora
H		Cimento produzido	Saída do moinho de cimento
I	Expedição	Cimento expedido	Bico da ensacadeira/ Caminhão

FONTE: Votorantim Cimentos (2013)

QUADRO 9 - OBJETIVOS DAS AMOSTRAGENS DE CADA ETAPA

Item	Objetivo
A	Caracterização da matéria-prima para ajustes dos processos subsequentes
B	Caracterização da matéria-prima para ajustes dos processos subsequentes
C	Monitoramento para controle e ajustes no processo produtivo para garantia de composição e homogeneidade das matérias-primas
D	Monitoramento para controle e ajustes no processo produtivo para garantia da composição ideal da farinha utilizada na produção do clínquer
E	Monitoramento para garantia da composição ideal e homogeneidade da farinha utilizada na produção do clínquer, controle e ajustes no processo.
F	Verificação da composição química e da mineralogia do clínquer produzido para garantia de desempenho dos cimentos, controle e ajustes no processo.
G	Monitoramento da composição química das adições para garantir o atendimento aos limites normativos, controle e ajustes no processo
H	Medição do desempenho e da composição química dos cimentos produzidos de acordo com os requisitos normativos para controle e ajustes no processo
I	Medição do desempenho e da composição química dos cimentos expedidos de acordo com os requisitos normativos e os requisitos comerciais

FONTE: Votorantim Cimentos (2013)

2.1.5.1 Etapas Críticas

Avaliando os dados dos QUADROS 8 e 9, percebe-se que todas as amostragens fornecem informações fundamentais para que correções ao longo do processo produtivo, quando necessárias, sejam realizadas objetivando-se a expedição de cimentos com desempenho e características ideais.

Além disso, é possível identificar uma divisão da produção do cimento em duas fases. A primeira dela diz respeito à produção do clínquer, iniciando na etapa de mineração e seguindo até a etapa de clínquerização. Essas etapas são ajustadas e calibradas para a produção de um clínquer de composição e mineralogia adequadas. A segunda fase se inicia no processo de moagem do cimento e termina na expedição do mesmo.

Avaliando as etapas anteriores à de formação do clínquer, percebe-se, que existe um maior grau de liberdade no que tange a possibilidade de correções e ajustes de operação. Nestas etapas as matérias-primas podem ser ajustadas quanto às suas propriedades químicas e físicas, e o processo

parametrizado para ser alimentado com as mesmas, permitindo assim um maior nível de ajuste.

O mesmo não pode ser visualizado nas etapas de clínquerização e nas suas sequenciais. Desta forma, consideram-se nesse estudo os itens clínquer produzido na clínquerização (F), adições na moagem de cimento (G), cimento produzido (H) e o cimento expedido (I) como críticos pelo fato de não apresentarem alta flexibilidade de ajustes quando comparados com os demais.

No QUADRO 10 são apresentadas as principais variáveis verificadas pelo CQ em cada um destes itens.

QUADRO 10 – VARIÁVEIS DE VERIFICAÇÃO E CONTROLE DAS ETAPAS CRÍTICAS

Item	Variáveis de verificação e controle
F	Composição química (%) e mineralógica
G	Teor (%) e umidade das adições
H	Composição química (%), Perda ao fogo (PF) , Resíduo Insolúvel (RI) e finura
I	Composição química (%), Perda ao fogo (PF) , Resíduo Insolúvel (RI), finura e desempenho físico

FONTE: Votorantim Cimentos (2013)

As verificações identificadas no QUADRO 10 atendem os requisitos normativos e aferem também outras medidas para as quais se conhecem as influências no cimento produzido.

As principais influências podem ser resumidas no QUADRO 11, onde estão rastreadas em categorias de responsabilidade, ou seja, etapa ou subproduto responsável e que deve sofrer ações corretivas em casos de irregularidade.

QUADRO 11 - INFLUÊNCIA DOS FATORES NO DESEMPENHO DOS CIMENTOS

Categoria	Fator de influência	Resistência à compressão inicial (1 e 3 dias)	Resistência à compressão final (28 dias)	Tempo de pega
Qualidade do clínquer	C ₃ S	↑	↑	-
	C ₂ S	↓	↑	-
	C ₃ A	↑	↓	↓
	C ₄ AF	-	-	-
	CaO livre	-	-	↓
Condições do processo	Finura ¹	↑	↑	↓
	Adição de escória	↓	↑	-

FONTE: Votorantim Cimentos (2013); KOSMATKA e WILSON (2016).

2.2 TRABALHOS CORRELATOS

Nesta seção é apresentado o levantamento feito de trabalhos correlatos ao tema em questão nesta pesquisa. A pergunta que deve ser respondida pela revisão de literatura é relativa às lacunas existentes a respeito da aplicação de metodologias de inteligência artificial em modelos preditivos de resistência à compressão de cimentos.

Dentro do levantamento realizado percebeu-se que os maiores volumes de publicações ocorrem para os problemas ligados à predição da resistência à compressão de concretos e argamassas, mas ainda se encontra a ocorrência de trabalhos voltados à aplicação de modelos preditivos para a resistência de cimentos considerando os fatores do clínquer, adições e composição química dos cimentos como variáveis.

Essa consideração de parâmetros finais (no caso de concretos e argamassas), não permite que as unidades produtoras de cimento possam identificar pontos de ajuste em seu processo, bem como garantir que o cimento utilizado desempenhará suas características físicas e químicas como o esperado. Essas considerações são imediatistas e trabalham visando a obtenção do desempenho sem considerar a qualidade dos subprodutos, também foco deste trabalho.

¹ Quanto maior a finura, maior a influência (Votorantim, 2013)

Os autores Topçu, Karakurt e Saridemir (2008) dissertaram a respeito de uma modelagem por intermédio dos métodos de RNA e Lógica Fuzzi (FL, do inglês *Fuzzy Logic*). O objetivo dos autores foi investigar a composição ótima de cimentos considerando a adição de três pozolanas naturais e duas pozolanas artificiais e, a partir desta, definir um modelo preditivo para a resistência à compressão destes cimentos visando a não necessidade de obtenção de dados experimentais.

Com a definição da composição ideal e a utilização de uma RNA *multilayer feed-forward* com algoritmo de *back propagation*, e do método *fuzzy Sugeno* de inferência, os autores encontraram uma aproximação dos dados teóricos com os dados experimentais, destacando a possibilidade de uso destes modelos para o caso estudado, não sendo o mesmo válido para outras situações.

De forma semelhante aos autores anteriores, Eskandarie Tayyebinia (2012) aplicaram a metodologia de RNA para avaliar a composição ótima de concretos, avaliando também a influência dos diferentes tipos de cimento na resistência final (28 dias) do produto. O resultado encontrado valida a aplicação da metodologia e permite a implementação da mesma, dadas a composição e características dos insumos.

Mousavi *et al.* (2012) procuraram prever a resistência à compressão de concretos de alta resistência em diversas idades por meio da aplicação de Gene Expression Programming (GEP) considerando variáveis do processo de mistura do concreto. O resultado alcançado pelos autores, quando comparados com técnicas de regressões lineares e não lineares, mostrou alta correlação com os dados experimentais, permitindo dessa forma, que não sejam necessárias as práticas experimentais para que se obtenha a informação da resistência à compressão desse tipo de material. Além disso, os autores destacam a possibilidade de aplicação do método em atividades de desenvolvimento.

Motamedi *et al.* (2015) aplicaram a metodologia de Neuro-Fuzzy para a previsão de resistência á compressão a 1, 7, 14 e 28 dias de concretos a partir de misturas de materiais cimentícios (*pulverized fuel ash*), cimento e areia. As variáveis de entrada foram os teores de cada um dos insumos, bem como a idade do corpo de prova de concreto testado. Os resultados alcançados mostram

erros reduzidos de previsão e validam a metodologia, que pode ser replicada para situações de mesma parametrização.

A partir da busca da composição ótima para a mistura de cimentos de diferentes classes de resistências e diferentes teores para os agregados, Eskandari-Naddaf, Kazemi (2017) aplicaram a RNA visando a obtenção da resistência à compressão da argamassa de cimento para 3, 7, 14 e 28 dias a partir de cinco variáveis relacionadas ao processo de mistura e uso do cimento. Os resultados alcançado também validam a metodologia e os autores destacam que a consideração da classe de resistência como uma variável do modelo auxilia na convergência e aproximação com os dados experimentais.

Hong-Guang e Ji-Zong (2000) aplicaram o modelo de RNA buscando a predição da resistência à compressão do concreto aos 28 dias considerando onze variáveis. Semelhante aos demais trabalhos, essas variáveis traduzem a caracterização dos agregados e dos parâmetros de mistura. As etapas de treino e teste da metodologia foram realizadas utilizando dados reais de uma concreteira, e foram consideradas diferentes possibilidades de mistura para os agregados e dosagem de água.

O estudo conclui que o modelo fornece uma resposta rápida e muito próxima dos valores experimentais, considerando o modelo como uma solução prática para os profissionais que necessitam dessas informações e não possuem disponibilidade para testes experimentais.

No estudo desenvolvido por Akkurt, Ozdemir, Tayfur e Akyol (2003), é considerada a aplicação de duas metodologias da inteligência artificial com objetivos distintos. A RNA é desenvolvida para modelar a predição da resistência à compressão dos cimentos aos 28 dias com base em vinte variáveis, considerando a composição química e mineralogia e o desempenho físico dos cimentos produzidos. As etapas de treino e teste foram realizadas com dados reais, os quais foram selecionados a partir da aplicação de algoritmos genéticos com o objetivo de retirar do modelo resultados com alta variação devido a períodos de instabilidade no processo produtivo da planta considerada, equalizando os dados considerados.

Como considerações finais, os autores destacam o alcance de resultados teóricos satisfatórios para a resistência à compressão, mas destacam

que o modelo não se apresenta como replicável pelo fato de considerar condições específicas da planta no momento da seleção dos dados de treino e teste. Além disso, concluem o trabalho realizando uma análise de sensibilidade das variáveis, entendendo a relação entre estas, e destas com a resistência à compressão.

Por fim, o trabalho realizado por Baykasoglu, Dereli e Tanis (2004) realiza uma comparação entre duas metodologias (RNA e GEP) na criação de um modelo preditivo para resistência à compressão de cimentos aos 28 dias, considerando a composição química, mineralogia e desempenho físico dos cimentos produzidos. Diferentemente dos demais, os autores consideram um cimento composto para realizar as análises.

Além disso, para cada uma das metodologias, foram consideradas diferentes combinações de parametrização, sendo possível avaliar, para o caso estudado, qual a técnica que apresenta os melhores resultados. Com o encerramento das análises, os autores encontraram a melhor configuração para cada técnica, bem como a melhor metodologia para a predição da resistência. Na situação estudada, ambas as metodologias encontraram resultados semelhantes aos experimentais com erros equivalentes. A GEP, de acordo com os autores, apresenta vantagem sobre a RNA pelo fato de apresentar a habilidade de gerar uma expressão matemática de fácil aplicação prática.

No QUADRO 12 é apresentado um resumo do que foi descrito ao longo desta seção.

QUADRO 12 – CONSOLIDAÇÃO DE TRABALHOS CORRELATOS

Autor	Ano	Variáveis utilizadas	Técnica utilizada para a predição	Cimento utilizado	Resultados
Topçu, Karakurt e Sandemir	2008	Tempo de cura dos corpos de prova, teores de clínquer, pozolanas naturais e pozolanas artificiais	RNA e FL	CP I	Técnicas com ótima aproximação aos dados experimentais, e RNA com resultados ligeiramente mais precisos. Resultados não válidos para outros estudos. Destacam-se as habilidades da RNA em aprendizagem e tratamento de dados ruidosos.
Mousavi, Aminian, Gandomi, Alavi e Bolandi	2012	Tempo de cura dos corpos de prova, teores de água, cimento, de pozolanas artificiais, aditivos químicos, e de agregados graúdo e fino.	GEP	CP I	Técnica apresentou resultados com forte aproximação com os dados experimentais, validando a metodologia e demonstrando a não necessidade de ensaios laboratoriais para a verificação da resistência à compressão. O modelo gerado pode ser aplicado para planejamento de misturas.
Motamedi, Shamshirband, Petković e Hashim	2015	Tempo de cura dos corpos de prova, teores de areia, cimento e adição (PFA).	Neuro-Fuzzy	CP I	A técnica apresentou resultados com forte aproximação com os dados experimentais, validando a metodologia, e pode ser implementado no planejamento deste tipo de mistura.
Eskandarie Tayyebinia	2016	Tempo de cura dos corpos de prova, razão água/cimento, teor de aditivos, razão cimento/areia	RNA	CP I	A técnica apresentou resultados com forte aproximação com os dados experimentais, demonstrando que sua aplicação no dimensionamento das misturas é válido e substitui os ensaios experimentais.
Eskandari-Naddaf, Kazemi	2017	Tempo de cura dos corpos de prova, razão água/cimento, teor de aditivos, razão cimento/areia e classe de resistência do cimento	RNA	CP I	O desempenho da técnica na predição da resistência à compressão é satisfatório (forte aproximação aos dados experimentais). Destaca-se que a consideração da classe de resistência é significante na acurácia do modelo.

Autor	Ano	Variáveis utilizadas	Técnica utilizada para a predição	Cimento utilizado	Resultados
Hong-Guang e Ji-Zong	2000	Dosagem de água, cimento e aditivos, classe de resistência do cimento, razão água/cimento, razão agregado/cimento, razão areia/agregado, granulometria da areia, efeito dos aditivos, tamanho máximo do agregado e abatimento do concreto	RNA	CP I	A aplicação da técnica favorece a predição da resistência à compressão de forma rápida e acurada a partir da verificação dos principais fatores de influência. Destaca-se que o resultado é útil e pode ser realizado na prática de dosagem de concretos.
Akkurt, Ozdemir, Tayfur e Akyol	2003	Composição química do cimento e do clínquer, composição mineralógica do clínquer, início de pega, fim de pega, superfície específica e finura do cimento	GA e RNA	CP I	O resultado alcançado se mostrou satisfatório (com forte correlação com os dados experimentais) e auxiliou na compreensão desse tipo de sistema.
Baykasoglu, Dereci e Tanis	2004	Composição química do cimento, tempo de pega, finura, superfície específica, perda ao fogo, densidade do clínquer	GEP e RNA	CP II	A comparação entre as duas metodologias mostrou que, para o caso estudado, os resultados apresentam forte correlação com os dados experimentais. Além disso, a GEP se destaca na visão dos autores por gerar uma expressão matemática de fácil aplicação, o que não é feito de forma direta na RNA.

FONTE: O Autor, 2017.

2.3 FUNDAMENTAÇÃO TEÓRICA

2.3.1 Introdução

A revisão de literatura de trabalhos correlatos permitiu a identificação de aplicações de técnicas de predição da resistência à compressão em diversas etapas, desde a produção do cimento até a sua aplicação final em concretos e argamassas, modificando assim o tipo das variáveis consideradas nos modelos. Também foi possível verificar a precisão da informação fornecida por cada metodologia considerada, favorecendo o entendimento de quais destas se adequam melhor aos objetivos deste estudo.

Para a maioria dos trabalhos identificados, a mesma classe de cimentos foi considerada (CP I), sinalizando a necessidade de pesquisas neste segmento para que se possa avaliar as influências de adições nas demais classes de cimento. Assim, encontrou-se uma oportunidade de trabalho na investigação da predição da resistência à compressão considerando a adição de escórias na produção de cimentos compostos (CP II-E e CP III).

Esse tipo de adição, no escopo deste estudo, não foi explorado na literatura. Além disso, a consideração da mesma no processo de produção dos cimentos aumenta o número de variáveis que devem ser consideradas para a garantia de qualidade e desempenho, uma vez que apresenta impactos no desempenho dos cimentos.

De acordo com os trabalhos expostos, e avaliando as metodologias aplicadas e os resultados alcançados, o presente trabalho selecionou a RNA como ferramenta de trabalho a ser aplicada. A mesma mostrou aderência aos objetivos desta pesquisa e, sobretudo, a habilidade de aprender com dados experimentais reduzindo possíveis ruídos originários do processo, ainda assim garantindo boa proximidade com os dados experimentais.

Nesta seção, portanto, apresentam-se os assuntos ligados às RNAs, iniciando com os principais conceitos da IA e aprendizagem de máquinas, de cuja área as RNAs formam uma das principais técnicas.

2.3.2 Inteligência Artificial

A Inteligência Artificial (IA) sistematiza e automatiza tarefas intelectuais e, por esse motivo, é de elevada relevância para a atividade intelectual humana. Nesse sentido, a IA é um campo de estudos universal que tenta imitar a maneira como o homem pensa na resolução dos problemas (RUSSELL e NORVIG, 2004).

Da mesma forma, Nilsson (1998) conceitua a IA como uma técnica que relaciona percepções, raciocínios, aprendizagem, comunicação e ação em ambientes complexos de forma equivalente à mente humana, com o objetivo de compreender o comportamento tanto humano como de máquinas.

Segundo Monard and Baranauskas (2003), uma área da IA denominada como Aprendizagem de Máquina (AM), possui como objetivo o desenvolvimento de técnicas computacionais sobre o aprendizado, bem como a construção de sistemas capazes de adquirir conhecimento de forma automática. Os autores complementam que esses sistemas de aprendizado são programas computacionais que tomam decisões baseadas em experiências acumuladas nas soluções bem sucedidas de problemas históricos (MONARD e BARANAUSKAS, 2003).

Portanto, pode-se afirmar que o campo da IA tem como objetivo o contínuo aumento do poder de raciocínio dos programas computacionais, emulando algumas capacidades dos seres humanos visando a resolução de problemas, a aquisição e a representação de conhecimentos.

2.3.3 Aprendizagem de máquina

A aprendizagem de máquina (do inglês, *machine learning*) é um recurso computacional que representa, a partir de modelos matemáticos, acontecimentos do mundo real ou experiências passadas, com objetivo de realizar inferências futuras a partir de amostras atuais (MONARD e BARANAUSKAS, 2003; ALPAYDIN, 2010).

De acordo com CHEESEMAN e STUSTZ (1990), esse aprendizado é efetuado a partir de raciocínio sobre exemplos fornecidos por um processo

externo ao sistema e pode ser dividido em dois tipos principais: supervisionado e não-supervisionado.

A aprendizagem supervisionada recebe um conjunto de entradas junto com as saídas corretas correspondentes e o algoritmo aprende comparando a saída do modelo com as saídas corretas para encontrar erros. O padrão identificado nos dados é então utilizado para prever valores de saída não conhecidos e, portanto, considerado em aplicações nas quais os dados históricos preveem prováveis acontecimentos futuros (CHEESEMAN e STUSTZ, 1990; ALPAYDIN, 2010).

Por sua vez, o aprendizado não supervisionado recebe dados que não possuem rótulos históricos e o algoritmo deve explorar os mesmos para encontrar alguma estrutura de semelhança. Neste modelo de aprendizagem, os algoritmos são utilizados para identificar e segmentar um conjunto de dados (CHEESEMAN e STUSTZ, 1990; ALPAYDIN, 2010).

O interesse no aprendizado de máquina se deve ao volume e variedade de dados disponíveis, o processamento computacional que está cada vez mais barato e mais poderoso e o armazenamento de dados de forma acessível. Tudo isso significa que é possível produzir de forma rápida e automática modelos que permitam analisar dados maiores e mais complexos e fornecer resultados mais rápidos e mais precisos. Com isso, se tornam possíveis previsões de alto valor que podem levar a melhores decisões e ações inteligentes em tempo real sem a intervenção humana (ALPAYDIN, 2010).

Um requisito importante para as técnicas de aprendizagem de máquina é que elas sejam capazes de lidar com dados imperfeitos, denominados ruídos, ou seja, valores afetados por leituras de medidas incorretas (SHAWER-TAYLOR e CRISTIANINI, 2000).

Uma das modalidades da aprendizagem de máquinas é a metodologia de redes neurais artificiais, cujas ações estão focadas na identificação de padrões baseados no funcionamento do nosso cérebro. O detalhamento dessa metodologia é apresentado na seção seguinte.

2.3.3.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) consistem em uma técnica para a solução de problemas de inteligência artificial que tenta simular o funcionamento do cérebro humano e foi projetada para processar informações e adquirir conhecimento por meio de simulações computacionais (BARRETO, 2002; MELLO, 2004).

De acordo com Braga, Carvalho e Ludemir (2011), as Redes Neurais Artificiais são utilizadas na resolução de problemas complexos devido à habilidade que possuem de aprender com base em exemplos e generalizar a informação aprendida.

De forma semelhante, Haykin (2001) conceitua a técnica como:

“Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos: (1) O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; (2) Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.” (HAYKIN, 2001, p.28)

Além disso, as redes neurais são capazes de detectar padrões e relações não explícitas em um conjunto de dados aparentemente desconexos. Portanto, de uma forma geral, a RNA é uma metodologia que recria o processamento e a lógica do pensamento humano para a aquisição de conhecimento e resolução de problemas complexos (FAUSETT, 1994; HAYKIN, 2001).

2.3.3.1.1 Histórico

O primeiro modelo artificial de um neurônio biológico foi introduzido no trabalho “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, publicado em 1943 por McCulloch e Pitts, cujo trabalho deu início à concretização da RNA (ZURADA, 1992; FAUSETT, 1994; HAYKIN, 2001;

BARRETO, 2002; BRAGA, CARVALHO e LUDERMIR, 2011). Neste artigo, os autores demonstraram que uma rede composta por um número suficiente de neurônios, conectados sinapticamente de forma ajustada e operando sincronizadamente, seria capaz de realizar, a princípio, a computação de qualquer função matemática (HAYKIN, 2001).

Contudo, o trabalho apresentado por McCulloch e Pitts teve como foco a descrição do modelo artificial de neurônio e de suas capacidades computacionais. O aprendizado de redes biológicas e artificiais, de fato, foi estudado pela primeira vez em 1949 por Donald Hebb. Em sua publicação "*The Organization of Behaviour*", o autor relacionou a aprendizagem das RNAs com a variação dos pesos de entrada dos neurônios propondo uma teoria, conhecida como Regra de Hebb, que explica o aprendizado em neurônios biológicos. Desde então, a regra é utilizada no desenvolvimento de diversos algoritmos de aprendizado (HAYKIN, 2001; BRAGA, CARVALHO e LUDERMIR, 2011; YADAV, YADAV e KUMAR, 2015).

Rosenblatt, em 1958, apresentou o método *perceptron* de aprendizagem supervisionada, introduzindo uma nova abordagem para o problema de Reconhecimento de Padrões (RP) (HAYKIN, 2001). O *perceptron*, como descrito por Rosenblatt, era formado por três camadas: a primeira camada (retina) recebe as entradas do exterior e, através de conexões com eficiência de transmissão ajustável, transmite os impulsos para a segunda camada, que, por sua vez, envia saídas para a terceira camada (FAUSETT, 1994; BRAGA, CARVALHO e LUDERMIR, 2011).

Em 1982, as pesquisas na área foram intensificadas após a publicação de John Hopfield destacando as propriedades associativas das RNAs. O autor relacionou as redes e os sistemas físicos, gerando interesse da física teórica pela modelagem neural (BRAGA, CARVALHO e LUDERMIR, 2011).

No período compreendido entre 1982 a 1986, várias pesquisas amplificaram significativamente o potencial das redes neurais artificiais (ZURADA, 1992). Após a introdução do algoritmo *backpropagation*, desenvolvido em 1986 por Rumelhart, Hinton e Williams, as pesquisas concentraram-se em propor alternativas eficientes de algoritmo de aprendizado. Desde então, o interesse

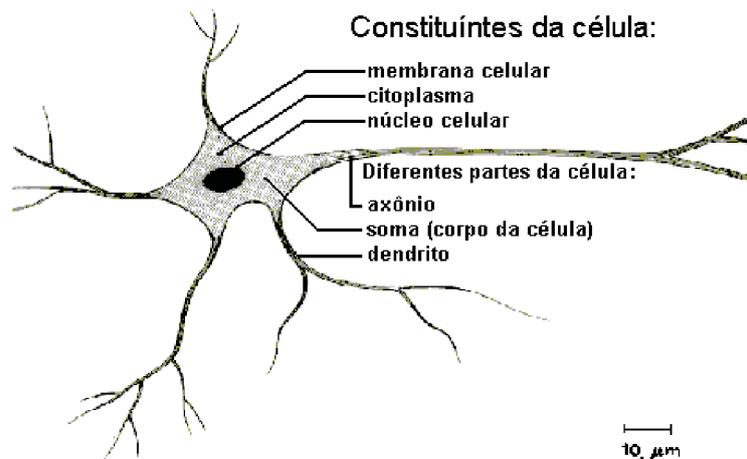
pelas redes neurais se intensificou e a área passou por transformações significativas (HAYKIN, 2001; BRAGA, CARVALHO e LUDERMIR, 2011).

Para se ter a compreensão da estrutura de um neurônio artificial e a forma de organização física entre estes, é necessária a sua comparação com os neurônios biológicos, descritos nas seções seguintes.

2.3.3.1.2 Cérebro humano

O cérebro humano é composto por aproximadamente cem bilhões de neurônios que se comunicam entre si através de uma rede de conexões, chamada de rede neural. Essa rede é capaz de reconhecer padrões e relacioná-los, além de usar e armazenar conhecimento por experiência (BRAGA; CARVALHO; LUDERMIR, 2011; PAWLINA, 2016).

FIGURA 7 - CONSTITUINTES DA CÉLULA NEURAL



FONTE: TATIBANA E KAETSU (2000)

Conforme o esquema apresentado na FIGURA 7, um neurônio biológico apresenta três seções principais: o corpo da célula (Soma), o Axônio e os Dendritos (BARRETO, 2002; PAWLINA, 2016).

Os dendritos são ramificações distribuídas ao redor do corpo do neurônio que recebem informações vindas de outros neurônios por meio do axônio. O axônio, por sua vez, é uma longa fibra cilíndrica, cujas extremidades são conectadas aos dendritos de outros neurônios pelas sinapses, formando as

redes neurais biológicas. As sinapses são responsáveis pela transmissão de impulsos nervosos de um neurônio para os neurônios vizinhos, estabelecendo assim um fluxo de informação. (BARRETO, 2002; ZURADA, 1992).

O neurônio recebe o sinal através da sinapse e o compara com os outros sinais recebidos. Se o percentual de excitação for superior ao seu limiar, produz um impulso que é transmitido para os seus neurônios vizinhos, e assim por diante. Esse sistema é essencialmente responsável pelo funcionamento, comportamento e raciocínio humano e, quando todos os neurônios da rede funcionam em paralelo, são capazes de realizar funções complexas (BRAGA; CARVALHO; LUDERMIR, 2011).

2.3.3.1.3 Neurônio Artificial

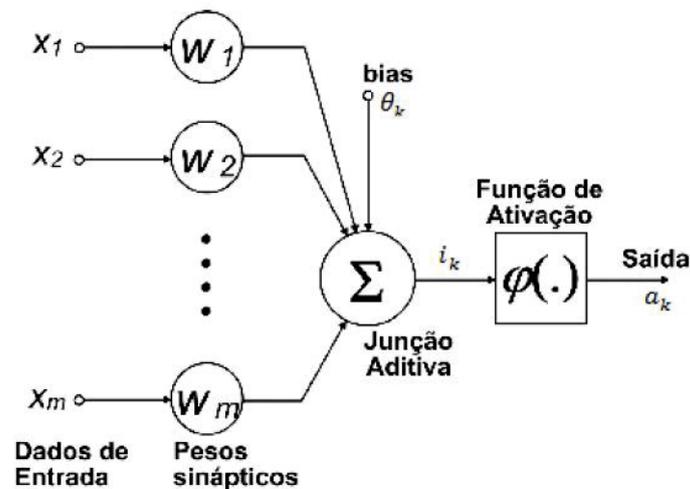
As unidades simples de processamento de informação que constituem uma rede neural artificial são denominadas neurônios artificiais (HAYKIN, 2001).

Boukadida *et al.* (2011) apresentam que, da mesma forma que sua contraparte biológica, o neurônio artificial é a unidade básica que compõe a RNA, e os elementos básicos que o compõem são:

- I. Um conjunto de nós de entrada que recebe o sinal de entrada correspondente ou um vetor de padrões;
- II. Um conjunto de conexões sinápticas cujas forças são representadas por um conjunto de pesos;
- III. Uma função de ativação que relaciona a entrada sináptica com a saída (ativação) do neurônio.

De uma forma geral, a estrutura de um neurônio artificial pode ser representada pela FIGURA 8.

FIGURA 8 - ESTRUTURA DE UM NEURÔNIO ARTIFICIAL



FONTE: Adaptado de HAYKIN, 2001.

Os terminais de entrada recebem os valores X_i ($i = 1, \dots, m$), que representam os sinais dos neurônios anteriores, e, para representar o comportamento das sinapses, têm pesos sinápticos acoplados (w_1, w_2, \dots, w_m), que determinam em que grau o neurônio deve considerar os sinais de disparo que ocorrem naquele terminal de entrada. O efeito de uma sinapse i no neurônio é dado, portanto, por $X_i W_i$.

Enquanto um neurônio biológico dispara quando a soma dos impulsos recebidos é maior que o seu limiar de excitação, o neurônio artificial faz a soma dos valores $x_m w_m$ recebidos e compara com o seu limiar para decidir se deve ou não disparar. A ativação acontece através da aplicação de uma função de ativação, que ativa ou não a saída e que tem a finalidade de evitar o acréscimo progressivo dos valores de saída ao longo das camadas da rede (LUDWIG e MONTGOMERY, 2007).

Além disso, há também o bias que atua aumentando ou diminuindo esta entrada da função de ativação (BRAGA; CARVALHO; LUDERMIR, 2011). Esta variável é incluída ao somatório da função de ativação, com o intuito de aumentar o grau de liberdade desta função e, conseqüentemente, a capacidade de aproximação da rede. O valor do bias é ajustado da mesma forma que os pesos sinápticos e possibilita que um neurônio apresente saída não nula ainda que todas as suas entradas sejam nulas. (LUDWIG e MONTGOMERY, 2007).

Matematicamente, essas relações são ilustradas nas expressões 5 e 6. Na expressão 5 representa-se a consolidação das entradas no neurônio da camada j partidas da camada i , recebendo ainda o *bias*, representado por θ .

$$entrada_j = \sum_i w_{ij}x_i + \theta_j \quad (5)$$

A expressão 6, por sua vez, representa o seu valor de saída, ou ativação onde $F(x)$ é a função de ativação e pode assumir naturezas distintas, as quais são descritas na seção 3.2.3.1.6.

$$a_j = F \left(\sum_i w_{ij}x_i + \theta_j \right) \quad (6)$$

Enquanto neurônios artificiais possuem capacidade computacional limitada, um conjunto deles conectados em forma de rede é capaz de resolver problemas complexos (BRAGA, CARVALHO e LUDERMIR, 2011). Estas redes são denominadas Redes Neurais Artificiais e, segundo Fausett (1994), se diferenciam entre si por três aspectos: sua arquitetura, seu algoritmo de aprendizado e sua função de ativação. Tais aspectos são tratados nas seções seguintes.

2.3.3.1.4 Arquiteturas de rede

Na resolução de problemas, um neurônio pode não ser suficiente para a obtenção da solução desejada. Para tal, pode ser necessária uma quantidade maior de neurônios operando em paralelo. Tal organização é chamada de "camada". A composição de camadas de uma RNA é chamada de arquitetura, ou topologia da rede (HAYKIN, 2009).

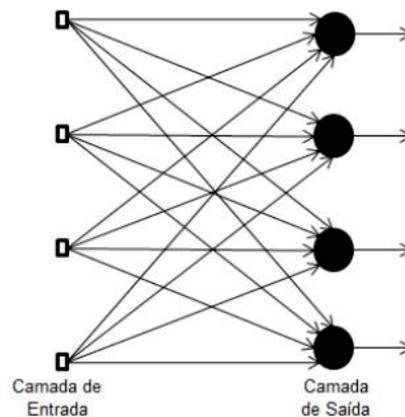
Na forma mais simples de uma rede em camadas, pode existir uma camada de entrada de nós de origem que se projeta diretamente para uma camada de saída de neurônios, mas não vice-versa (HAYKIN, 2009). Essa arquitetura é chamada de rede *feedforward* de camada única. A denominação

“camada única” se refere à camada de saída, uma vez que a de entrada não é contabilizada pois nela não é realizada nenhuma computação (HAYKIN, 2001).

Da mesma forma, Barreto (2002) define as redes *feedforward* de camada única como aquelas cujos grafos são acíclicos. Nestas estruturas, os neurônios são organizados em camadas conectadas por pesos direcionados unicamente da entrada para a saída, ou seja, existem conexões somente entre neurônios pertencentes a camadas diferentes e subsequentes.

Um exemplo desta topologia é apresentado na FIGURA 9 , onde se ilustra uma rede *feedforward* de camada única com quatro nós de fonte e quatro neurônios na camada de saída.

FIGURA 9 - REDE FEEDFORWARD DE CAMADA ÚNICA



FONTE: Adaptado de HAYKIN (2001)

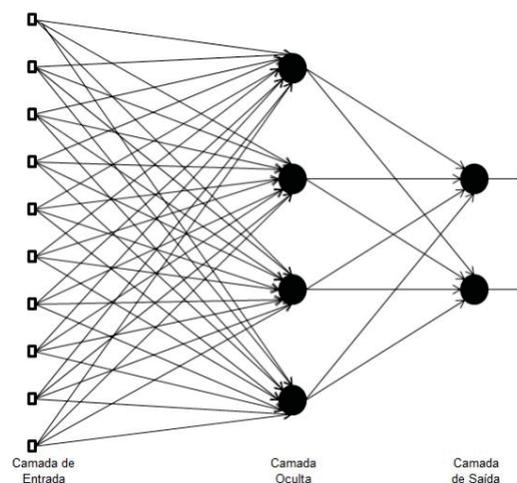
Uma outra classificação da rede neural feedforward distingue-se pela presença de uma ou mais camadas ocultas, operando em paralelo, cujos nós de computação são correspondentemente chamados de neurônios ocultos. O termo "oculto" refere-se ao fato de que esta parte da RNA não é vista diretamente da entrada ou da saída da rede. As redes *feedforward* com múltiplas camadas se distinguem por possuírem uma ou mais camadas adicionais que proporcionam maior capacidade computacional e universalidade na aproximação de funções contínuas (BRAGA, CARVALHO e LUDERMIR, 2011).

Os neurônios na camada oculta atuam na rede tornando-a capaz de extrair estatísticas de ordem elevada. Nessa classificação, os nós da camada de entrada fornecem os sinais de entrada aplicados aos neurônios da primeira camada

oculta, e os sinais de saída desta camada são utilizados como entrada para a segunda camada oculta, e assim por diante. A resposta da rede para os parâmetros de entrada recebidos é constituída pelos sinais de saída da camada de saída (HAYKIN, 2001).

A rede neural *feedforward* com múltiplas camadas é apresentada como exemplo na FIGURA 10, onde se observa uma única camada oculta. Esta rede é referida como uma rede 10-4-2, pois possui 10 nós de fonte, 4 neurônios ocultos e 2 neurônios de saída. Além disso, a mesma é considerada totalmente conectada, ou seja, cada um dos nós de uma camada está conectado a todos os nós da próxima camada adjacente. Essa topologia também é definida como MLP (*Multilayer Perceptron*).

FIGURA 10 - REDE FEEDFORWARD COM MÚLTIPLAS CAMADAS



FONTE: Adaptado de HAYKIN (2001)

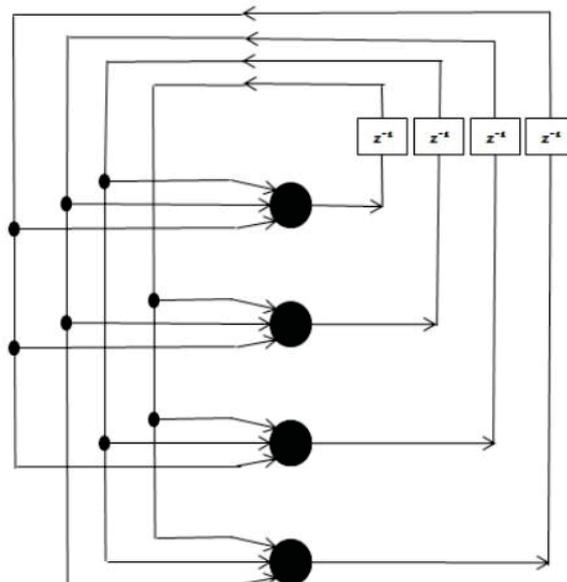
Não existe um critério pré-determinado para definir o número de camadas ocultas, bem como o número de neurônios a serem colocados nesta. Em geral, redes neurais com poucos neurônios são preferidas, pois tendem a possuir um maior poder de generalização, evitando assim o sobreajuste (*overfitting*). Contudo, se a rede possuir poucos neurônios, a mesma não aprende, prejudicando a convergência do resultado final (*underfitting*) (KAYKIN, 2001).

A terceira topologia é nomeada de RNA Recorrentes. Segundo Haykin (2009), essa arquitetura distingue-se das demais pelo fato de possuir pelo menos

um loop de retroalimentação, chamado laço de realimentação. Nessas estruturas, a saída não depende apenas dos dados de entrada, mas também do seu valor atual (BRAGA; CARVALHO; LUDERMIR, 2011).

A rede recorrente ilustrada na FIGURA 11 possui uma única camada de neurônios, sendo que cada neurônio alimenta seu sinal de saída de volta para as entradas de todos os outros neurônios. Nesta ilustração de rede não há laços de auto realimentação, ou seja, situações onde a saída de um neurônio é realimentada para a sua própria entrada, existindo apenas a realimentação a partir dos neurônios ocultos (HAYKIN, 2001).

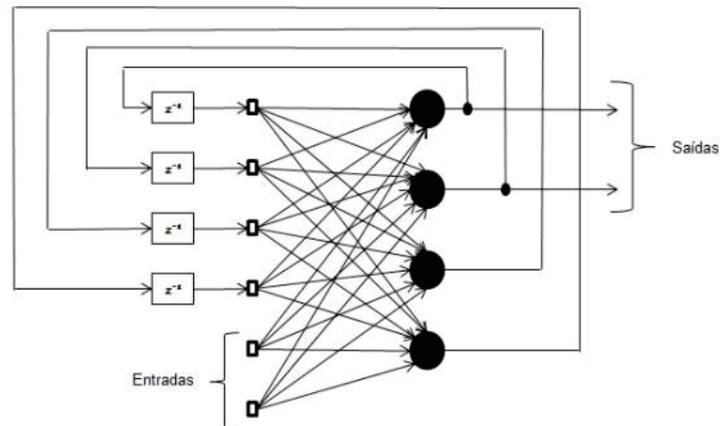
FIGURA 11 - REDE RECORRENTE SEM LAÇOS DE AUTO REALIMENTAÇÃO E SEM NEURÔNIOS OCULTOS



FONTE: Adaptado de HAYKIN (2001)

Na FIGURA 12, por sua vez, é ilustrada outra possibilidade de rede recorrente, onde as conexões de realimentação se originam tanto de neurônios ocultos quanto dos neurônios de saída. Segundo Haykin (2001), a presença dos laços de realimentação em ambas as estruturas impacta significativamente no aprendizado e no desempenho da rede neural.

FIGURA 12 - REDE RECORRENTE COM NEURÔNIOS OCULTOS



FONTE: Adaptado de HAYKIN (2001)

Braga, Carvalho e Ludermir (2011) afirmam que a escolha da arquitetura de RNA a ser utilizada depende de diversos fatores, entre eles:

- O grau de complexidade do problema,
- A dimensão do espaço de entrada,
- Se o problema tem características dinâmicas ou estáticas
- Conhecimento que se tem sobre o problema
- Representatividade dos dados.

Depois da decisão da arquitetura da RNA a ser utilizada, deve-se definir como funcionará o aprendizado da estrutura para que se possa lidar com os dados.

2.3.3.1.5 Processos de aprendizado

Dada uma RNA, o processo de aprendizado ocorre à proporção que seus parâmetros livres forem ajustados por meio de uma forma continuada de estímulo originada do ambiente externo. Tal processo está relacionado à melhoria do desempenho da rede de acordo com alguma medida preestabelecida (BRAGA; CARVALHO; LUDERMIR, 2011).

Esta definição do processo de aprendizagem implica, segundo Haykin (2001), na seguinte sequência de eventos:

- A rede neural é estimulada por um ambiente.

- A rede neural sofre modificações nos seus parâmetros livres como resultado desta estimulação.
- A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna.

A um conjunto de regras bem definidas para a solução de um problema de aprendizado denomina-se algoritmo de aprendizado. Existem vários tipos de algoritmos de aprendizado, tais como, backpropagation, perceptron, entre outros, específicos para determinados modelos de redes neurais. Normalmente, estes algoritmos diferem entre si pelo modo como os pesos são modificados (TATIBANA e KAETSU, 2000).

Um exemplo de mecanismos de aprendizado pode ser ilustrado pela regra delta (ou regra de Widrow-Hoff). Matematicamente, pode-se definir a atualização dos pesos da rede na iteração n pela expressão 7.

$$w_{kj}(n + 1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (7)$$

Onde w_{kj} representa o peso do neurônio k da camada j , e Δw_{kj} o ajuste deste peso, com $0 < j < 1$ (onde $j=0$ representa o bias e n representa a n -ésima informação (entrada) analisada no momento). O ajuste Δw_{kj} aplicado no peso sináptico w_{kj} , de acordo com a regra delta, é definido pela expressão 8.

$$\Delta w_{kj}(n) = \gamma \cdot \delta_k(n) \cdot x_j(n) \quad (8)$$

Onde γ é a taxa de aprendizado ($0 < \gamma < 1$), δ_k é o erro obtido, ou seja, a diferença entre o valor esperado (d_j) e o sinal de saída da rede (a_k) como definido na expressão 9 e, finalmente, x_j é o sinal de entrada.

$$\delta_k(n) = d_j(n) - a_k(n) \quad (9)$$

Como afirmado por Tatibana e Kaetsu (2000), os algoritmos de aprendizado diferem entre si na forma como o Δw_{kj} é calculado.

2.3.3.1.6 Função de ativação

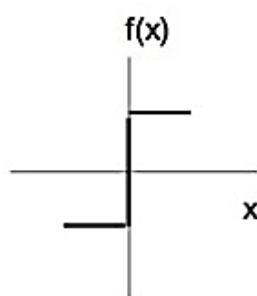
A função de ativação é responsável por gerar a saída y do neurônio a partir dos valores dos vetores de peso w e de entrada x , bem como do bias θ considerado (BRAGA, CARVALHO e LUDERMIR, 2011). É uma função matemática que, aplicada à combinação linear entre as variáveis de entrada e os pesos que chegam a determinado neurônio, retorna ao seu valor de saída. (FAUSETT, 1994; HAYKIN, 2001; BRAGA, CARVALHO E LUDERMIR, 2011).

Quanto as funções de ativação das RNA, Hagan *et al.* (2014) apresentam as três mais utilizadas, sendo elas a função de limite rígido (Função Limiar ou Função Passo), a função linear e a função sigmoideal.

A função de limite rígido é definida, segundo Haykin (2001) e Fausett (1994), pela expressão 10 e ilustrada na FIGURA 13. A função define a saída do neurônio para “ $-y$ ” se o argumento de função for menor que 0, e “ $+y$ ” se seu argumento for maior ou igual a 0.

$$f(x) = \begin{cases} -y, & \text{se } x < 0 \\ +y, & \text{se } x \geq 0 \end{cases} \quad (10)$$

FIGURA 13 - GRÁFICO DA FUNÇÃO DE LIMITE RÍGIDO

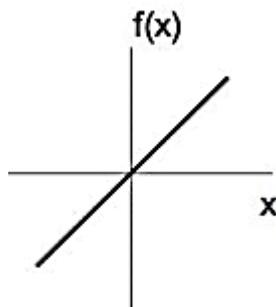


FONTE: O Autor (2018)

A função linear apresenta como principal característica o fato da saída ser igual à entrada da função. A função pode ser definida, segundo Braga, Carvalho e Ludermir (2011) e Fausett (1994), pela expressão 11 e ilustrada na FIGURA 14.

$$f(x) = ax \quad (11)$$

FIGURA 14 - GRÁFICO DA FUNÇÃO LINEAR

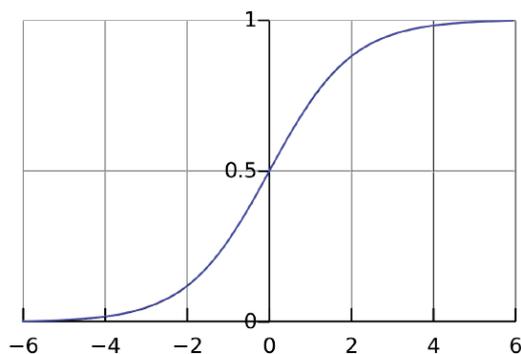


FONTE: O Autor (2018)

A última das principais funções de ativação das RNA é a Sigmoidal. Esta função é comumente utilizada em redes de múltiplas camadas que são treinadas usando o algoritmo backpropagation, o qual será apresentado nas próximas seções. O gráfico desta função é representado na FIGURA 15 e sua equação matemática identificada na expressão 12, onde σ é o parâmetro de inclinação da sigmóide (HAYKIN, 2001).

$$f(x) = \frac{1}{1 + e^{-\sigma x}} \quad (12)$$

FIGURA 15 - GRÁFICO DA FUNÇÃO SIGMOIDAL



FONTE: BREUEL (2013)

Esta função recebe a entrada, que pode ter qualquer valor pertencente ao intervalo $(-\infty, +\infty)$, e a conduz à saída, que poderá ter qualquer valor pertencente ao intervalo $(0, 1)$.

2.3.3.1.7 Treinamento

O processo de treinamento supervisionado de uma rede se constitui em um problema de otimização no ajuste de pesos das conexões e exige a apresentação da base de dados à rede por diversas vezes, até que o conjunto de pesos encontrados satisfaça a condição desejada para o erro apurado. Nessa etapa, podem ocorrer dificuldades associadas a problemas de convergência, existência de mínimos locais e tempo de computação indeterminado.

O algoritmo de aprendizagem, ou de treinamento, é escolhido em função do tipo de rede utilizada e das características dos dados que serão ajustados. De acordo com os parâmetros que eles atualizam, os algoritmos para treinamento podem ser classificados como estáticos ou dinâmicos. (KOVÁCS, 2002).

Os algoritmos estáticos não alteram a estrutura da rede, variando apenas os valores de seus pesos, os algoritmos dinâmicos podem tanto reduzir quanto aumentar o tamanho da rede (número de camadas, número de nós nas camadas ocultas e o número de conexões).

Um problema que pode ocorrer durante o treinamento de redes é a ocorrência de *overfitting*. Este ocorre quando, após um determinado ciclo do treinamento, a rede, em vez de melhorar, começa a piorar a sua taxa de acertos para padrões diferentes daqueles utilizados para o ajuste dos pesos. Diz-se então que a rede memorizou os padrões de treinamento, gravando suas peculiaridades e ruídos. Isto tem como resultado uma piora na capacidade de generalização da rede.

De acordo com Demuth, Beale e Hagan (2010), assim como para os problemas de lentidão e mínimos locais, existem alternativas para lidar com o problema de *overfitting*, que podem ser encerrar o treinamento da rede ou podar os pesos dessa.

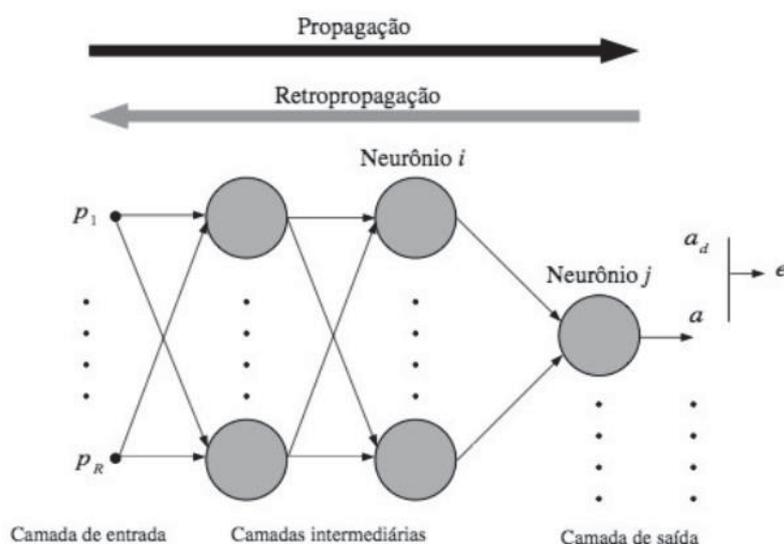
O algoritmo *backpropagation*, ou algoritmo de retropropagação, é o mais utilizado para o treinamento de redes MLP (SANTOS *et al.*, 2005; BRAGA; CARVALHO; LUDERMIR, 2011) e a aplicação deste algoritmo requer a escolha de um conjunto de parâmetros (número de iterações do algoritmo, critério de parada, pesos iniciais e taxa de aprendizado) cuja influência pode ser decisiva para a capacidade de generalização da rede.

Por tratar-se um algoritmo de aprendizado supervisionado, o treinamento da rede neural por este algoritmo envolve três estágios (FIGURA 16) (FAUSETT, 1994):

- Propagação dos parâmetros de entrada
- Retropropagação do erro associado
- Ajuste dos pesos

Na fase de propagação, os valores de entrada são aplicados como estímulo à primeira camada da rede, e as saídas da primeira camada intermediária são calculadas. As saídas da primeira camada intermediária serão as entradas da camada intermediária seguinte, e assim por diante, até que se chegue na camada de saída. A saída produzida pelos neurônios da camada de saída é então comparada com a saída desejada, gerando um erro para cada elemento de saída (MATSUNAGA, 2012).

FIGURA 16 - ILUSTRAÇÃO DO ALGORITMO BACKPROPAGATION



FONTE: MATSUNAGA (2012)

Em seguida, inicia-se a fase de retropropagação. Os sinais de erro encontrados são retropropagados da camada de saída para a camada intermediária imediatamente anterior. Para isso, são utilizados os pesos das conexões, que são multiplicados pelos erros correspondentes para encontrar o valor de erro estimado para cada neurônio da camada intermediária. Os erros calculados para a camada intermediária são então utilizados para ajustar os seus pesos pelo gradiente decrescente. Este processo se repete camada por camada, até que se conclua o ajuste dos pesos de toda a rede (BRAGA; CARVALHO; LUDERMIR, 2011; MATSUNAGA, 2012).

Como critério de parada do algoritmo é utilizado, em geral, um número máximo de ciclos ou iterações.

2.3.3.1.8 Medidas de erro de uma rede MLP

Quando é apresentada a rede um conjunto de entrada, esta retorna um conjunto de valores de saída, que é comparado ao conjunto de valores de saída desejado. Em seguida os pesos sinápticos e níveis de bias são ajustados de forma a minimizar a diferença entre a saída apresentada pela rede e a saída desejada de acordo com a metodologia *backpropagation* de treinamento.

Este processo é realizado para todos os pares de entrada e saída que constituem o conjunto de treinamento da rede até que a taxa de acerto seja considerada satisfatória. Na MLP, o sinal de erro do neurônio de saída j , na interação n , é definido pela expressão 13.

$$e_j(n) = d_j(n) - y_i(n) \quad (13)$$

Onde, $d_j(n)$ – é a resposta desejada do neurônio j e $y_i(n)$ é a resposta calculada para o neurônio j . O erro quadrático médio (MSE) da rede, para os J neurônios da camada de saída, na interação n , é definido pela expressão 14.

$$MSE = \frac{1}{J} * \sum_{j=i}^J e_j^2(n) \quad (14)$$

De acordo com Ludwig e Montgomery, (2007) o erro de cada neurônio é elevado ao quadrado para evitar que um erro negativo oriundo de um neurônio compense um erro positivo de outro.

A raiz quadrada do erro quadrático médio (RMSE) da rede para todo o conjunto de treinamento, ou seja, para um número N de interações necessárias para apresentar todo um ciclo de treinamento em cada exemplo utilizado, é definida conforme a expressão 15.

$$RMSE = \sqrt{MSE} \quad (15)$$

O desempenho da rede neural, nesse estudo, foi avaliado por meio da raiz quadrada do erro quadrático médio (RMSE), que é raiz quadrada da média do somatório dos quadrados dos erros de cada caso.

2.3.3.1.9 Redes neurais na avaliação de qualidade de cimentos

Como já destacado pela literatura no capítulo II, a resistência à compressão de cimentos é a principal característica considerada para a avaliação de desempenho e qualidade deste produto. Nesta seção, portanto, são consolidados os principais trabalhos correlatos que consideram a RNA como metodologia de predição desta característica com o objetivo de verificar vantagens de parametrização.

A partir dos dados consolidados na seção 3.1, dois trabalhos se destacam pela aplicação da metodologia de RNA na predição da resistência à compressão de cimentos utilizando variáveis do processo. No QUADRO 13 são resumidas as parametrizações das RNAs.

Diferentemente da metodologia de treino de back-propagation apresentada neste estudo, Baykasoglu, Dereli e Tanis (2004) consideram a metodologia Delta-Bar-Delta. Essa técnica de aprendizagem visa aumentar a velocidade de convergência por meio da aplicação de heurísticas. Neste método, cada peso tem seu próprio coeficiente de aprendizagem, e os valores históricos são considerados para calcular os erros futuros (Negnevitsky,2002).

QUADRO 13 – PARAMETRIZAÇÃO DOS PRINCIPAIS TRABALHOS CORRELATOS

	Akkurt, Ozdemir, Tayfur e Akyol	Baykasoglu, Dereli e Tanis
Topologia	Multi Layer Perceptron	Rede Recorrente com múltiplas camadas
Nº de camadas	3	3
Nº de camadas ocultas	1	1
Nº de neurônios nas camadas ocultas	20	13
Nº de neurônios na camada de entrada	20	19
Nº de neurônios na camada de saída	1	1
Metodologia de treino	Back-propagation	Delta-bar-delta
Função de ativação	Sigmoidal	Sigmoidal

FONTE: O Autor, 2017.

Avaliando os estudos, percebe-se algumas semelhanças e diferenças na parametrização definida. No que tange a topologia, Akkurt, Ozdemir, Tayfur e Akyol (2004) consideraram uma rede feedforward de múltiplas camadas, ao passo que os outros autores utilizaram uma rede recorrente. As duas metodologias consideraram múltiplas camadas na rede (um camada de entrada, uma camada oculta e uma camada de saída).

Em relação ao número médio de neurônios na camada oculta, Baykasoglu, Dereli e Tanis (2003) definiram o mesmo por meio da expressão 16 , onde n é o número de neurônios na camada de entrada. Neste valor, soma-se e subtrai-se o valor 3 para realização de simulações com diferentes estruturas de rede. Para o estudo, o melhor resultado foi encontrado para 13 neurônios.

$$n^{\circ} \text{ de neurônios na camada oculta} = 2 * \sqrt{(n + 1)} \quad (16)$$

Akkurt, Ozdemir, Tayfur e Akyol (2004), por sua vez, testaram diferentes números de neurônios, variando de 1 a 20, e selecionaram aquele que apresentou, junto as demais parametrizações, o melhor resultado final.

A função de ativação considerada em ambos os estudos é a função sigmoidal, destacadas pelos autores como a principal função utilizada neste tipo de

estudo. Como visto no QUADRO 10 da seção 3.1, o tipo de cimento considerado, bem como as variáveis de entrada na rede, são diferentes.

Sobre os resultados observados, Akkurt, Ozdemir, Tayfur e Akyol (2004) ilustram a obtenção de erro médio de 2,24% obtido pela média entre as diferenças dos valores preditos com os dados experimentais. Por sua vez, Baykasoglu, Dereli e Tanis (2003) obtiveram o coeficiente de determinação do modelo igual a 69,9%, demonstrando que o modelo representa de forma satisfatória a relação entre as variáveis.

2.3.4 Análise de Componentes Principais (ACP)

A ACP 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 (MINGOTI, S. A., 2007; VARELLA, C. A. A., 2008).

A ideia central desta metodologia é a de reduzir a dimensionalidade do conjunto de dados tal que p variáveis possam ser substituídas por k ($k < p$) componentes principais não correlacionadas entre si, de forma que seja mantida o máximo da variação dos dados originais. A qualidade dessa substituição depende do número de componentes conservadas no sistema e pode ser medida por meio da avaliação da proporção da variância total explicada por essas (JOLLIFFE, I. T.; 2002; MINGOTI, S. A., 2007).

Além desse objetivo, a ACP também pode ser aplicada para a seleção de variáveis. De acordo com Jolliffe (2002), as principais metodologias se baseiam na seleção daquelas de maior correlação com as componentes principais.

A obtenção das componentes principais envolve a decomposição espectral da matriz de correlação do vetor aleatório observado X . Uma vez determinadas as componentes principais, os seus valores numéricos denominados de escores, podem ser calculados para cada elemento amostral disponível. Esses valores obtidos podem ser, dessa forma, analisados por meio

de técnicas estatísticas usuais como a análise de regressão múltipla (MINGOTI, S. A., 2007; VARELLA, C. A. A., 2008).

A estrutura de uma ACP é definida a partir do cálculo dos autovetores e autovalores da matriz de covariância e, para os casos em que é definida a normalização dos dados, matriz de correlação.

Considerando a situação em que se observa p características de n ocorrências de determinada população, tem-se a matriz de dados definida como X de ordem $n \times p$. A estrutura de interdependência entre as p variáveis normalizadas é então definida pela matriz de correlação R , de ordem $p \times p$.

$$X = \begin{bmatrix} X_{1,1} & \cdots & X_{1,p} \\ \vdots & \ddots & \vdots \\ X_{n,1} & \cdots & X_{n,p} \end{bmatrix} \text{ (MATRIZ DE DADOS)}$$

$$R = \begin{bmatrix} 1 & \cdots & r_{1,p} \\ \vdots & \ddots & \vdots \\ r_{p,1} & \cdots & 1 \end{bmatrix} \text{ (MATRIZ DE CORRELAÇÃO)}$$

Os autovalores e autovetores da matriz R são calculados por meio da expressão 17 que, caso nenhuma coluna dessa matriz seja combinação linear de outra, terá p autovalores. E para cada autovalor λ_i existe um autovetor \tilde{a}_i associado.

$$|R - \lambda I| = 0 \quad (17)$$

Sendo \tilde{a}_i o autovetor correspondente ao autovalor λ_i , então a i -ésima componente principal é definida como na expressão 18.

$$Y_i = a_{i1}X_1 + \cdots + a_{ip}X_p \quad (18)$$

A contribuição de cada componente principal na variância do modelo é expressa em porcentagem e calculada por meio da expressão 19.

$$C_i(\%) = \frac{\lambda_i}{\sum_{i=1}^p \lambda_i} * 100 \quad (19)$$

A soma dos primeiros k autovalores ordenados representa a proporção de informação retida na redução de p para k dimensões. Com essa informação, e a definição de uma linha de corte, é possível definir quantos componentes são considerados na análise. Não existe um modelo estatístico exato que ajude nesta decisão. Entretanto, de acordo com a literatura, para aplicações em diversas áreas do conhecimento o número de componentes utilizados tem sido aquele que acumula pelo menos 70% da proporção da variância total explicada (JOHNSON e WICHERN, 1999; KHATTREE e NAIK, 2000; REGAZZI, 2000).

2.3.5 Seleção das variáveis

Os critérios definidos por Jolliffe (1972) para a seleção de variáveis são baseados nos valores dos autovalores obtidos no cálculo da ACP. São definidas pelo autor duas metodologias denominadas B2 e B4 onde são excluídas m variáveis, sendo m o número de autovalores menores ou iguais a 0,7. A aplicação dos métodos B2 e B4 gera, respectivamente, os cenários C e D considerados nesse estudo.

O método B2 seleciona as variáveis de maior correlação com cada um dos últimos componentes principais, ordenados de forma decrescente em relação aos autovalores, e exclui as mesmas. De acordo com Jolliffe (1972), o método B2 seleciona a variável de maior correlação com a última componente principal, em seguida, a próxima variável a ser selecionada será a de maior correlação correspondente à penúltima componente principal, e assim sucessivamente até a m -ésima componente principal. Caso a mesma variável apresente maior correlação em componentes diferentes, então a variável a ser selecionada será a de segunda maior correlação da componente correspondente.

Esse processo pode ser feito apenas uma vez, excluindo as m variáveis dos últimos m componentes, ou iterativamente. Se o processo for iterativo, deve-se excluir a variável de maior correlação com o último componente principal e

realizar novamente a ACP. O processo deve ser realizado enquanto houverem autovalores iguais ou menores que 0,7.

De acordo com Jolliffe (2002), os componentes de menor autovalor possuem baixo impacto na variabilidade do subconjunto avaliado e a exclusão da variável de maior correlação com este não gera grandes perdas de informação.

O método B4, por sua vez, 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.

O número n de variáveis que são mantidas no modelo é igual ao número de autovalores cujo valor é maior que 0,7. Assim, é possível notar que o método B4 é complementar ao método B2 com uma única iteração e se diferencia por selecionar as principais variáveis a partir das primeiras componentes principais.

2.3.6 K-fold

Em *k-fold* um conjunto de dados é aleatoriamente dividido em k partições mutuamente exclusivas (*folds*) e de tamanho aproximadamente iguais (n/k). As $(k-1)$ 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 o conjunto de treinamento $(k - 1)$ vezes. A variância é reduzida a medida que o k é aumentado. A desvantagem é que o algoritmo de treinamento deve ser repetido k vezes, o que significa um custo operacional elevado (MARTINELLI, 1999; STEINER, 2012; ALPAYDIN, 2010).

CAPITULO III

3 MÉTODO DE PESQUISA

Este capítulo apresenta a classificação da pesquisa realizada, bem como o método de pesquisa que será adotado neste trabalho.

3.1 CLASSIFICAÇÃO DA PESQUISA

De acordo com Gil (2008), o método indutivo parte do específico e coloca a generalização como um produto posterior do trabalho de coleta de dados particulares. Seguindo esse tipo de raciocínio, a generalização de uma determinada ideia não deve ser buscada inicialmente, mas constatada a partir da observação de casos concretos que, suficientemente, poderão confirmar essa realidade. Dessa forma, a pesquisa a ser realizada classifica-se como indutiva uma vez que, a partir de dados experimentais reais de uma planta produtora de cimentos, ela possa ser futuramente replicada.

Analisando os métodos que indicam os meios técnicos de investigação expostos por Gil (2008), observa-se que o método que proporcionará a investigação é o método experimental. Tendo em vista que este método consiste em submeter os objetos de estudo à influência de certas variáveis, em condições controladas e conhecidas, visando à observação dos resultados que a variável produz no objeto. Segundo o autor, boa parte dos conhecimentos obtidos nos últimos três séculos se deve ao emprego do método experimental, que pode ser considerado como o método por excelência das ciências naturais.

Observando a natureza da pesquisa a ser desenvolvida, expõe-se que a mesma é considerada aplicada, pois, segundo Gil (2008), esse tipo de pesquisa volta-se para a aplicação imediata numa realidade circunstancial. Para justificar essa classificação tem-se o interesse nos efeitos práticos dos conhecimentos gerados, ou seja, a predição da resistência à compressão aos 28 dias dos cimentos compostos produzidos pela Votorantim Cimentos.

Quanto à forma de abordagem, essa pesquisa é classificada como mista, devido ao fato que não apenas os dados analisados podem ser quantificados, mas também exige uma análise desses dados por parte do pesquisador no momento que forem obtidos os resultados da pesquisa. Dessa forma, a pesquisa em questão é classificada como mista, por conter características de ambas as formas de abordagem.

De acordo com Gil (2008), quanto aos objetivos, esta pesquisa classifica-se como descritiva, uma vez que objetiva descrever fatos de determinada realidade. Quanto aos procedimentos técnicos, que representam o delineamento da pesquisa realizada, serão utilizados neste trabalho, de acordo com Gil (2008), levantamento bibliográfico, visto que esta pesquisa implica leituras sobre o assunto, auxiliando o entendimento sobre o problema e utilização de referências teóricas para execução da pesquisa, a pesquisa documental, pois dependerá das informações das unidades produtoras da empresa estudada, e também se trata de um estudo de caso, uma vez que serão levantados dados de uma fábrica de cimentos, e, ainda, pode-se incluir a pesquisa experimental, devido ao fato que após determinar um objetivo de estudo, serão selecionadas as variáveis capazes de influenciá-lo.

Finalmente, o instrumento de coleta de dados a ser utilizado nesta pesquisa, segundo Gil (2008), é a análise documental. No caso desta pesquisa, virá em formato de registros estatísticos e documentos da Votorantim Cimentos, onde o trabalho será desenvolvido.

Com base nas definições apresentadas anteriormente, a pesquisa deste trabalho foi enquadrada na estrutura a seguir, representada pelo FIGURA 17.

FIGURA 17 – ENQUADRAMENTO DA PESQUISA



FONTE: O Autor (2018).

A descrição detalhada das etapas que serão realizadas, bem como o cronograma para a sua implementação, é feita nas seções seguintes.

3.2 MATERIAIS E MÉTODOS

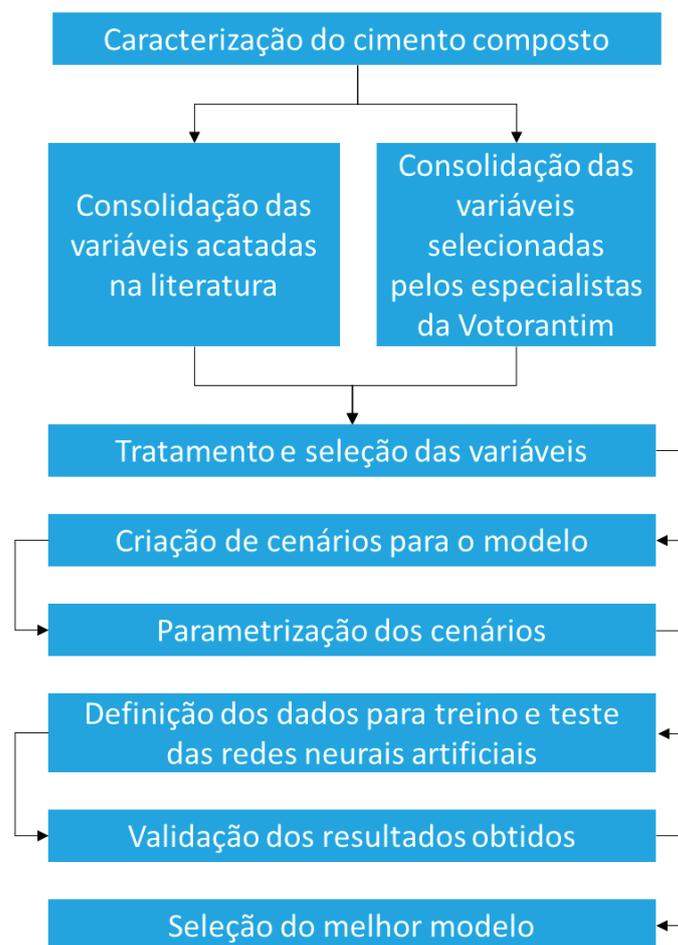
O estudo da definição de resistência à compressão realizado neste trabalho tem como objetivo o desenvolvimento de um modelo preditivo para apoiar a tomada de decisão de qualidade sobre os cimentos produzidos.

Para o estabelecimento da metodologia do trabalho foi necessário realizar um levantamento das metodologias existentes no segmento da inteligência artificial e, na sequência, das arquiteturas de RNA existentes, os métodos de validação de rede mais utilizados, quais são as principais aplicações de RNA no estudo de desempenho de cimentos, bem como identificação da lacuna existente neste ramo de pesquisa.

Dentre os trabalhos pesquisados, encontram-se poucas aplicações que consideram variáveis dos subprodutos e das matérias-primas do processo produtivo do cimento, mais raros ainda os que consideram cimentos compostos para o estudo. A pesquisa em questão visa preencher esta lacuna propondo um modelo preditivo, a partir da aplicação de RNA, de cimentos compostos considerando as características do clínquer, das adições, do processo de moagem do cimento, e das características de desempenho finais desse produto. A metodologia aplicada neste trabalho pode ser resumida na FIGURA 18.

Na etapa de caracterização do cimento composto considerado para o estudo é detalhado o cimento do tipo CP II-E produzido na unidade de Santa Helena. Para a definição das variáveis que são consideradas para a predição da resistência à compressão é realizada a verificação daquelas acatadas na literatura, bem como aquelas escolhidas pelos especialistas da Votorantim Cimentos por meio de entrevistas informais. A seleção dos especialistas é baseada em suas experiências no processo produtivo e nas suas percepções de possibilidades de influência na resistência final dos cimentos.

FIGURA 18 - ESTRUTURA DA METODOLOGIA APLICADA



FONTE: O Autor (2018)

A etapa de tratamento e seleção de variáveis é responsável por definir a forma com que as variáveis são escolhidas e consideradas no problema estudado, influenciando na geração dos diferentes cenários para a criação do modelo de predição. Nessa etapa é considerada a aplicação do método de Análise de Componentes Principais (ACP) sendo utilizado o software R para a execução das análises.

No passo seguinte, na criação de cenários para a realização do modelo, são definidos diferentes conjuntos de variáveis considerando as suas influências na resistência à compressão aos 28 dias com o objetivo de buscar, para o modelo gerado, a maior explicação da variável resposta. Para isso serão considerados, para todos os cenários, a aplicação das redes neurais artificiais com o objetivo de predição da resistência à compressão de forma numérica e a

aplicação das redes neurais artificiais com o objetivo de classificação das resistências à compressão em dois grupos de acordo com limites pré estipulados, dentro dos limites ou “conformes” e fora dos limites ou “não conformes”.

Na sequência, na parametrização dos cenários, são definidos e ajustados os parâmetros fundamentais das RNAs. É considerada a topologia MLP com apenas uma camada oculta. Para essa camada é variado o número de neurônios de processamento com o objetivo de encontrar o melhor resultado para os dados considerados.

As etapas de treino e de teste são realizadas considerando os dados disponíveis na planta e a definição dos grupos de dados de treino e de teste pela metodologia *k-fold*, variando o valor de *k* de 3 até 10.

Na sequência são performados os cenários propostos e avaliada a qualidade de cada um desses visando determinar a melhor aproximação dos resultados do modelo preditivo com os valores experimentais observados. A verificação da qualidade é feita a partir da apuração dos erros quadráticos médios (RMSE) e do coeficiente de correlação. Nessa etapa, os modelos de RNA para classificação da resistência são considerados para fortalecer a escolha da melhor parametrização de rede.

Por fim, a etapa de conclusão é responsável por validar os resultados encontrados para definir o melhor modelo de predição para os cimentos compostos da unidade estudada. A implementação da RNA ocorre por meio de programações no ambiente Visual Basic®.

CAPITULO V

4 DESENVOLVIMENTO E RESULTADOS

Neste Capítulo, as técnicas do Capítulo III são utilizadas na resolução do problema de pesquisa desse trabalho e para isso é fundamental que se façam alguns comentários a respeito das informações e das parametrizações realizadas para a utilização destas nos algoritmos escolhidos.

As variáveis consideradas para o modelo de predição são avaliadas por meio da Análise de Componentes Principais (ACP) com o objetivo de gerar diferentes cenários para definição do modelo de predição a partir de metodologias para redução da dimensionalidade, como o critério de Kaiser, e de metodologias para seleção de variáveis (B2 e B4), conforme orientações da literatura definidas por Jolliffe (2002).

O resultado das análises de ACP resulta na divisão de três grandes conjuntos de dados para treinamento e teste das RNAs. No primeiro treinamento, foram utilizadas todas as variáveis do problema; o segundo treinamento foi executado após a aplicação da ACP com o objetivo de substituir as variáveis pelas componentes principais, reduzindo a dimensionalidade do modelo. O terceiro treinamento, por sua vez, foi realizado após a aplicação da ACP visando a redução do número de variáveis no modelo, diminuindo o problema apenas às componentes que explicam a maior parte da variabilidade da variável resposta investigada.

Para cada cenário gerado foram avaliados os resultados obtidos para que o modelo mais adequado aos dados considerados fosse o escolhido. A medida de escolha foi baseada na Raiz Quadrada do Erro Quadrático Médio do modelo (RMSE) na etapa de treino e no coeficiente de correlação entre os valores observados e os preditos na etapa de validação.

4.1 DELIMITAÇÃO DO PROBLEMA

Para o desenvolvimento dessa pesquisa foram considerados os dados do cimento do tipo CP II-E 40 produzido na unidade de Santa Helena da

Votorantim Cimentos, no estado de São Paulo. A unidade atende o segmento de concreteiras da regional Sudeste e responde por aproximadamente 10% do volume total produzido nas unidades fabris da Votorantim Cimentos no Brasil. Desse valor, o cimento CP II-E 40 representa aproximadamente 30% do volume expedido pela unidade.

Para a coleta de dados e caracterização dos cimentos produzidos são consideradas todas as análises disponíveis na unidade produtora que considerem as variáveis identificadas na literatura consolidada bem como as identificadas como candidatas pelos especialistas da Votorantim Cimentos (Engenheiros e técnicos responsáveis pela qualidade do cimentos produzido), respeitando a disponibilidade para realização das amostragens e execução dos ensaios, ou seja, sem interferir no plano de qualidade da fábrica para que o estudo pudesse ser performado sem impactar na rotina produtiva.

O referido procedimento foi utilizado no intuito de entender o comportamento das variáveis aferidas no cimento produzido da unidade de Santa Helena a fim de possibilitar a criação de um modelo de regressão capaz de representar a situação estudada. As variáveis consideradas para caracterização do cimento são apresentadas no QUADRO 14.

QUADRO 14– VARIÁVEIS CONSIDERADAS PARA A CARACTERIZAÇÃO DO CIMENTO

Classificação do 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 (%) ²	Alita, belita, C ₃ A ortorrômbico, C ₃ A cúbico, ferrita, CaO livre, periclásio, arcanita, aftitalita, lagbeinita, calcita, dolomita, quartzo, gispsita, bassanita, escória, portlandita e fluorita.
Ensaio 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.

FONTE: O Autor (2018)

² As análises de composição mineralógica são realizadas pelo ensaio de difratometria de Raio-X e os minerais quantificados são definidos pela estratégia dos especialistas após análise das matérias-primas consideradas no processo.

Dentro desse processo produtivo, todas as amostras são coletadas na expedição do cimento e analisadas na planta por funcionários devidamente treinados e responsáveis pelo controle de qualidade da fábrica. Os resultados são registrados em sistemas internos de controle e disponibilizados pela Votorantim Cimentos para a execução desse estudo.

4.2 SELEÇÃO DA AMOSTRA

Atualmente, o processo de amostragem dos cimentos expedidos ocorre, para as duas modalidades de expedição, de acordo com um padrão operacional estabelecido pela Votorantim Cimentos. Para o caso da expedição à granel, modalidade de expedição do cimento estudado, são amostradas manualmente todas as carretas do 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. Essa redução de amostras é possível pela estabilidade das características do cimento armazenado no silo de expedição e necessária devido às complexidades e custos dos ensaios, bem como pela baixa disponibilidade de mão-de-obra na planta.

Os resultados das análises são considerados na criação de cenários para a execução da RNA. Nesse sentido, são avaliadas a redução da dimensionalidade do problema e a redução do número de variáveis. Os cenários considerados para a criação do modelo preditivo são descritos na seção 5.3.

4.3 CENÁRIOS AVALIADOS

Com a obtenção de todas as análises é efetuada uma avaliação para identificar quais delas de fato influenciam na definição do modelo de regressão. Para tal, o presente trabalho utilizou a metodologia de Análise de Componentes Principais (ACP) com dois objetivos. O primeiro deles é a redução da

dimensionalidade das variáveis por meio da substituição dessas por componentes principais e a segunda é a redução de variáveis por meio da seleção das que possuem maior explicação da variabilidade do conjunto de dados. Assim, são considerados os cenários apresentados no QUADRO 15.

QUADRO 15 – VARIÁVEIS CONSIDERADAS PARA A CARACTERIZAÇÃO DO CIMENTO

Cenário	Descrição
A	Consideração de todas as variáveis para a criação do modelo.
B	Redução da dimensionalidade por meio da substituição das variáveis pelas componentes principais seguindo o critério de Kaiser.
C	Seleção das variáveis pela ACP e de acordo com a regra B2 de Jolliffe.
D	Seleção das variáveis pela ACP e de acordo com a regra B4 de Jolliffe.

FONTE: O Autor (2018)

A intenção de avaliar cenários é a de considerar as diferentes possibilidades de convergência dos modelos, visto que não existe uma parametrização ideal para o problema estudado.

4.4 TRATAMENTO INICIAL DOS DADOS

Nesta seção é realizado o tratamento inicial dos dados considerados no estudo com o intuito de garantir a correta avaliação de cada uma das variáveis por meio da normalização dessas dada a existência de diferentes escalas numéricas, bem como a aplicação da ACP para definição dos cenários propostos.

4.4.1 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 forma de cálculo dessa metodologia é descrita na expressão 20.

$$W_i = \frac{X_i - \text{Valor mínimo}}{\text{Valor máximo} - \text{Valor mínimo}} \quad (20)$$

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

4.4.2 Redução da dimensionalidade

A redução de dimensionalidade é empregada com o objetivo de comprimir o volume de dados criando variáveis latentes para a análise dos mesmos. Isso é vantajoso por permitir visualizar menos variáveis e reduzir a complexidade da amostra. Visto que quanto mais complexo é um modelo, ou seja, quanto mais variáveis ele possuir, mais amostra serão necessárias para dar confiabilidade aos resultados (VANDENBERG, 2009).

A redução de dimensionalidade, portanto, permite selecionar um subconjunto de variáveis menor do que o original, possibilitando que um modelo multivariado tenha o mesmo desempenho, ou aproximadamente o mesmo, com menos variáveis (PILLAR, 2004).

Esse processo, realizado a partir da matriz de correlação, consiste em transformar um conjunto de variáveis Z em um novo conjunto de variáveis Y , não-correlacionadas entre si e arranjadas numa ordem decrescente de variância. Feito de tal forma para que poucas, dentre as primeiras componentes principais, contenham a maior variabilidade dos dados originais definindo assim o descarte das demais componentes (JOLLIFFE, 2002).

Como critério de seleção das componentes principais o presente estudo adota o critério de Kaiser, também conhecido como critério da raiz latente. Por esse critério, escolhe-se o número de componentes para se manter no modelo em função do número de autovalores maiores ou iguais a 1. Os autovalores mostram a variância explicada por cada componente e, por consequência, qual a influência de cada um na variância total. Essa regra decorre do fato de que, no mínimo, cada componente deve explicar a variância de uma variável utilizada no modelo (FAVERO, BELFIORE, SILVA e CHAN, 2009).

Para a realização da ACP com esse objetivo foram consideradas 41 variáveis aferidas no cimento expedido e cujos resultados podem ser associados à todas as etapas consideradas como críticas na seção 2.2.5.1. Dessa forma, são avaliadas as composições química e mineralógica do clínquer e das adições no cimento produzido, bem como as características químicas e físicas do produto final. Para a execução da ACP é utilizado o software estatístico R. O resultado dessa análise define o cenário B considerado nesse estudo.

Os autovalores de cada componente principal são exibidos na TABELA 1, onde é possível observar que 12 componentes atendem o critério de Kaiser.

No GRÁFICO 1 é apresentada a variância, ou contribuição, de cada componente principal bem como a variância acumulada explicada pelo conjunto dessas. De acordo com o critério adotado, houve redução da dimensionalidade em 70,7%, sendo mantida 92% da explicação da variância do modelo.

TABELA 1 – AUTOVALORES E SELEÇÃO DOS COMPONENTES PRINCIPAIS

Componente	Autovalor	Componente	Autovalor	Componente	Autovalor
1	8,49	16	0,46	31	0,00
2	5,90	17	0,40	32	0,00
3	4,09	18	0,23	33	0,00
4	3,21	19	0,15	34	0,00
5	2,96	20	0,13	35	0,00
6	2,66	21	0,00	36	0,00
7	2,40	22	0,00	37	0,00
8	2,19	23	0,00	38	0,00
9	1,79	24	0,00	39	0,00
10	1,57	25	0,00	40	0,00
11	1,23	26	0,00	41	0,00
12	1,09	27	0,00	-	-
13	0,80	28	0,00	-	-
14	0,68	29	0,00	-	-
15	0,55	30	0,00	-	-

FONTE: O Autor (2018)

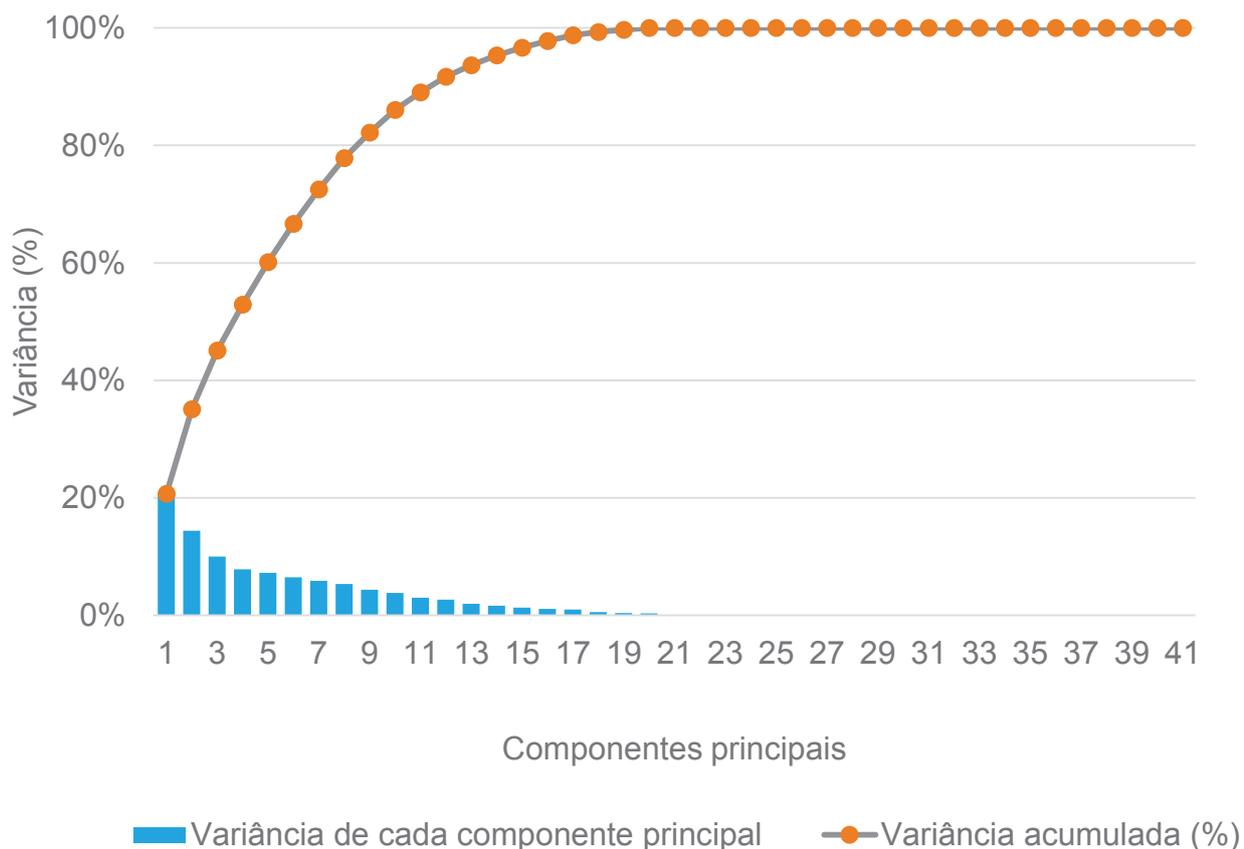


GRÁFICO 1 – VARIÂNCIA INDIVIDUAL E ACUMULADA DOS COMPONENTE PRINCIPAIS
 FONTE: O Autor (2018)

4.4.3 Seleção das variáveis

Aplicando a metodologia B2 para seleção de variáveis (Jolliffe, 2002) obtém-se a seleção das variáveis identificadas no QUADRO 16. No total, 28 variáveis foram desconsideradas do modelo.

QUADRO 16 – VARIÁVEIS SELECIONADAS PELO MÉTODO B2

PF	Água de consistência	Gipsita
R7	C3A ortorrômbico	Portlandita
RI	Periclásio	MgO
Al ₂ O ₃	Langbeinita	Dolomita

FONTE: O Autor (2018)

Executando o método B4, por sua vez, são selecionadas as variáveis destacadas no QUADRO 17. Nos dois métodos, o número de variáveis

selecionadas é o mesmo (12 variáveis) , o que representa uma redução de aproximadamente 71% nas variáveis do modelo estudado.

QUADRO 17 – VARIÁVEIS SELECIONADAS PELO MÉTODO B4

R7	MgO	Fe ₂ O ₃
FP	K ₂ O	Langbeinita
RI	MS	Aftalitita
SiO ₂	C ₃ A cúbico	Calcita

FONTE: O Autor (2018)

O que se nota em ambos o métodos, B2 e B4, é a deleção da variáveis mineralógicas do clínquer, como a belita (C₂S), alita (C₃S) e o C₃A (ortorrômbico e cúbico), bem como o teor de escória, que para os especialistas e responsáveis pela qualidade dos cimentos seus monitoramentos são de fundamental importância para o desenvolvimento das resistências à compressão no cimento produzido.

Tal fato pode ser ocasionado por dois possíveis motivos. Um deles é a colinearidade entre as variáveis, ou seja, um conjunto de variáveis consideradas no modelo já é suficiente para explicar a variável selecionada para deleção. Outro motivo é a grande estabilidade dos dados, ou seja, ao longo do tempo a variação dos resultados teve baixo impacto na variação do modelo permitindo que a mesma fosse desconsiderada visto seu comportamento “constante”.

Contudo, para fins de implementação do modelo na rotina visando a aceitação e facilidade de entendimento, serão mantidas no modelo as variáveis mineralógicas do clínquer (Alita, Belita, C₃A ortorrômbico, C₃A cúbico) bem como o teor de escória adicionado pois sabe-se da criticidade das mesmas. Nessa situação, os métodos B2 e B4 geram os cenários C e D com 16 variáveis para o desenvolvimento do modelo.

4.5 TREINAMENTO E TESTE

Para a obtenção de um bom resultado, devem ser feitas várias partições diferentes no mesmo conjunto de dados em conjuntos de treinamento. O método

considerado nesse trabalho, chamado de *k-fold cross validation*, fornece uma estimativa mais realista do erro a ser cometido pelo método de predição utilizado. (MARTINELI, 1999).

De acordo com Alpaydin (2010), não existe um valor de k ideal para a realização da divisão dos grupos. Nessa situação o presente estudo simula diferentes parametrizações para o número k buscando a melhor combinação entre tempo computacional e qualidade de resultados, considerando o menor valor de k igual a 3 e o maior igual a 10. Os valores de k intermediários entre esses limites são definidos em um intervalo de 1 unidade.

Para a escolha do melhor resultado, ou seja, qual a combinação de folds de treino trouxe o menor erro, avalia-se a distribuição dos erros quadráticos médios das k rodadas e calcula-se a média desconsiderando os valores outliers (identificados em gráficos box-plot). A combinação que apresentar menor diferença em relação ao valor médio encontrado será escolhida para definir as equações matemáticas do modelo.

4.6 TÉCNICA DE REDES NEURAIS ARTIFICIAIS

Para a implementação da técnica de RNAs foi realizada a implementação computacional no VBA® e planilhas auxiliares, a partir de adaptações e complementos ao código de RUTYNA (2015). A alimentação dos dados é feita pela importação das informações em uma planilha eletrônica.

Na utilização da ferramenta devem ser informadas as variáveis independentes (*input*), dependente (*output*), o número de *folders* considerado no método de partição para os grupos de treino, bem como o número de neurônios na camada de entrada e na camada oculta. Os resultados finais são registrados em planilhas auxiliares, consolidados e, no presente trabalho, são analisados nas seções seguintes.

4.6.1 Parametrização do modelo de RNA

Para o presente desenvolvimento, optou-se por uma rede MLP com uma única camada oculta e com correção de erro pelo algoritmo *backpropagation*. 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 da topologia de rede escolhida de 3 até 10 neurônios, e o número de *folds*, para a partição dos dados de treino e de teste, conforme descrito na seção 5.5.1.

O critério de parada considerado para a execução da RNA foi o erro quadrático médio menor ou igual a 0,01. Além disso, limita-se a execução da RNA em 10000 iterações para cada treinamento.

4.7 RESULTADOS OBTIDOS E DISCUSSÃO

Nessa seção são consolidados, para cada cenário, os resultados da aplicação da metodologia proposta nesse estudo. É avaliado o resultado numérico e classificatório das redes neurais artificiais. O resultado classificatório é avaliado a partir da matriz de confusão e do cálculo da sua acurácia.

Todos os cenários avaliados contam com 21 resultados para a realização da etapa de treino da rede e a validação é realizada com todos os 21 resultados considerados na etapa de treino adicionados de 6 resultados não considerados anteriormente.

Por fim, os cenários A, B, C e D, são comparados quanto aos seus resultados numéricos e seus resultados classificatórios. A configuração de

melhor desempenho em relação ao RMSE e ao coeficiente de correlação é selecionada.

4.7.1 Cenário A

O cenário A considera todas as 41 variáveis estudadas para a execução do modelo de predição por meio da RNA. Os resultados gerados para esse cenário são consolidados na TABELA 2 e detalhados no APÊNDICE 1.

De uma forma geral identifica-se que, para determinada quantidade de neurônios na camada oculta, o aumento do número k de folds reduz o RMSE da etapa de treino sem, no entanto, demonstrar ganhos na etapa de validação. Além disso, o aumento do número de neurônios na camada oculta não demonstrou melhoras significativas em relação ao RMSE, exibindo a situação de que para esse cenário um maior esforço computacional não confere, necessariamente, melhorias de acurácia para a rede.

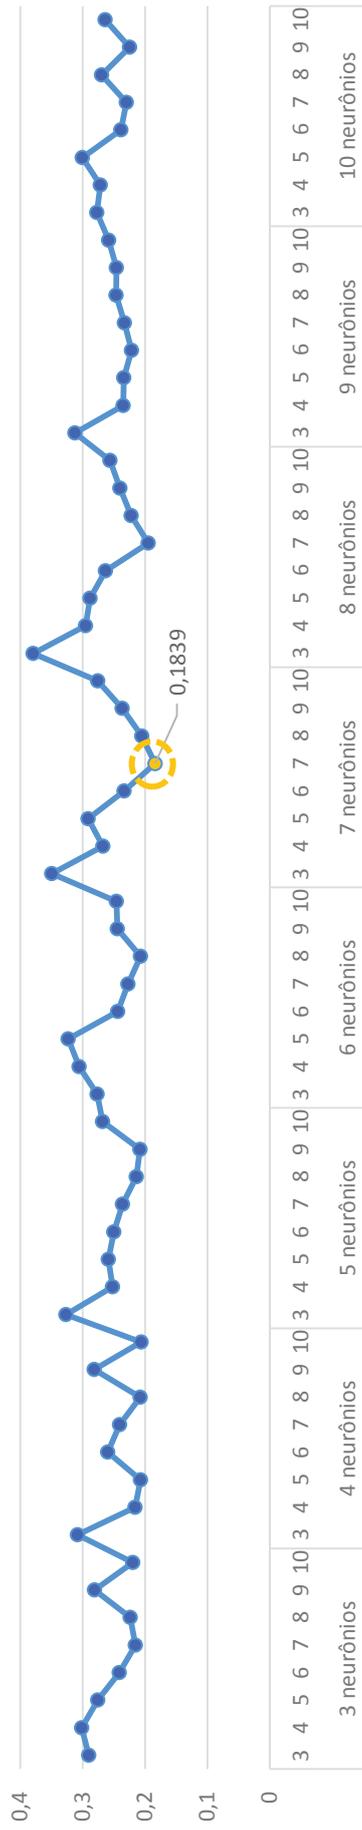
A partir dos dados apresentados (TABELA 2), identifica-se que para a etapa de treino 7 neurônios na camada oculta e a divisão dos dados em 7 folds apresenta o menor erro. Contudo, avaliando o RMSE da etapa de validação, percebe-se a que configuração com melhor capacidade de generalização é a de 8 neurônios na camada oculta com 7 folds, sendo essa a parametrização destaque do cenário. Graficamente, tem-se as informações nos GRÁFICOS 2 e 3.

TABELA 2 – RESULTADO DA RNA PARA AS PARAMETRIZAÇÕES DO CENÁRIO A

Camada oculta	K-folds	RMSE treino	RMSE validação	Camada oculta	K-folds	MSE treino	RMSE validação
3 neurônios	3	0,2905	2,1364	7 neurônios	3	0,3494	1,8836
	4	0,3017	2,1964		4	0,2677	2,893
	5	0,2757	1,8225		5	0,2913	1,753
	6	0,2414	1,6164		6	0,2336	1,8537
	7	0,2154	1,8318		7	0,1839	1,7118
	8	0,224	1,818		8	0,205	1,6252
	9	0,2812	3,0651		9	0,2366	1,6692
	10	0,2196	1,7187		10	0,2759	1,6971
4 neurônios	3	0,3082	2,2306	8 neurônios	3	0,3795	1,9271
	4	0,2161	1,8588		4	0,2954	1,875
	5	0,2074	1,5673		5	0,2882	1,5416
	6	0,2597	1,4698		6	0,2634	1,7606
	7	0,241	1,7042		7	0,1947	1,4673
	8	0,2076	1,5607		8	0,2221	1,8645
	9	0,2817	1,951		9	0,2402	1,6244
	10	0,2064	1,9345		10	0,2561	1,7613
5 neurônios	3	0,3271	1,6856	9 neurônios	3	0,3126	1,9262
	4	0,2521	1,8064		4	0,2353	1,9761
	5	0,2588	1,7165		5	0,2343	1,7783
	6	0,25	1,5703		6	0,2217	1,8354
	7	0,2362	1,8576		7	0,2331	1,5468
	8	0,2141	1,6967		8	0,2466	2,03
	9	0,2081	1,7402		9	0,2458	1,5606
	10	0,2681	1,6298		10	0,2581	2,0125
6 neurônios	3	0,2767	2,22	10 neurônios	3	0,2776	1,8718
	4	0,3056	1,9955		4	0,2716	1,9715
	5	0,3232	1,7966		5	0,3004	1,5789
	6	0,2438	1,788		6	0,239	1,8703
	7	0,2272	1,8216		7	0,2298	1,8074
	8	0,2071	1,8832		8	0,2698	1,8568
	9	0,2446	1,9053		9	0,225	1,5787
	10	0,2462	1,7146		10	0,2639	1,6034

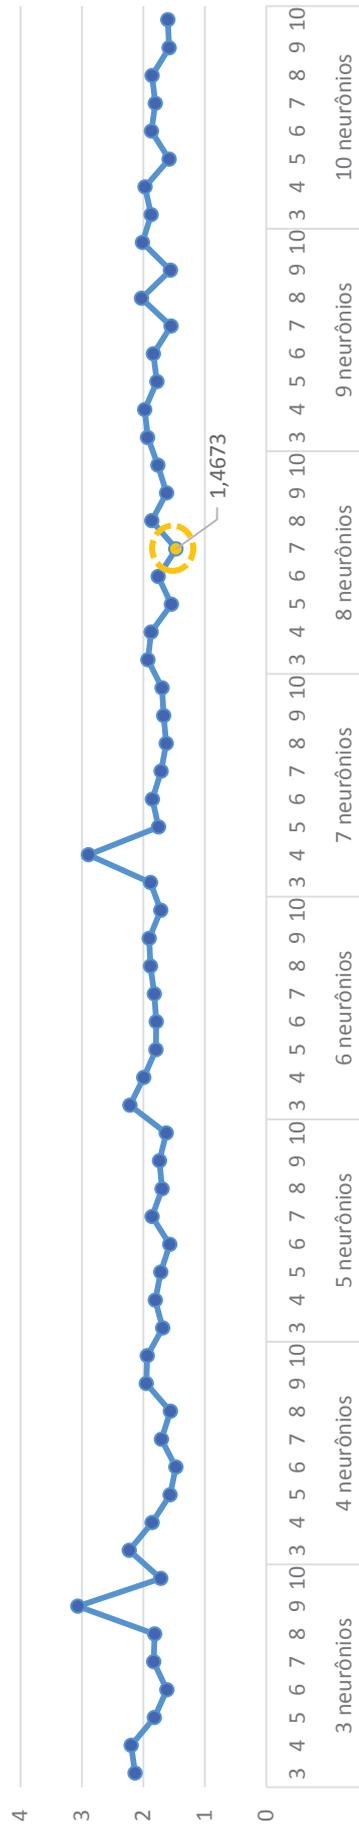
FONTE: O Autor (2018)

GRÁFICO 2 – RMSE DA ETAPA DE TREINO PARA AS PARAMETRIZAÇÕES DO CENÁRIO A



FONTE: O Autor (2018)

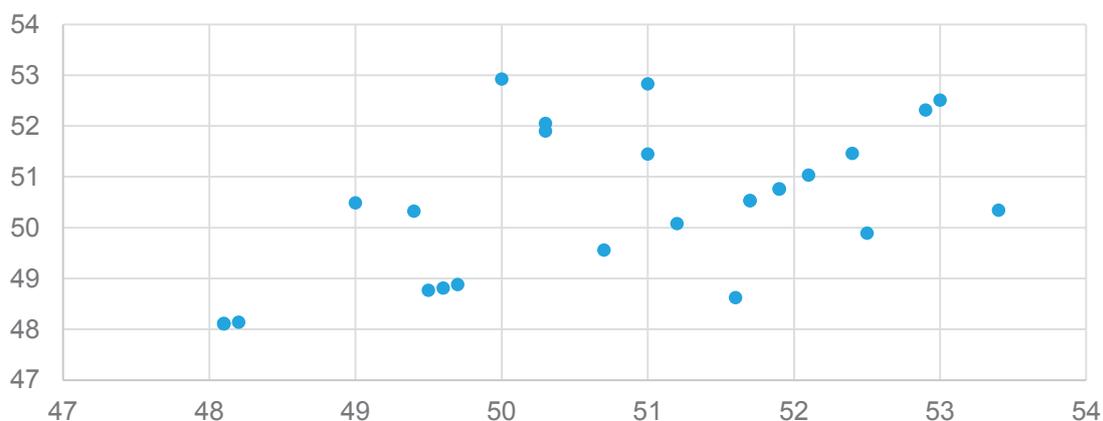
GRÁFICO 3 – RMSE DA ETAPA DE VALIDAÇÃO PARA AS PARAMETRIZAÇÕES DO CENÁRIO A



FONTE: O Autor (2018)

Comparando os resultados obtidos na etapa de validação com os resultados observados no ensaio de resistência à compressão, verifica-se que existe uma correlação moderada de 0,58, ilustrada no GRÁFICO 4. A análise dos resíduos apresentou distribuição Gaussiana, verificada pelo teste de Kolmogorov-Smirnov (p -valor igual a 0,034) com média aproximadamente zero (0,4) e desvio-padrão de cerca de 1,4 MPa.

GRÁFICO 4 – CORRELAÇÃO DAS RESISTÊNCIAS PREDITAS E OBSERVADAS



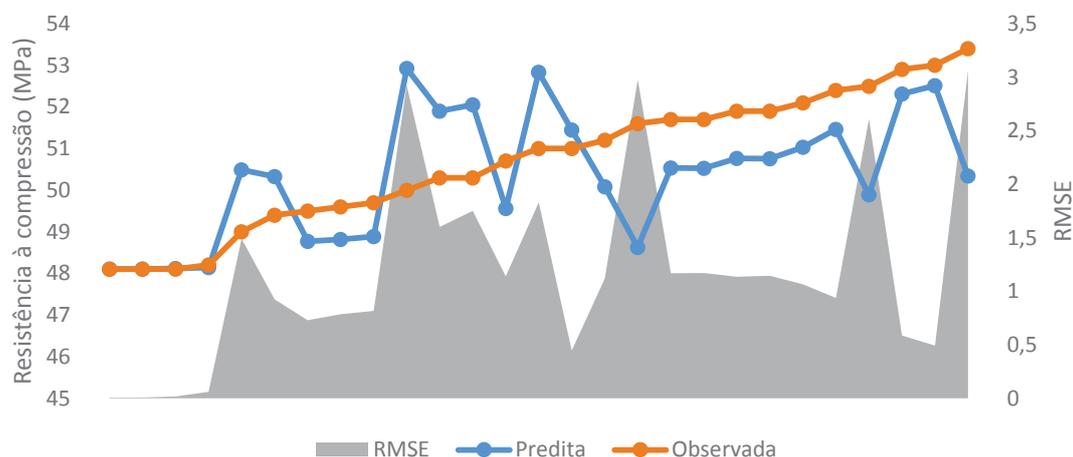
FONTE: O Autor (2018)

Se ordenarmos os resultados de resistência à compressão observados do menor para o maior valor, associarmos os valores previstos de acordo com o resultado do modelo gerado para o cenário A e calcularmos o valor absoluto da diferença dos valores, obtem-se o GRÁFICO 5.

Nele é possível observar que a predição apresenta comportamento conservador visto que a maior parte dos valores, dado o conjunto de dados, é predito com um valor menor comparados com os valores observados, ou seja, a resistência à compressão gerada pelo modelo é “menor” que a resistência real. Além disso o erro do modelo não é influenciado pelo aumento das resistências uma vez que não se identifica uma tendência de comportamento para esse tipo de resultado.

Contudo, para os valores de resistência mais elevados percebe-se um comportamento mais uniforme em relação aos valores preditos, podendo este ser um comportamento de *over-fitting* da rede neural.

GRÁFICO 5 – ERRO ABSOLUTO ENTRE AS RESISTÊNCIAS PREDITAS E OBSERVADAS



FONTE: O Autor (2018)

Paralelo a isso é realizada a classificação dos resultados preditos e dos resultados aferidos em dois grupos definidos como “conformes” e “não conformes” tendo como valores de referência os limites de qualidade estipulados para o cimento estudado pela Votorantim Cimentos (limite inferior de qualidade igual a 49 MPa e limite superior de qualidade igual a 56,2 MPa para a característica de resistência à compressão aos 28 dias). Os valores classificados como “conformes” atendem os limites de qualidade e os “não conformes” alcançam valores abaixo ou acima dos limites.

A matriz de confusão para a parametrização destaque do cenário A é apresentada na TABELA 3. De acordo com o modelo de classificação, é possível prever com 85,2% de acerto a classificação da resistência à compressão aos 28 dias.

TABELA 3 – MATRIZ DE CONFUSÃO PARA A PARAMETRIZAÇÃO DO CENÁRIO A

	Conforme	Não conforme	% Correta
Conforme	19	4	82,6%
Não conforme	0	4	100%

FONTE: O Autor (2018)

Além disso, percebe-se que o modelo classificatório do cenário A também apresenta características conservadoras na medida que para todos os resultados aferidos e classificados como não conformes, o modelo classificou os resultados preditos correspondentes da mesma forma, ou seja, foi sensível de tal maneira que identificou todas as irregularidades. Contudo, gerou alarmes falsos, ou falsos positivos, classificando como não conformes alguns valores que atendem aos limites estipulados.

A geração de alarmes falsos, no entanto, é de baixa criticidade quando comparada com a situação de identificação de falsos negativos.

4.7.2 Cenário B

O cenário B considera a redução da dimensionalidade por meio da aplicação da ACP e, como identificado na seção 5.4.3, são consideradas 12 componentes principais para a execução do modelo. Os resultados gerados são consolidados na TABELA 4 e detalhados no APÊNDICE 2.

É possível perceber que o aumento do número de neurônios na camada oculta eleva, sutilmente, o valor do RMSE para a etapa de treino. De forma contrária, identifica-se que o aumento do número k de folds reduz o RMSE, demonstrando que a divisão dos dados em um maior número de grupos de treino auxilia, para esse cenário, na convergência da rede.

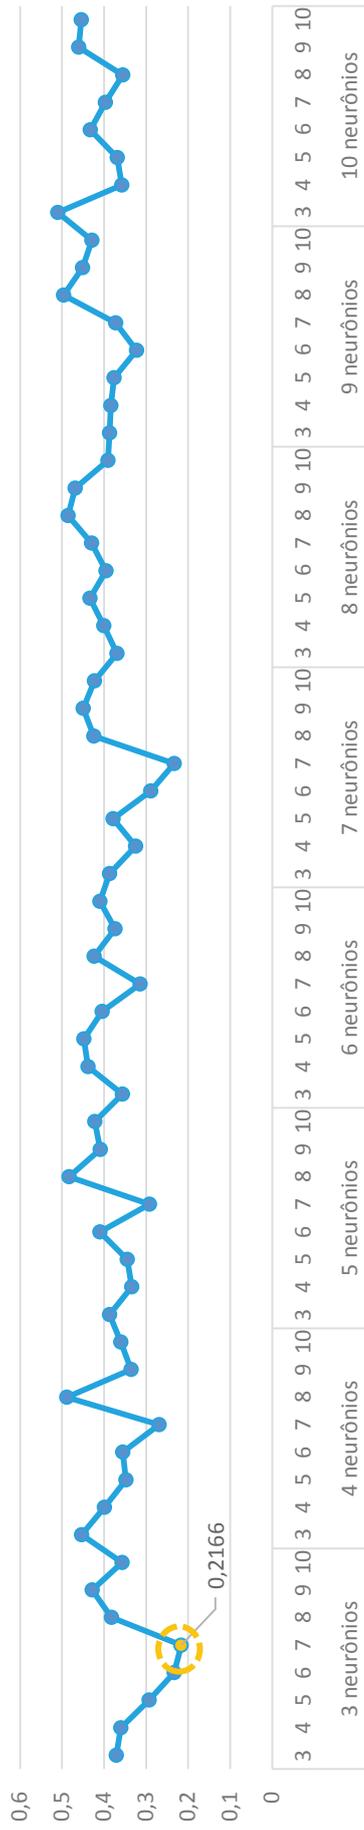
A partir dos dados apresentados (TABELA 4), identifica-se que para a etapa de treino 3 neurônios na camada oculta e a divisão dos dados em 7 folds apresenta o menor erro. Contudo, avaliando o RMSE da etapa de validação, percebe-se a que configuração com melhor capacidade de generalização é a de 10 neurônios na camada oculta com 10 folds. Graficamente, tem-se as informações nos GRÁFICOS 6 E 7.

TABELA 4 – RESULTADO DA RNA PARA AS PARAMETRIZAÇÕES DO CENÁRIO B

Camada oculta	K-folds	RMSE treino	RMSE validação	Camada oculta	K-folds	RMSE treino	RMSE validação
3 nós	3	0,3711	1,6832	7 nós	3	0,3869	1,6814
	4	0,3601	1,7487		4	0,3247	1,8199
	5	0,2925	1,2653		5	0,3784	1,5070
	6	0,2332	1,3377		6	0,2890	1,4558
	7	0,2166	1,3315		7	0,2335	1,2142
	8	0,3826	1,2456		8	0,4246	1,2614
	9	0,4285	1,8270		9	0,4495	1,2503
	10	0,3573	1,2991		10	0,4227	1,2635
4 nós	3	0,4533	2,0424	8 nós	3	0,3695	1,9601
	4	0,3990	1,5887		4	0,4005	1,9218
	5	0,3480	1,1884		5	0,4337	1,5026
	6	0,3555	1,5350		6	0,3952	1,4714
	7	0,2688	1,2433		7	0,4300	1,5307
	8	0,4884	1,2889		8	0,4853	1,3069
	9	0,3354	1,2823		9	0,4692	1,2029
	10	0,3603	1,4471		10	0,3909	1,4631
5 nós	3	0,3868	1,6880	9 nós	3	0,3869	1,9257
	4	0,3338	1,6801		4	0,3840	1,6427
	5	0,3452	1,4178		5	0,3759	1,4707
	6	0,4101	1,3339		6	0,3230	1,4319
	7	0,2920	1,3636		7	0,3721	1,4195
	8	0,4833	1,2951		8	0,4966	1,2156
	9	0,4088	1,1477		9	0,4509	1,3719
	10	0,4225	1,4176		10	0,4293	2,3289
6 nós	3	0,3560	1,6183	10 nós	3	0,5103	1,9651
	4	0,4383	1,6440		4	0,3577	1,3866
	5	0,4481	1,8577		5	0,3689	1,4705
	6	0,4043	1,5242		6	0,4329	1,3721
	7	0,3142	1,2902		7	0,3967	1,5138
	8	0,4236	1,1338		8	0,3554	1,2638
	9	0,3740	1,1380		9	0,4606	1,4716
	10	0,4101	1,1604		10	0,4545	1,0958

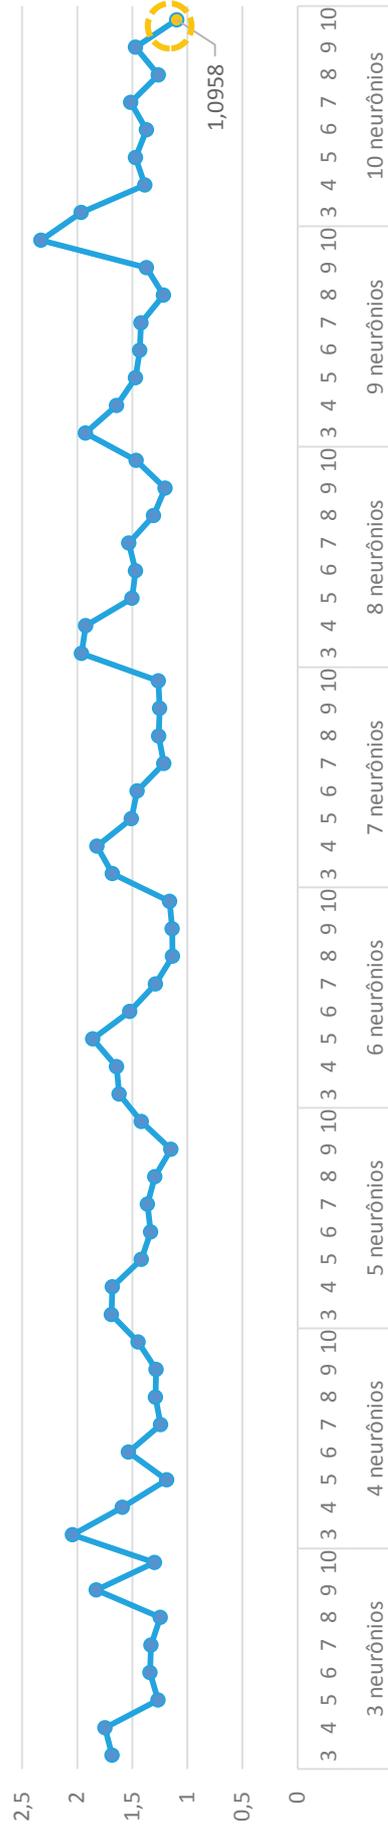
FONTE: O Autor (2018)

GRÁFICO 6 – RMSE DA ETAPA DE TREINO PARA AS PARAMETRIZAÇÕES DO CENÁRIO B



FONTE: O Autor (2018)

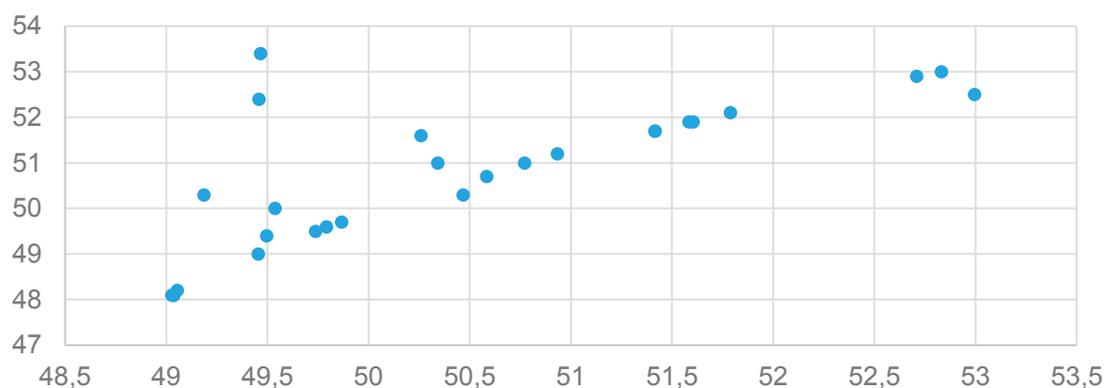
GRÁFICO 7 – RMSE DA ETAPA DE VALIDAÇÃO PARA AS PARAMETRIZAÇÕES DO CENÁRIO B



FONTE: O Autor (2018)

Comparando os resultados obtidos na etapa de validação com os resultados reais aferidos pelo ensaio de resistência à compressão, verifica-se que existe uma correlação forte de 0,74, ilustrada no GRÁFICO 8. A análise dos resíduos apresentou distribuição Gaussiana, verificada pelo teste de Kolmogorov-Smirnov (p-valor menor que 0,01), com média aproximadamente zero (0,3) e desvio-padrão de cerca de 1,1 MPa.

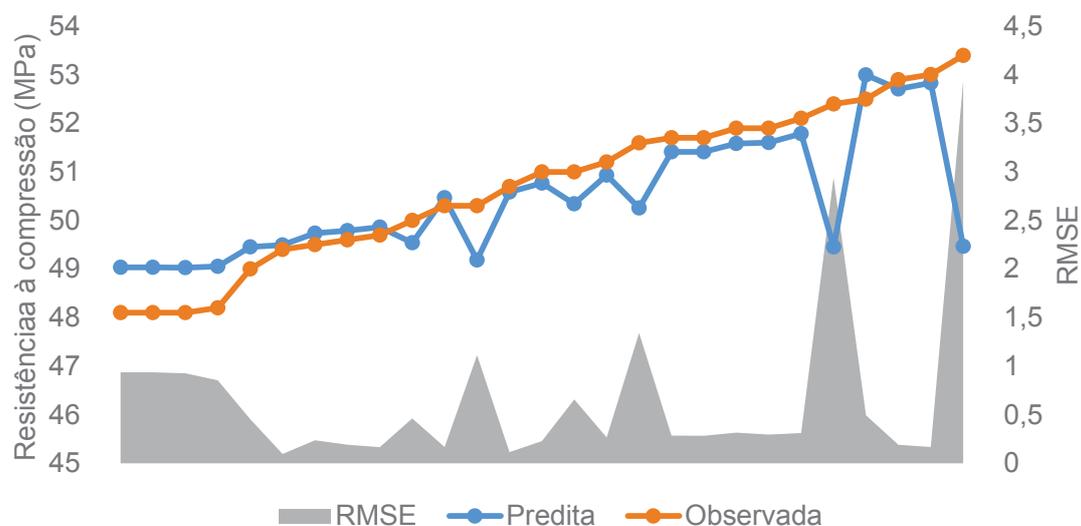
GRÁFICO 8 – CORRELAÇÃO DAS RESISTÊNCIAS PREDITAS E OBSERVADAS



FONTE: O Autor (2018)

Ordenando os resultados de resistência à compressão observados e os valores preditos correspondentes de acordo com o resultado do modelo gerado para o cenário B, calcula-se o valor absoluto da diferença de valores e obtém-se o GRÁFICO 9. Nele é possível observar que a predição apresenta comportamento conservador e com desvios relativamente pequenos em relação aos valores observados, apresentando maiores erros em alguns casos de maiores resistências. Além disso também é possível observar que para as menores resistências a predição se mostra praticamente linear, podendo ser um sinal de *over-fitting* da rede.

GRÁFICO 9 – ERRO ABSOLUTO ENTRE AS RESISTÊNCIAS PREDITAS E OBSERVADAS



FONTE: O Autor (2018)

Executando a classificação dos resultados gerados para a parametrização destaque do cenário B, obtem-se a matriz de confusão apresentada na TABELA 5. De acordo com o modelo de classificação, é possível prever com 85% de acerto a classificação da resistência à compressão aos 28 dias.

TABELA 5 – MATRIZ DE CONFUSÃO PARA A PARAMETRIZAÇÃO DO CENÁRIO B

	Conforme	Não conforme	% Correta
Conforme	23	0	100%
Não conforme	4	0	0%

FONTE: O Autor (2018)

Percebe-se que o modelo classificatório do cenário B possui uma boa acurácia mas apresentou a situação de classificação de falsos negativos, o que é crítico pois o modelo deixa de identificar situações não conformes o que, futuramente, permite a entrega de cimentos irregulares aos clientes finais.

A classificação incorreta ocorre para as menores resistências existentes entre as amostras consideradas e que, pelo GRÁFICO 9, são preditas pelo modelo com valores superiores ao aferido, resultando na consideração dos resultados como “conformes” em relação aos limites considerados.

4.7.3 Cenário C

O cenário C considera a seleção de variáveis por meio da aplicação da ACP de acordo com a metodologia B2 proposta por Jolliffe (2002). Como identificado na seção 5.4.4, são consideradas 16 variáveis para a execução do modelo. Os resultados gerados são consolidados na TABELA 6 e detalhados no APÊNDICE 3.

De uma forma geral, identifica-se que o aumento do número de neurônios na camada oculta não altera, na média, o valor do RMSE. Da mesma forma, observa-se que o aumento do número k de *folders* eleva sutilmente o RMSE da etapa de treino.

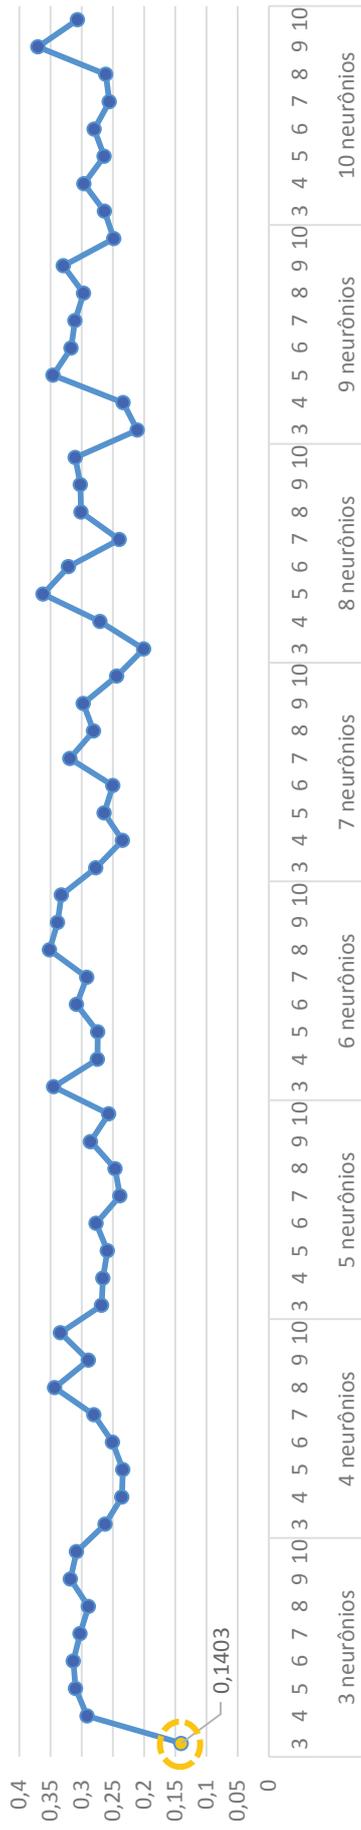
A partir dos dados apresentados (TABELA 6), identifica-se que para a etapa de treino 3 neurônios na camada oculta e a divisão dos dados em 3 *folders* apresenta o menor erro. Contudo, avaliando o RMSE da etapa de validação, percebe-se a que configuração com melhor capacidade de generalização é a de 9 neurônios na camada oculta, com 4 *folders*. Graficamente, tem-se as informações nos GRÁFICOS 10 e 11.

TABELA 6 – RESULTADO DA RNA PARA AS PARAMETRIZAÇÕES DO CENÁRIO C

Camada oculta	K-Folds	RMSE treino	RMSE validação	Camada oculta	K-Folds	RMSE treino	RMSE validação
3 nós	3	0,1403	1,4425	7 nós	3	0,2773	1,5007
	4	0,2913	1,5043		4	0,2344	1,9108
	5	0,3101	1,3132		5	0,2639	1,2866
	6	0,3134	1,5319		6	0,2499	1,1885
	7	0,3025	1,2821		7	0,3191	1,1772
	8	0,2894	1,4396		8	0,2809	1,4483
	9	0,3179	1,2631		9	0,2975	1,3922
	10	0,3085	1,2164		10	0,2437	3,0521
4 nós	3	0,2627	1,6454	8 nós	3	0,2005	1,5626
	4	0,2356	1,3437		4	0,2708	1,5529
	5	0,2340	1,4048		5	0,3619	1,4848
	6	0,2507	1,3564		6	0,3211	1,3920
	7	0,2806	1,2170		7	0,2397	1,2439
	8	0,3433	1,4808		8	0,3012	1,5978
	9	0,2895	1,5916		9	0,3022	1,3572
	10	0,3339	1,4551		10	0,3105	1,0880
5 nós	3	0,2681	1,4474	9 nós	3	0,2108	1,7764
	4	0,2662	1,7404		4	0,2336	1,0741
	5	0,2587	2,5652		5	0,3460	1,3510
	6	0,2770	1,4452		6	0,3172	1,6091
	7	0,2387	1,2677		7	0,3107	1,1458
	8	0,2466	1,5960		8	0,2968	1,1620
	9	0,2859	1,3249		9	0,3294	1,5094
	10	0,2568	1,4630		10	0,2484	1,3883
6 nós	3	0,3449	1,4716	10 nós	3	0,2633	1,7604
	4	0,2748	1,1294		4	0,2965	1,6280
	5	0,2744	1,3001		5	0,2642	1,4670
	6	0,3086	1,2595		6	0,2802	1,4343
	7	0,2918	1,3470		7	0,2560	1,3353
	8	0,3519	1,4101		8	0,2613	1,4462
	9	0,3390	1,2209		9	0,3704	1,2897
	10	0,3326	1,3367		10	0,3067	1,3540

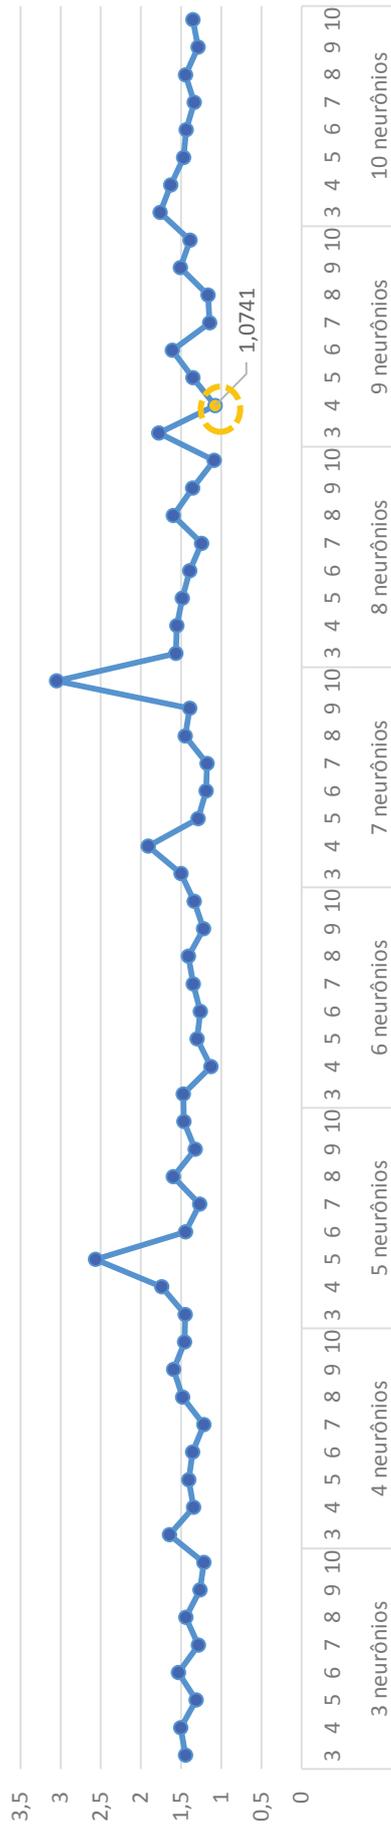
FONTE: O Autor (2018)

GRÁFICO 10 – RMSE DA ETAPA DE TREINO PARA AS PARAMETRIZAÇÕES DO CENÁRIO C



FONTE: O Autor (2018)

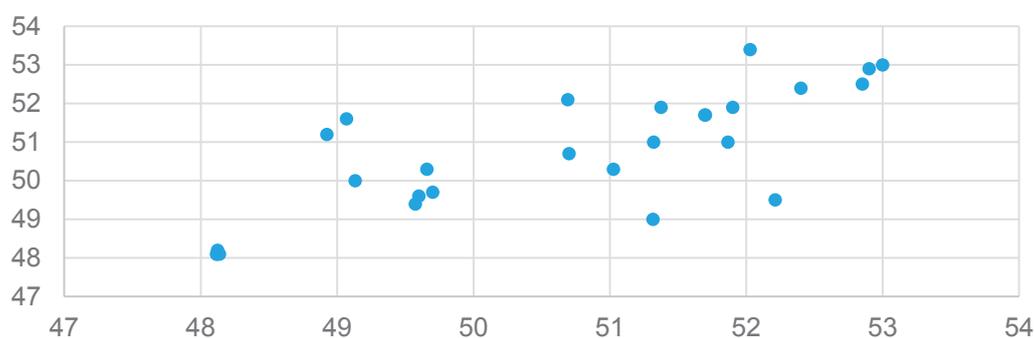
GRÁFICO 11 – RMSE DA ETAPA DE VALIDAÇÃO PARA AS PARAMETRIZAÇÕES DO CENÁRIO C



FONTE: O Autor (2018)

Comparando os resultados obtidos na etapa de validação com os resultados observados no ensaio de resistência à compressão, verifica-se que existe uma correlação forte de 0,77, ilustrada no GRÁFICO 12. A análise dos resíduos apresentou distribuição Gaussiana, verificada pelo teste de Kolmogorov-Smirnov (p-valor menor que 0,01), com média aproximadamente zero (0,1) e desvio-padrão de cerca de 1,1 MPa.

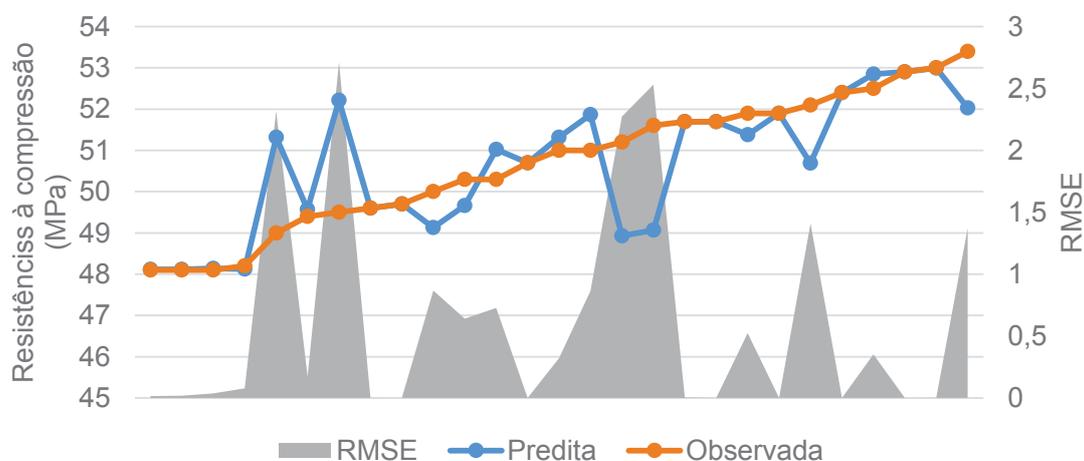
GRÁFICO 12 – CORRELAÇÃO DAS RESISTÊNCIAS PREDITAS E OBSERVADAS



FONTE: O Autor (2018)

Ordenando os resultados de resistência à compressão aferidos e os valores previstos correspondentes do menor para o maior valor, pode-se calcular o valor absoluto da diferença dos valores e obtém-se o GRÁFICO 13.

GRÁFICO 13 – ERRO ABSOLUTO ENTRE AS RESISTÊNCIAS PREDITAS E OBSERVADAS



FONTE: O Autor (2018)

É possível perceber que o erro do modelo é sutilmente influenciado pelo aumento das resistências uma vez que se identifica uma tendência de diminuição do erro com o crescimento dessa.

Executando a classificação dos resultados gerados para a parametrização destaque do cenário C, obtem-se a matriz de confusão apresentada na TABELA 7. De acordo com o modelo de classificação, é possível prever com 96,3% de acerto a classificação da resistência à compressão aos 28 dias.

TABELA 7 – MATRIZ DE CONFUSÃO PARA A PARAMETRIZAÇÃO DO CENÁRIO C

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

FONTE: O Autor (2018)

A acurácia do modelo classificatório é alta e apresenta comportamento conservador pois seu erro de classificação está relacionado à falsos positivos, ou seja, situação de alarme falso e de baixa criticidade.

4.7.4 Cenário D

O cenário D considera a seleção de variáveis por meio da aplicação da ACP de acordo com a metodologia B4 proposta por Jolliffe (2002). Os resultados gerados são consolidados na TABELA 8 e detalhados no APÊNDICE 4.

Avaliando os resultados percebe-se que o aumento do número de neurônios na camada oculta reduz de forma branda o valor do RMSE na etapa de treino. Além disso o aumento do número de folds, de uma forma geral, aumentou de forma não expressiva o valor do RMSE. A mesma análise pode ser feita para a etapa de validação.

A partir dos dados apresentados (TABELA 8), identifica-se que para a etapa de treino 3 neurônios na camada oculta e a divisão dos dados em 4 *folds* apresenta o menor erro. Contudo, avaliando o RMSE da etapa de validação,

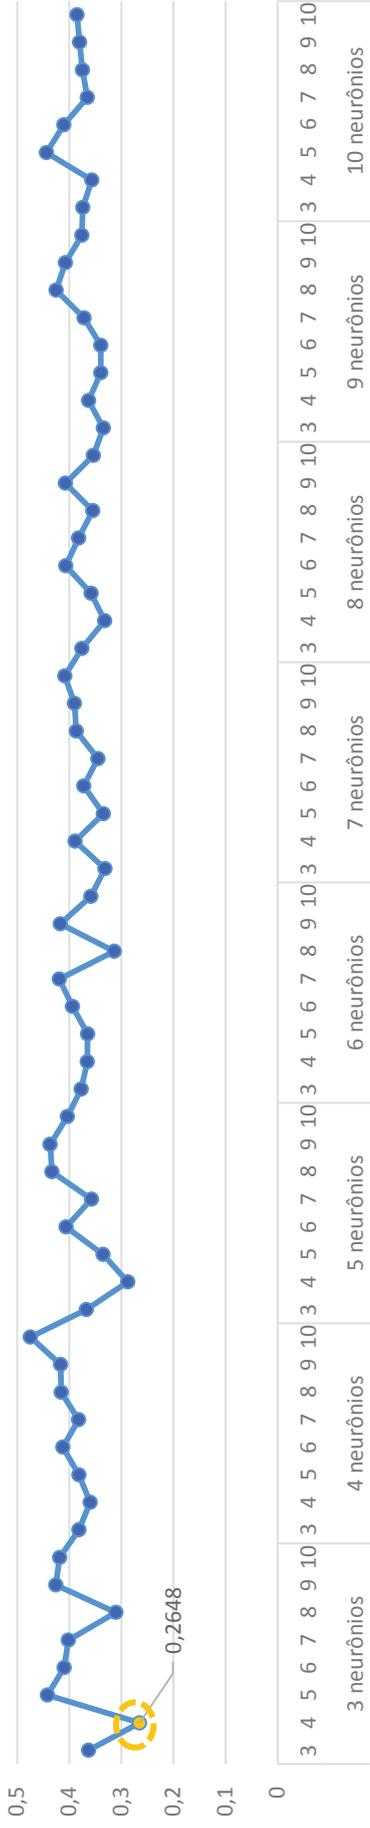
percebe-se a que configuração com melhor desempenho é a de 4 neurônios na camada oculta com 3 *folds*. Graficamente, tem-se as informações nos GRÁFICOS 14 e 15.

TABELA 8 – RESULTADO DA RNA PARA AS PARAMETRIZAÇÕES DO CENÁRIO D

Camada oculta	K-Folds	RMSE treino	RMSE validação	Camada oculta	K-Folds	RMSE treino	RMSE validação
3 nós	3	0,3627	2,6181	7 nós	3	0,3315	2,0837
	4	0,2648	2,4431		4	0,3885	2,7526
	5	0,4416	2,4800		5	0,3345	2,5846
	6	0,4094	2,3272		6	0,3722	2,1567
	7	0,4018	2,2328		7	0,3448	2,1859
	8	0,3103	2,3476		8	0,3861	2,4340
	9	0,4254	2,5188		9	0,3899	2,2991
	10	0,4185	1,9358		10	0,4083	2,4233
4 nós	3	0,3814	1,8424	8 nós	3	0,3759	2,1798
	4	0,3594	2,6629		4	0,3322	2,4927
	5	0,3815	2,3698		5	0,3576	2,2991
	6	0,4120	2,6752		6	0,4067	2,2474
	7	0,3821	2,1822		7	0,3818	2,2187
	8	0,4152	2,3096		8	0,3548	2,4056
	9	0,4164	2,3500		9	0,4071	2,4144
	10	0,4747	2,1146		10	0,3537	2,2570
5 nós	3	0,3673	2,1728	9 nós	3	0,3347	2,5116
	4	0,2873	2,5854		4	0,3629	1,9812
	5	0,3353	3,0434		5	0,3393	2,6491
	6	0,4060	2,1644		6	0,3391	2,6370
	7	0,3570	2,2618		7	0,3713	2,3217
	8	0,4329	2,3513		8	0,4252	2,4884
	9	0,4365	2,3873		9	0,4070	2,5897
	10	0,4038	2,3214		10	0,3755	2,4271
6 nós	3	0,3771	1,9876	10 nós	3	0,3740	2,1620
	4	0,3655	2,1408		4	0,3564	2,5608
	5	0,3647	2,3609		5	0,4439	2,2483
	6	0,3939	2,2118		6	0,4103	2,2831
	7	0,4187	2,2225		7	0,3654	2,1852
	8	0,3133	2,5056		8	0,3744	2,3012
	9	0,4170	2,4046		9	0,3801	2,3553
	10	0,3586	2,3463		10	0,3851	2,3839

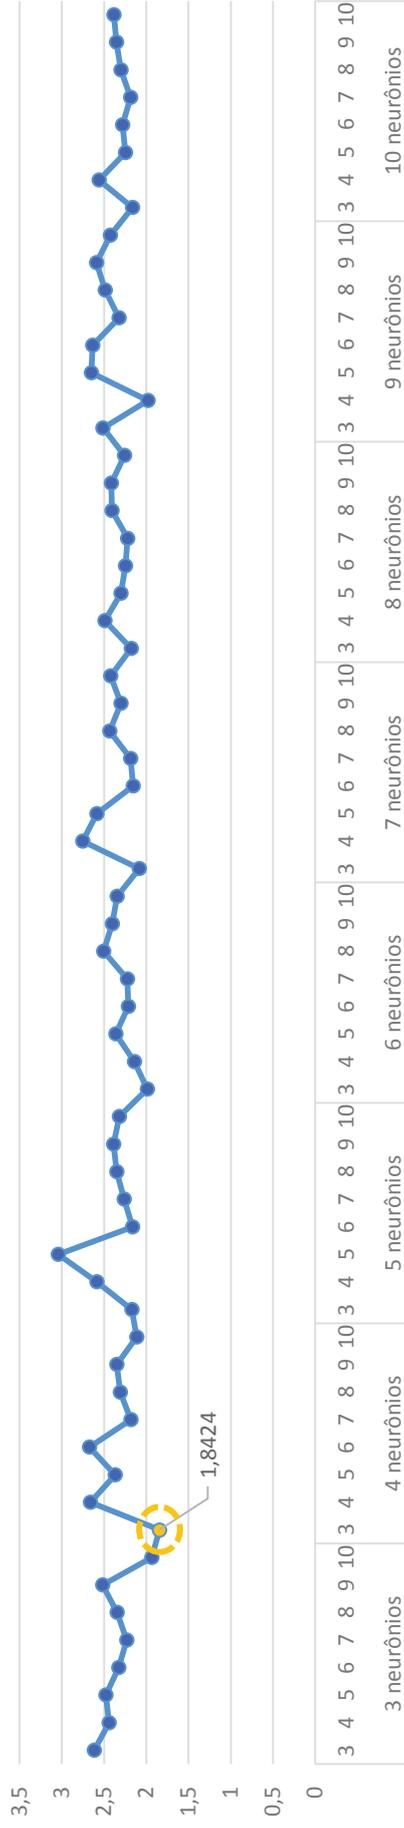
FONTE: O Autor (2018)

GRÁFICO 14 – RMSE DA ETAPA DE TREINO PARA AS PARAMETRIZAÇÕES DO CENÁRIO D



FONTE: O Autor (2018)

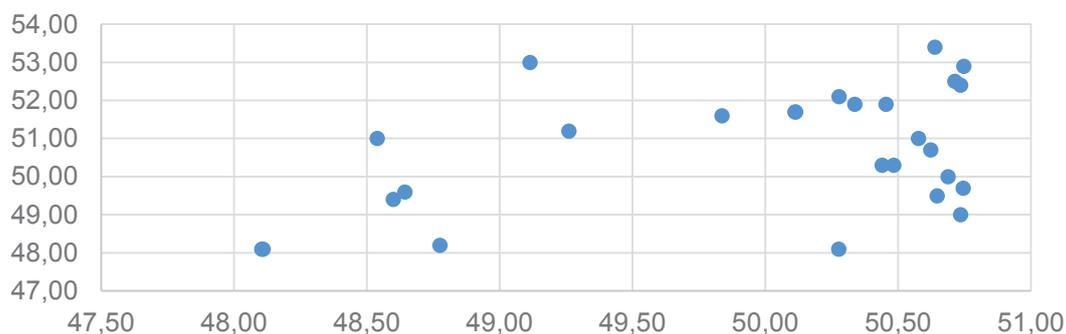
GRÁFICO 15 – RMSE DA ETAPA DE VALIDAÇÃO PARA AS PARAMETRIZAÇÕES DO CENÁRIO D



FONTE: O Autor (2018)

Ao comparar os resultados obtidos na etapa de validação com os resultados reais aferidos pelo ensaio de resistência à compressão, verifica-se que existe uma correlação fraca de 0,43, ilustrada no GRÁFICO 16. A análise dos resíduos apresentou distribuição Gaussiana, verificada pelo teste de Kolmogorov-Smirnov (p-valor igual a 0,083), com média aproximadamente 0,8 e desvio padrão de 1,7.

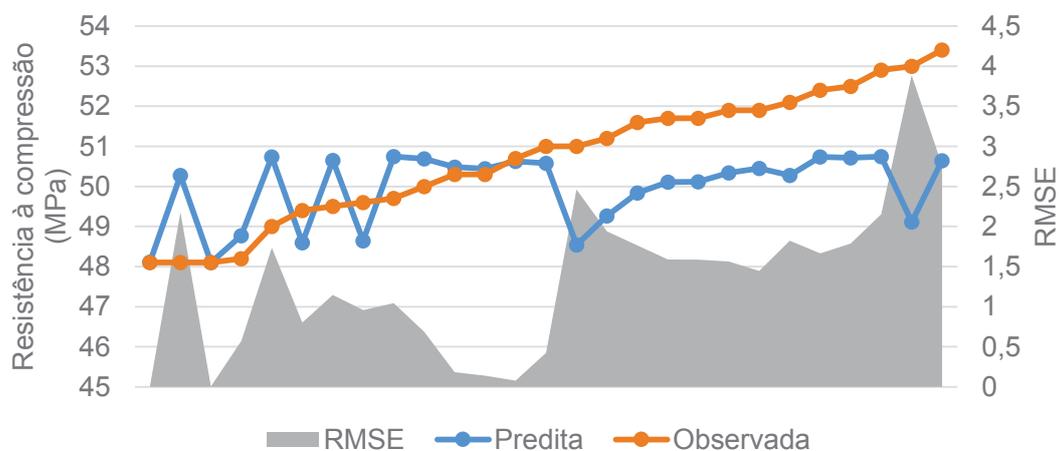
GRÁFICO 16 – CORRELAÇÃO DAS RESISTÊNCIAS PREDITAS E OBSERVADAS



FONTE: O Autor (2018)

Ao ordenar os resultados de resistência à compressão aferidos do menor para o maior valor, associar os valores previstos correspondentes e calcular o valor absoluto da diferença destes, obtém-se o GRÁFICO 17.

GRÁFICO 17 – ERRO ABSOLUTO ENTRE AS RESISTÊNCIAS PREDITAS E OBSERVADAS



FONTE: O Autor (2018)

É possível perceber que o erro do modelo é influenciado pelo aumento das resistências uma vez que se identifica uma tendência de comportamento. Além disso, para os maiores valores de resistência o modelo apresenta um comportamento de previsão praticamente “uniforme”, podendo indicar a situação de *over-fitting* na etapa de treino.

Executando a classificação dos resultados gerados, obtém-se a matriz de confusão apresentada na TABELA 9. De acordo com o modelo de classificação, é possível prever com 85,2% de acerto a classificação da resistência á compressão aos 28 dias.

TABELA 9 – MATRIZ DE CONFUSÃO PARA A PARAMETRIZAÇÃO DO CENÁRIO D

	Conforme	Não conforme	%Correta
Conforme	20	3	87,0%
Não conforme	1	3	75,0%

FONTE: O Autor (2018)

A acurácia do modelo classificatório do cenário D é expressiva, porém apresenta a situação de não identificação de resultados não conformes (falsos negativos). Essa classificação, definida como crítica ocorreu para apenas um resultado que, pelo que se observa no GRÁFICO 17, pode ser um valor predito outlier³.

4.8 COMPARAÇÃO ENTRE OS CENÁRIOS

Os resultados obtidos nos quatro cenários de predição permitem a seleção da melhor parametrização e para fins de comparação apenas observa-se o potencial de uso da metodologia de RNA com objetivo classificatório sem considerar, para este estudo, a mesma como método substitutivo, ou seja, sem a intenção de avaliar a substituição da RNA para a predição numérica, mas sim como apoio para a tomada de decisão.

³ *Outliers* são observações que apresentam um grande afastamento das demais em uma mesma série de dados (Montgomery e Mastrangelo, 1991)

A etapa de treinamento das redes neurais artificiais, responsável por “ensinar” a forma de interpretação dos dados de entrada na rede, se mostrou com comportamentos semelhantes para os cenários estudados. Já na etapa de validação, responsável por atestar a generalização do método, a diferença de resultados e de performance entre os cenários é mais evidente, destacando o Cenário C com os menores erros e com o maior coeficiente de correlação.

Considerando o método de classificação da resistência, responsável por classificar em “conforme” e “não conforme” as resistências preditas e observadas em cada um dos cenários, percebem-se resultados satisfatórios para todos os modelos, porém com destaque para o cenário C.

A comparação é demonstrada na TABELA 10, onde são apresentadas as medidas de erro e o coeficiente de correlação para a etapa de validação das RNAs e o valor da precisão para o método de classificação.

TABELA 10 – COMPARATIVO DOS CENÁRIOS

Cenário	Variáveis	RNA			Classificação
		Topologia	RMSE	Correlação	Precisão
A	41	8n 7k	1,5	0,58	85,2%
B	12	10n 10k	1,1	0,74	85,0% ⁴
C	16	9n 4k	1,1	0,77	96,3%
D	16	4n 3k	1,8	0,43	85,2% ⁴

FONTE: O Autor (2018)

Avaliando os resultados, não se percebe uma grande sobreposição de desempenho entre os cenários e metodologias quando se comparam os erros (RMSE) e a acurácia das classificações. Porém, ao avaliar o coeficiente de correlação é possível destacar os cenários B e C.

O cenário B gerou em seu modelo classificatório resultados críticos visto que identificou falsos negativos. Associando esse dado à topologia de rede, percebe-se ainda que o mesmo exige um maior esforço computacional e considera a necessidade de medição de um maior número de variáveis, visto

⁴ Classificação de falsos negativos, situação crítica para o modelo preditivo.

que as 12 componentes principais são definidas a partir da aferição das 41 variáveis identificadas nesse estudo.

O cenário C obteve destaque tanto na predição numérica (menor RMSE e maior coeficiente de correlação) como na predição classificatória (maior acurácia). Além disso, seus resultados foram alcançados com a consideração de apenas 16 variáveis.

Desta forma, a parametrização mais indicada para a predição de resistência à compressão considerando a metodologia de RNA e a partir dos dados apresentados neste trabalho, é a consideração das 16 variáveis, selecionadas pela metodologia da ACP e pelo método B2 de Jolliffe (2002), aplicadas em uma rede neural de topologia MLP com 9 neurônios na camada oculta e com divisão dos dados em 4 folds de treinamento.

Apesar da disponibilidade de apenas 27 amostras para a realização do estudo, é possível afirmar, a partir da avaliação dos especialistas, que o conjunto de dados considerado representa as condições possíveis para a caracterização do cimento dado a variação do processo.

Dessa forma, espera-se que um maior número de amostras seja capaz de melhorar os resultados no que tange os coeficientes de correlação e acurácia, bem como possivelmente reduzir o esforço computacional por meio da simplificação da topologia de rede. Contudo, essa conclusão só pode ser verificada por meio de simulações da rede baseadas em um maior banco de dados.

CAPÍTULO VI

5 CONSIDERAÇÕES FINAIS E CONCLUSÃO

Neste capítulo, são apresentadas as principais conclusões obtidas no estudo e algumas sugestões para trabalhos futuros.

5.1 CONCLUSÃO

O objetivo deste estudo foi o de desenvolver um modelo preditivo para a resistência à compressão aos 28 dias de cimentos produzidos com adição de escória, considerando a aplicação das redes neurais artificiais como método prático.

Para tal, foram consolidadas as informações referentes ao fluxo produtivo do cimento composto, identificando as suas etapas críticas e as variáveis de controle correspondentes. Além disso, foram identificados os requisitos normativos do cimento e da escória para que o produto final pudesse ser produzido e comercializado.

O levantamento bibliográfico realizado sobre o tema buscou a aplicação de técnicas de inteligência artificial com o mesmo objetivo final, a predição de resistência de cimentos, e encontrou diferentes considerações em relação às variáveis do processo produtivo e das características do produto final consideradas nos modelos. Como resultado, identificou-se a aplicação da redes neurais artificiais como ideal para o tipo de problema estudado nesta dissertação, bem como a sugestão de variáveis de influência que poderiam ser consideradas.

A caracterização da metodologia de RNA permitiu a identificação e compreensão da sua estrutura, particularidades e principais topologias consideradas para o desenvolvimento de modelos preditivos, foco desse trabalho.

As redes neurais do tipo MLP, consideradas na metodologia desta dissertação, não dependem de nenhum conhecimento prévio ou premissa do relacionamento entre as variáveis de entrada e a variáveis de saída, contudo é importante que a amostra selecionada possua informações suficientes para descrever a variável resposta estudada (MATIGNON, 2005).

Além disso, a rede MLP, graças a função sigmoideal dos neurônios da camada oculta, consegue representar tanto as relações lineares como as não lineares entre as variáveis, ao passo que outras metodologias, como por exemplo a regressão linear múltipla, conseguem apenas extrair e modelar a componente linear dessas relações (TANG; LEUNG; BAGCHI, 2006).

Com a compilação de todas as informações, e com base no conhecimento do processo produtivo disponibilizado pela Votorantim Cimentos, foi definido um conjunto de variáveis que fosse fundamental para a predição da resistência à compressão e ao mesmo tempo acessível para as unidades produtoras no quesito técnico (disponibilidade de ferramental), financeiro (alto custo para execução dos ensaios de difração de raios-x) e humano (disponibilidade de mão-de-obra).

A partir da execução das redes neurais artificiais para os diferentes cenários considerados foi possível observar que o valor da resistência à compressão aos 28 dias pode ser predito a partir de modelos matemáticos podendo esse resultado ser considerado como informação fundamental para a certificação de qualidade do produto no momento da sua expedição.

O melhor desempenho encontrado para a topologia do tipo MLP foi considerando 16 neurônios na camada de entrada, 9 neurônios na camada oculta e um neurônio na camada de saída. Ainda, a rede foi treinada considerando a divisão dos dados disponíveis de acordo com a metodologia *k-fold* em 4 grupos de igual dimensão, resultando em uma correlação de 0,77 entre os dados preditos e os dados observados e 96,3% de acurácia na classificação dos resultados nas classes “conforme” e “não conforme”, sendo os 3,7% referentes a alarmes falsos.

O resultado gerado por esse estudo abre a possibilidade de diversas ações gerenciais no que tange a garantia da qualidade dos cimentos expedidos. A identificação de possíveis desvios na qualidade do produtos, especificamente da resistência à compressão, antes do mesmo ser entregue ao cliente permite a redução de custos resultantes de ressarcimentos provenientes de reclamação de clientes por falta de desempenho, bem como permite o início de um processo investigativo e de reparametrização do processo produtivo no intuito de mitigar esse tipo de impacto.

Com base nos históricos de reclamações disponibilizados pela Votorantim Cimentos, a possibilidade de redução de custos, no que tange o valor monetário dispendido em ressarcimentos e considerando que as situações não conformes para os dados avaliados fossem identificadas pelo modelo preditivo de acordo com a sua acurácia, seria de aproximadamente 79% do valor monetário anual médio⁵.

Não se pode afirmar, contudo, que o cimento que obteve a predição da resistência à compressão dentro dos limites de qualidade vai apresentar, no cliente final, desempenho ideal pois fatores externos como problemas de transporte, armazenamento e aplicação podem alterar o comportamento do produto. No entanto, esses fatores são facilmente restreáveis e caso resultem em reclamações, as mesmas são classificadas como não procedentes.

A metodologia aqui apresentada pode ser facilmente replicada para os demais tipos de cimento e unidades da companhia estudada, fortalecendo a caracterização deste trabalho como genérico. Sugere-se, no entanto, o armazenamento de uma maior quantidade de dados, tanto do processo como da medição final de resistência, para enriquecer o poder de predição da rede neural.

A técnica de redes neurais artificiais mostrou ser uma ferramenta de grande utilidade para auxiliar os responsáveis pela qualidade a decidir sobre a expedição dos cimentos, pois é capaz de predizer a principal característica de

⁵ Porcentagem calculada com base no número médio de ressarcimentos, no valor monetário médio dos ressarcimentos cuja causa foi o desempenho da resistência à compressão e no valor monetário médio total dos ressarcimentos para os anos de 2016 e 2017.

desempenho dos cimento com um índice de erro aceitável. Além disso, mostra um potencial de melhoria em sua precisão caso o estudo seja performado para um maior número de amostras.

Assim, conclui-se que a partir das possíveis decisões gerenciais sobre as respostas geradas e do conseqüente potencial de redução de custo identificado, esse estudo apresenta grande aplicabilidade prática na indústria e contribui, academicamente, para o aprimoramento de novos estudos no segmento da produção de produtos conformes e no desenvolvimento de ferramentas para o controle de qualidade destes.

5.2 ESTUDOS FUTUROS

Nesta seção são descritas algumas sugestões que podem ser objeto de estudo de modo a aperfeiçoar a metodologia abordada.

- Acompanhamento do processo e aumento de registros no banco de dados para reavaliação das redes neurais buscando a melhora do RMSE e do coeficiente de correlação.
- Considerar o mesmo estudo para os demais tipos de cimentos, viabilizando a implementação prática em todos os cenários fabris.
- Avaliar e implementar outros métodos de predição de resistência à compressão de cimentos com o intuito de buscar melhores resultados.
- Considerar outras parametrizações e topologias de rede.
- Realizar a análise classificatória, por meio da matriz de confusão, segmentada em faixas de valores para entender como ocorre a classificação para os diferentes valores de resistência;
- Com um maior volume de dados, realizar um ajuste sazonal na avaliação do RMSE com a intenção de retirar do modelo variações outliers.

- Buscar novas variáveis, como a captura de imagem, para a realizar a predição da resistência à compressão dos cimentos visando a simplificação do processo de coleta de dados.
- Entender parametrizações das etapas anteriores à produção do cimento que possam ser alteradas visando a garantia de qualidade.
- Aplicar a mesma metodologia pra predizer outras características de desempenho dos cimentos produzidos.
- Aplicar a metodologia de análise fatorial para seleção de variáveis.

REFERÊNCIAS

AGULHA DE LE CHATELIER, Solotest, 2017. Disponível em: <http://www.solotest.com.br/novo/produtos/agulha-de-le-chatelier-p-expansibilidade/1.117.001>. Acesso em 10 de maio, 2017.

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.

AKKURT, S.; TAYFUR, G.; CAN, S. **Fuzzy Logic model for prediction of cement compressive strength**. Cement and Concrete Research, p. 1429-1433, 2004

ALPAYDIN, E. **Introduction to Machine Learning**. MIT Press, 2010.

APARELHO DE VICAT, Solotest, 2017. Disponível em: <http://www.solotest.com.br/novo/produtos/vicat-p-ensaio-de-cimento-nbr11581--nm43/1.111.001>. Acesso em 10 de maio, 2017.

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

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland - Análise química – Determinação de resíduo insolúvel**. NBR NM 15, 2012.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland - Análise química – Determinação de perda ao fogo**. NBR NM 18, 2012.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland com adições de materiais pozolânicos- Análise química – Método de arbitragem**. NBR NM 22, 2012.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland – Determinação da pasta de consistência normal**. NBR NM 43, 2003.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland – Determinação do tempo de pega**. NBR NM 65, 2003.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland – Determinação da finura pelo método de permeabilidade ao ar (Método Blaine)**. NBR NM 67, 1998.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland comum**. NBR 5732, 1991.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland de alta resistência inicial**. NBR 5733, 1991.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland - Determinação da resistência à compressão**. NBR 7215, 1997.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland composto - Especificação**. NBR 11578, 1997.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland – Determinação da finura por meio da peneira 75 µm (nº 200)**. NBR 11579, 1991.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Cimento Portland - Determinação da expansibilidade de Le Chatelier**. NBR 11582, 1991.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Materiais pozolânicos — Requisitos**. NBR 12653, 2004.

BAKIRCIOĞLU, H.; KOÇAK, T. **Survey of random neural networks applications**. European Journal of Operational Research, p. 319 –330, 2000.

BARANAUSKAS, J. A.; MONARD, M. C. **Conceitos de aprendizagem de máquinas. Sistemas Inteligentes – Fundamentos e Aplicações**, p.89-114. Editora Manole, 2003.

BARRETO, J. M. **Introdução às redes neurais artificiais**. Florianópolis: Universidade Federal de Santa Catarina, 2002.

BAYKASOGLU A., DERELI T., TANIS S. **Prediction of Cement Strength Using Soft Computing Techniques**. Cement and Concrete Research, vol. 34, p. 2083–2090, 2004.

BOUKADIDA, H.; HASSEN, N.; GAFSI, Z.; BESBES, K. **A Highly Time-Efficient Digital Multiplier based on the A2 Binary Representation**. International Journal of Engineering Science and Technology, vol. 3, p. 4498– 4509, 2011.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2ª ed., Rio de Janeiro, LTC, 2011.

BREUEL, T. **FFAI Problems and Solutions**. 2013. Disponível em: <https://www.mindmeister.com/pt/254106776>. Acesso em novembro de 2017.

BUCHANAN, B. G. **A (Very) Brief History of Artificial Intelligence**. AI Magazine, v. 26, p. 53 – 60, 2006.

CHEESEMAN, P.; STUSTZ, J. **Bayesian classification (Autoclass: Theory and results in knowledge Discovery data mining)**, 1990. Disponível em: <http://ic.arc.nasa.gov/ic/projects/bayes-group/Autoclass-c-program.html>. Acesso em 8 de maio de 2017.

DEMUTH, H., BEALE, M., HAGAN, M. **Neural Network Toolbox User's Guide**. The MathWorks, 2010.

DOGAN, G.; ARSLAN, M. H.; CEYLAN, M. **Statistical feature extraction based on an ANN approach for estimating the compressive strength of concrete**. Neural Network World, vol. 3, pg. 301-318, 2015.

ELSALAMONY, H. A. **Anemia cells detection based on shape signature using neural networks**. Measurement, v. 104, p. 50 – 59, 2017.

ESKANDARI, H.; NIK, M. G.; EIDI, M. M. **Prediction of mortar compressive strengths for different cement grades in the vicinity of sodium chloride using ANN**. Procedia Engineering, vol. 150, p. 2185-2192, 2016.

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.

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.

FA-LIANG, G. **A new way of predicting cement strength-fuzzy logic**, Cement and Concrete Research, vol. 27, p. 883-888, 1994.

FAUSETT, L. **Fundamentals de Neural Networks: architectures, algorithms and applications**. Ed Prentice-Hall, New Jersey, 1994.

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.

GHRITLAHRE, H. K.; PRASAD, R. K. **Prediction of Thermal Performance of Unidirectional Flow Porous Bed Solar Air Heater with Optimal Training Function Using Artificial Neural Network**. Energy Procedia, vol. 109, p. 369-376, 2017.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6ª. ed., Atlas, São Paulo, 2008.

GURNEY, K. **An Introduction to neural networks**, Taylor & Francis e-library, England, 2004.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H.; JESÚS, O. **Neural Network Design**, 2ª ed., p. 3-5, 2014.

HAIR, J. F., ANDERSON, R., BABIN, B. **Multivariate Data Analysis**. 6ª ed., Pearson Prentice Hall, New Jersey, 2005.

HAYKIN, S. **Redes neurais: princípios e práticas**. Tradução de Paulo Martins Engel, 2ª ed., Bookman, Porto Alegre, 2001.

HAYKIN, Simon. **Neural Networks and Learning Machines**. 3ª ed., Prentice Hall, New Jersey, 2009.

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.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 4ª edição. Upper Saddle River, New Jersey: Prentice-Hall, 1999.

JOLLIFFE, I. T. **Principal Component Analysis**. Springer Science & Business Media, 2ª edição, 2002

KHATTREE, R., NAIK, D.N. **Multivariate data reduction and discrimination with SAS software**. Cary, NC, USA: SAS Institute Inc., 2000.

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.

LUDWIG, O., MONTGOMERY, E. **Redes Neurais: Fundamentos e Aplicações com Programas em C**. 1ª edição. Editora Ciência moderna. 2007.

MARTINELLI, E. **Extração de conhecimento de Redes Neurais Artificiais**. Dissertação (Mestrado em Ciências) – USP, SP, 1999.

MATIGNON, R. **Neural network modeling using SAS enterprise miner**. AuthorHouse, 2005.

MATSUNAGA, V. Y. **Curso de redes neurais utilizando o MatLab**. Belém-PA, 2012.

MCCULLOCH, W. S.; PITTS, W. H. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biophysics, vol. 5, p. 115 – 133, 1943.

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.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Editora UFMG, 2007.

MONTGOMERY D.C., MASTRANGELO C.M. **Some statistical process control methods for auto correlated data**. Journal of Quality Technology, pág. 179-193, 1991.

MOTAMEDI, 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.

MOUSAVI, S. M.; AMINIAN, P.; GANDOMI, A. H.; ALAVI, A. H.; BOLANDI, H. **A new predictive model for compressive strength of HPC using gene expression programming**. Advances in Engineering Software, vol. 45, p. 105-114, 2012.

NEGNEVITSKY, M. **Artificial Intelligence: A Guide to Intelligent Systems**, Boston: Addison Wesley, 2002.

PAWLINA, W. R. **Histologia Texto e Atlas: Correções com Biologia Celular e Molecular**, 7^a ed., Rio de Janeiro: Guanabara Koogan, p. 361–362, 2016.

PEREIRA, S.; PINTO, A.; ALVES, V.; SILVA, C. A. **Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images**. Transactions on Medical Imaging v. 35, p. 1240 – 1251, 2016.

PILLAR, V. D. P.; **Suficiência amostral: Amostragem em Limnologia**. São Carlos, Editora Rima, 2004.

REGAZZI, A. J. **Análise multivariada**. Notas de aula INF 766, Departamento de Informática da Universidade Federal de Viçosa, v.2, 2000.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 2. Ed. Rio de Janeiro: Campos, 2004.

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.

SAJED, F; RAZAK, H. A. **Effects of curing regimes and cement fineness on the compressive strength of ordinary Portland cement mortars**. Construction and building materials, vol. 25, p.2036-2045, 2011.

SANTOS, A. M.; SEIXAS, J. M.; PEREIRA, B. B.; MEDRONHO, R. A. **Usando Redes neurais artificiais e regressão logística na predição da Hepatite A**. Revista Brasileira de Epidemiologia, São Paulo, 2005.

SHAWE-TAYLOR, J.; CRISTIANINI, N. **Kernel Methods and Pattern Analysis**. United Kingdom: Cambridge: 2000.

SILVA, M.; VELLASCO, M. M. B. R., CATALDO, E. **Evolving Spiking Neural Networks for Recognition of Aged Voices**. *Journal of Voice*, v. 31, p.24– 33, 2017.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da Produção**, 3ª ed., Editora Atlas, 2009.

STEINER, M. T. A.; **Redes neurais artificiais**. 2012. 42 slides. Apresentação em Power Point.

STEINER, M. T. A.; NIEVOLA, J. C.; SOMA, N. Y.; SHIMIZU, T.; STEINER N. P. J. **Extração de regras de classificação a partir de redes neurais para auxílio à tomada de decisão na concessão de crédito bancário**. *Pesquisa Operacional*, v. 27, n. 3, p. 407 – 426, 2007.

TANG, Z.; LEUNG, C. W.; BAGCHI, K. **Improving population estimation with neural network models**. *Advances in Neural Networks-ISNN*, p. 1181-1186, 2006. Disponível em: http://dx.doi.org/10.1007/11760191_172

TANGO, C. E. S. **An extrapolation method for compressive strength prediction of hydraulic cement products**, *Cement and Concrete Research*, vol. 28, p. 969– 983, 1998.

TATIBANA, C. Y.; KAETSU, D. Y. **Uma introdução às redes neurais**, 2000. Disponível em: <http://www.din.uem.br/ia/neurais/#links>. Acesso 10 de maio. 2017.

TOPÇU, 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.

VANDENBERG, C. E. L. R. J.; **Statistical and Methodological Myths and Urban Legends: Doctrine, Verity and Fable in the Organizational and Social Sciences**, Rotledge, 2009.

VARELLA, C. A. A. **Análise de componentes principais**. 2008. Disponível em: <http://www.ufrj.br/institutos/it/deng/varella>. Acesso em novembro de 2017.

VOTORANTIM CIMENTOS – **Apostilas de treinamento de qualidade**, 2013.

YADAV, N., YADAV, A., KUMAR, M. **An introduction to Neural Networks Methods for Differential Equations**. Springer, p. 21, 2015.

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.

ZURADA, J. M. **Introduction to Artificial Neural Systems**. St. Paul: West Publishing Company, 1992.

**APÊNDICE 1 – DADOS UTILIZADOS PARA O DESENVOLVIMENTO DA
RNA PARA O CENÁRIO A**

Amostra	Peneira #325 (%)	Peneira #400 (%)	SO₃ (%)	Perda ao Fogo (%)	Blaine (cm²/g)	R3 (MPa)	R7 (MPa)	Início de Pega (min)	Fim de Pega (min)	Resíduo insolúvel (%)	CaO (%)	SiO₂ (%)
1	0,5	1,54	3,32	5,12	4500	33	39,3	215	295	1,29	58,89	18,5
2	0,2	0,88	3,4	5,2	4690	35	38,9	190	260	1,5	59,5	18,36
3	0,3	1,1	2,91	4,94	4650	33,9	39,1	225	280	1,42	57,59	18,52
4	0,4	1,1	3,08	4,86	4650	33,2	39,5	230	300	1,17	57,68	18,57
5	0,3	1,1	3,08	4,99	4650	35,1	40,5	200	290	1,22	56,84	17,57
6	0,5	1,64	3,25	5,02	4450	33,9	40,8	235	285	1,59	56,51	17,58
7	0,43	1,54	3,25	5,28	4500	32	37,9	175	240	1,05	57,95	18,67
8	0,32	1,43	2,99	5,41	4690	32,5	37,7	220	290	1,1	57,62	18,92
9	0,32	1,54	3,36	5,14	4670	33,1	38,5	200	255	1,18	56,09	18,18
10	0,54	1,76	2,85	5,01	4500	34,2	38,7	210	260	0,96	56,63	19,44
11	0,32	1,1	3,02	4,46	4650	33,3	36,4	190	250	1,11	56,44	20,17
12	0,32	1,45	3,14	4,03	4900	35,9	39,3	210	260	0,93	56,91	17,62
13	0,44	1,32	3,18	5,35	4680	37	41,8	200	280	0,97	58,23	18,89
14	0,43	1,54	3,28	5,46	4500	33,1	39,3	245	295	1,14	57,48	18,99
15	0,6	1,96	3,08	5,05	4450	33,9	41,4	230	280	1,22	57,11	18,47
16	0,5	1,42	3,29	5,22	4600	35,1	40,9	220	280	1,31	56,83	18,21
17	0,4	1,31	3,28	5,14	4550	34,4	40,8	245	320	1,02	56,75	18,02
18	0,5	1,64	3,18	5,33	4500	33,3	43,1	240	320	1,27	57,54	18,23
19	0,4	1,2	2,85	5,23	4700	33,6	40,9	230	310	1,09	57,92	18,71
20	0,4	1,2	3,07	4,73	4670	35,4	40,7	205	295	1,2	57,42	19,11
21	0,3	0,99	2,88	4,77	4750	34,2	40,5	175	255	1,01	58,12	18,63
22	0,5	1,31	3,23	5,03	4610	35,6	42,3	200	270	0,72	57,26	18,8
23	0,3	0,99	2,84	4,89	4750	35,3	42	190	240	1,13	59,3	18,89
24	0,4	1,1	3,01	4,95	4670	36,3	40,8	180	260	1,06	58,05	18,61
25	0,2	0,99	3,06	4,4	4800	34,6	42	200	265	1,19	58,33	18,52
26	0,5	1,42	3,29	4,94	4500	33,9	42,2	215	300	1,2	55,99	18,31
27	0,3	1,1	3,22	4,83	4580	33,4	42,3	200	260	1,49	61,31	19,1

Amostra	Al₂O₃ (%)	Fe₂O₃ (%)	MgO (%)	K₂O (%)	Na₂O (%)	TiO₂ (%)	Mn₂O₃ (%)	FSC	MS	MA	Água de consistência (%)	Alita (%)
1	5,31	2,74	5,5	0,87	0,19	0,27	0,21	98,40	2,30	1,94	28,3	46,9
2	5,35	2,66	5,43	0,82	0,18	0,27	0,22	100,08	2,29	2,01	28,4	47,6
3	5,38	2,64	5,53	0,81	0,36	0,27	0,19	96,11	2,31	2,04	28,4	48,3
4	5,27	2,55	4,95	0,82	0,14	0,27	0,17	96,34	2,37	2,07	28,4	48,4
5	5,09	2,62	5,05	0,77	2,97	0,27	0,2	99,89	2,28	1,94	28,7	49
6	5,13	2,67	5,01	0,84	2,96	0,26	0,19	99,12	2,25	1,92	28,6	48,6
7	5,44	2,5	5,46	0,79	0,15	0,27	0,18	96,07	2,35	2,18	27,8	50,6
8	5,54	2,52	5,55	0,79	0,17	0,27	0,2	94,23	2,35	2,20	28	47,9
9	5,4	2,39	5,13	0,79	0,16	0,28	0,2	95,34	2,33	2,26	28	49
10	5,73	2,46	5,44	0,77	0,16	0,29	0,21	90,19	2,37	2,33	28,2	58,3
11	5,95	2,46	5,47	0,77	0,16	0,29	0,22	86,70	2,40	2,42	28	48,9
12	5,28	2,61	5,18	0,78	0,16	0,27	0,18	99,38	2,23	2,02	27,8	48,3
13	5,51	2,43	5,74	0,83	0,19	0,26	0,17	95,50	2,38	2,27	28,2	47,4
14	5,69	2,47	5,52	0,76	0,16	0,28	0,2	93,48	2,33	2,30	27,4	54,8
15	5,33	2,44	5,24	0,75	0,16	0,27	0,18	95,84	2,38	2,18	27,2	49,8
16	5,38	2,51	5,32	0,76	0,16	0,26	0,18	96,37	2,31	2,14	27,2	45,2
17	5,38	2,51	5,15	0,74	0,15	0,27	0,17	97,11	2,28	2,14	27,8	49,2
18	5,37	2,47	5,2	0,76	0,16	0,27	0,18	97,55	2,33	2,17	28,1	46,9
19	5,67	2,73	5,46	0,75	0,16	0,28	0,21	95,18	2,23	2,08	27,9	46,6
20	5,76	2,58	5,56	0,72	0,16	0,28	0,21	92,64	2,29	2,23	27,8	49,7
21	5,42	2,61	5,55	0,75	0,16	0,27	0,19	96,45	2,32	2,08	27,8	47,2
22	5,46	2,6	5,58	0,74	0,13	0,27	0,19	94,22	2,33	2,10	28	53,2
23	5,47	2,63	5,67	0,77	0,14	0,27	0,19	97,12	2,33	2,08	27,7	51,9
24	5,17	2,43	5,61	0,78	0,19	0,25	0,16	97,09	2,45	2,13	27,8	51,2
25	5,56	2,66	5,86	0,76	0,16	0,26	0,19	96,98	2,25	2,09	28	50,9
26	5,57	2,37	5,54	0,78	0,15	0,28	0,21	94,29	2,31	2,35	28,4	50,1
27	5,54	2,87	5,49	0,88	0,18	0,27	0,2	99,07	2,27	1,93	28,8	49

Amostra	Belita (%)	C₃A ortorrômbico (%)	C₃A cúbico (%)	Ferrita (%)	CaO livre (%)	Periclásio (%)	Arcanita (%)	Aftitalita (%)
1	11,2	0	4,62	7,2	0,6	4,1	0,18	0,11
2	10,1	0,14	4,62	7,2	0,35	3,95	0,14	0,11
3	9,1	0,17	4,29	7,8	0,15	4,16	0,2	0
4	10,2	0,31	4,42	7,5	0,11	4,37	0,27	0
5	11,5	0	4,04	8,5	0,07	4,54	0,08	0,03
6	11,9	0,51	4,97	7,7	0,12	4,12	0,21	0,03
7	10,5	0	5,1	7,1	0,02	4,55	0	0,1
8	10,4	0,02	4,72	6,8	1,22	4,06	0	0,14
9	11,5	0	4,04	8,5	0,07	4,54	0,08	0,03
10	9	0,27	5,52	7,2	0,21	3,58	0,04	0,57
11	9,4	0	5,08	7,2	0,17	4,25	0	0,1
12	10,9	0	5,56	7	0,29	4,11	0,08	0,12
13	11,4	0,13	5,41	6,9	0,07	4,46	0,14	0,05
14	8,2	0	5,84	6,6	0,05	4,23	0	0,08
15	8,5	0	5,3	6,6	0,09	4,2	0	0
16	8,9	0	5,67	6,1	0,34	3,99	0	0,15
17	10,2	0,2	5,3	7	0,14	4,29	0,05	0,04
18	11,2	0	4,62	7,2	0,6	4,1	0,18	0,11
19	10,3	0	4,36	6,5	4,43	4,23	0	0
20	10,4	0	4,89	7,1	0,24	4,53	0,11	0,15
21	12,6	0	4,39	7,4	0,35	4,13	0	0,24
22	9,5	0	4,52	8,3	0,22	4,3	0,28	0,05
23	9,5	0	4,28	8,3	0,08	4,66	0,18	0,09
24	10,3	0	4,23	8,3	0	4,65	0,11	0,06
25	10,2	0,08	3,64	8,3	0,09	4,83	0,04	0,12
26	8,5	0	5,18	6,9	0,06	3,98	0	0
27	10,9	0	3,94	7,9	0,04	4,31	0,03	0

Amostra	Langbeinita (%)	Calcita (%)	Dolomita (%)	Quartzo (%)	Gipsita (%)	Bassanita (%)	Escoria (%)
1	0	9,8	0,3	0,9	6,1	0	7,1
2	0,04	9	0,3	1,1	5,2	0	9,3
3	0	9,5	0,5	0,9	5,3	0,1	8,7
4	0	9,2	0,7	1	4,2	0,1	8,3
5	0	9,1	0,4	1	3,2	0,8	6,5
6	0	8	0,5	1,3	3,4	0,6	7,2
7	0	8,6	0,4	0,7	3,3	0,6	7,6
8	0,01	10,5	0,3	0,4	3,4	0,5	8,9
9	0	9,1	0,4	1	3,2	0,8	6,5
10	0	8,3	0	0,7	3,4	1,3	14,6
11	0	8	0,5	0,7	2,9	1	10,5
12	0	8,5	0,3	0,7	3,4	0,7	8,9
13	0	9,1	0,6	0,5	2,9	1,1	8,7
14	0,01	5,5	0,5	0,5	3,4	0,7	8,8
15	0	9,6	0,8	0,8	2,8	1,2	9,1
16	0,04	9,6	0,6	0,6	2,7	1,4	12
17	0	8	0,6	1,3	3,5	1	8,1
18	0	9,8	0,3	0,9	6,1	0	7,1
19	0	9,8	0,5	0,6	2,4	0,7	8,8
20	0	8,4	0,4	0,6	4,4	0,2	8,3
21	0,02	7,3	0,2	0,5	4,3	0,2	10,9
22	0	9,1	0,4	0,7	2,4	0,6	5,7
23	0	9,7	0,3	0,7	2,9	1	5,3
24	0	9,2	0,4	0,8	2,9	1,1	5,7
25	0	8,6	0,3	0,9	4,4	0,5	6
26	0,01	9,8	0,5	0,7	3	0,5	9,9
27	0	8,5	0,4	1,4	3,5	1	8,3

Amostra	Portlandita (%)	Fluorita (%)	R28 observada (MPa)	R28 predita (MPa)
1	0,32	0,49	50,3	51,9
2	0,24	0,46	51,6	48,6
3	0,31	0,57	50,3	52,1
4	0,25	0,6	49,4	50,3
5	0,53	0,75	50	52,9
6	0,32	0,58	51	52,8
7	0,42	0,47	48,1	48,1
8	0,53	0,21	48,1	48,1
9	0,53	0,75	48,2	48,1
10	0,72	0,21	51,9	50,8
11	0,91	0,46	48,1	48,1
12	0,62	0,58	53	52,5
13	0,77	0,41	51,7	50,5
14	0,65	0,16	49,6	48,8
15	0,73	0,56	51,9	50,8
16	0,91	0,55	50,7	49,6
17	0,73	0,46	51,7	50,5
18	0,32	0,49	52,9	52,3
19	0,38	0,48	49,7	48,9
20	0,4	0,29	52,4	51,5
21	0,24	0,11	49,5	48,8
22	0,55	0,24	51	51,4
23	0,61	0,37	52,1	51,0
24	0,57	0,41	51,2	50,1
25	0,43	0,49	49	50,5
26	0,6	0,3	52,5	49,9
27	0,42	0,5	53,4	50,3

Neurônio	W _i								
	Peneira #325 (%)	Peneira #400 (%)	SO ₃ (%)	Perda ao Fogo (%)	Blaine (cm ² /g)	R3 (MPa)	R7 (MPa)	Início de Pega (min)	Fim de Pega (min)
1	1,0028	0,5665	-0,4562	-1,3167	-0,4089	0,2193	1,7015	0,4943	-0,1087
2	-1,7054	0,6165	0,9623	1,6348	0,7371	-1,8584	-2,2456	0,0285	-1,1374
3	0,6016	0,8438	-1,2021	-0,4572	0,3811	0,4243	0,8454	1,0630	0,7596
4	0,0982	-0,6883	-0,6089	0,4033	0,7801	0,1161	-1,1101	-1,3179	0,6047
5	-0,7226	0,3298	0,0450	1,9393	-0,5574	-2,8870	-3,0226	-1,0829	-0,9157
6	-0,8737	0,5179	0,3724	-0,4421	-0,7860	0,4020	0,4416	0,7593	0,2197
7	0,5223	-0,2143	-0,0625	0,4415	-0,8194	-0,1235	0,2567	-0,7455	1,0510
8	-1,1093	0,8195	-0,4755	0,8887	-0,3763	-0,9066	-0,7978	0,0579	-0,6408

Neurônio	W _i							
	Resíduo insolúvel (%)	CaO (%)	SiO ₂ (%)	Al ₂ O ₃ (%)	Fe ₂ O ₃ (%)	MgO (%)	K ₂ O (%)	Na ₂ O (%)
1	0,8506	-0,6679	0,1294	-0,3589	1,0533	-0,0660	-0,7046	0,4353
2	0,3758	-0,2808	0,7053	-0,4193	-0,6172	0,6913	0,0070	0,0006
3	0,1208	0,7983	-0,6550	0,6034	0,5760	0,1139	-0,0983	0,4504
4	-0,9957	-0,5020	0,2081	1,0191	0,4514	0,3297	-0,4389	-0,4417
5	-0,9452	-0,3366	-0,0811	0,4585	-0,8037	0,3110	0,7038	-0,5124
6	0,3002	0,9834	0,8017	0,7932	0,3156	-0,3867	0,9501	0,6406
7	0,8653	1,1261	0,5771	-0,0172	0,5158	-0,4614	-0,6501	-0,7690
8	-0,6711	0,7220	0,6553	0,7872	0,4944	0,4683	-0,0248	-0,5812

Neurônio	W _i							
	TiO ₂ (%)	Mn ₂ O ₃ (%)	FSC	MS	MA	Água de consistência (%)	Alita (%)	Belita (%)
1	0,3776	0,6091	-0,9380	-0,6773	-0,9691	-0,1501	-0,5930	-0,9886
2	-0,6164	0,7939	-0,3995	0,6295	0,1877	-0,2280	0,4198	-0,3029
3	0,4290	0,1499	0,4150	-0,9838	-1,0065	-0,7978	0,2119	-0,1308
4	0,4316	0,4669	-0,7048	-0,7079	0,8011	0,2532	0,0484	-0,6928
5	-0,9606	0,4410	0,2363	-0,2836	0,3168	0,9577	-0,3873	1,3386
6	0,4949	0,7050	-0,3246	-0,5618	0,1338	0,1705	0,5851	1,0405
7	0,0687	0,2042	-0,0234	0,7678	0,4182	-0,1147	-1,1404	1,0380
8	-0,3453	-0,2250	0,2031	-0,7506	-0,9617	-0,6477	0,4523	-0,4499

Neurônio	W _i						
	C ₃ A ortorrômbico (%)	C ₃ A cúbico (%)	Ferrita (%)	CaO livre (%)	Periclásio (%)	Arcanita (%)	Aftitalita (%)
1	-1,5965	0,0269	0,5808	-0,0070	0,1693	1,4073	0,3326
2	0,6033	-1,1456	-0,6038	0,4336	0,4186	-1,6148	-1,3918
3	1,0444	-0,3385	-0,5497	-0,7915	-0,1451	0,7610	-0,7494
4	-0,3452	-0,9400	0,6166	0,4281	0,2486	0,4579	-0,7752
5	-0,6226	-1,5732	-0,3235	-0,2083	0,8454	-1,9181	0,0174
6	0,3678	0,6769	-0,5181	-0,3179	1,0352	-0,6738	0,6758
7	-0,5687	-1,4215	0,8114	0,5433	0,5221	-0,8925	-1,4551
8	0,5638	-0,9199	-1,2731	0,5532	-0,2971	-0,2285	-0,4072

Neurônio	W_i						
	Langbeinita (%)	Calcita (%)	Dolomita (%)	Quartzo (%)	Gipsita (%)	Bassanita (%)	Escória (%)
1	-0,5246	-0,8379	-0,7612	0,0506	1,4041	-0,8698	-0,3079
2	0,8237	-0,3786	1,4464	0,5809	-1,1974	-0,4147	0,6809
3	0,8037	0,0978	0,5153	0,2911	0,0526	-0,1370	0,1691
4	0,1557	-0,0334	-0,2468	0,5129	-0,0398	-0,4598	0,2947
5	1,0799	0,8094	-0,8055	-1,5115	-0,9072	0,6266	0,6484
6	-0,8336	-0,4770	-0,3857	-0,8244	0,0394	0,8803	0,3748
7	0,9759	1,2984	-0,2513	0,9637	0,4439	-0,6155	-1,0610
8	-0,4841	-0,4721	0,1070	-0,9214	-0,5885	-0,5020	0,0277

Neurônio	W_i	
	Portlandita (%)	Fluorita (%)
1	0,1547	0,7736
2	-0,4555	0,1891
3	-1,0026	-0,0505
4	0,8744	-1,0357
5	0,5244	-0,0615
6	0,1813	-0,6641
7	-0,5570	-0,0181
8	-0,9813	0,4110

Neurônio	W_h
1	1,6197
2	-3,1448
3	1,0512
4	-0,8904
5	-4,1201
6	0,0146
7	-1,0999
8	-2,8936

Neurônio	$Teta$
1	0,8195
2	0,8138
3	0,9967
4	0,8878
5	1,0831
6	1,3289
7	0,7839
8	0,7793
Bias	0,0000

**APÊNDICE 2 – DADOS UTILIZADOS PARA O DESENVOLVIMENTO DA
RNA PARA O CENÁRIO B**

Amostra	CP 1	CP 2	CP 3	CP 4	CP 5	CP 6	CP 7
1	897,5	470,0	0,8	-551,6	1288,8	113,2	-820,6
2	924,3	474,1	-19,5	-581,9	1339,7	120,9	-842,6
3	927,6	482,2	-5,0	-574,5	1335,9	119,7	-850,5
4	885,7	462,0	-10,5	-556,8	1283,9	111,8	-810,5
5	920,7	486,4	-1,6	-569,5	1332,8	119,7	-848,5
6	972,1	506,4	-3,9	-602,8	1405,1	124,9	-895,9
7	927,5	478,0	-10,7	-579,4	1339,4	119,5	-843,7
8	880,2	445,3	-28,2	-563,1	1278,6	114,9	-797,8
9	875,4	442,4	-22,5	-554,5	1267,7	112,7	-792,3
10	906,7	462,5	-18,1	-570,7	1315,5	116,4	-825,6
11	891,1	443,7	-34,6	-572,3	1293,1	116,6	-802,9
12	883,6	437,9	-36,4	-567,0	1277,9	114,8	-792,1
13	924,3	468,2	-27,7	-586,5	1341,7	122,1	-837,0
14	922,4	474,4	-16,6	-580,7	1333,6	120,5	-838,3
15	947,5	498,1	0,9	-582,9	1363,7	119,7	-869,2
16	914,1	472,6	-8,4	-570,9	1316,3	118,7	-831,0
17	947,9	497,5	4,2	-581,8	1361,3	121,5	-868,5
18	931,2	485,5	-0,1	-575,0	1337,4	119,5	-849,2
19	954,6	496,7	-4,6	-591,4	1373,3	123,5	-872,8
20	885,5	448,8	-23,7	-562,3	1281,9	115,0	-799,8
21	911,5	469,8	-9,0	-564,2	1309,1	114,6	-827,1
22	889,5	449,0	-24,3	-561,5	1282,1	113,8	-802,0
23	934,0	485,1	-5,0	-577,1	1343,6	117,8	-853,1
24	917,9	469,5	-18,5	-577,0	1326,8	118,6	-835,8
25	915,6	464,1	-24,8	-579,7	1324,9	119,3	-830,7
26	922,9	471,4	-14,1	-576,9	1328,3	118,1	-836,5
27	877,3	439,7	-25,7	-555,3	1266,2	110,9	-791,6

Amostra	CP 8	CP 9	CP 10	CP 11	CP 12	R28 observada (MPa)	R28 predita (MPa)
1	435,2	551,6	-913,0	-28,4	-99,9	48,1	49,0
2	460,0	580,0	-970,9	-37,4	-97,5	48,1	49,0
3	454,2	574,7	-953,4	-32,0	-100,7	48,2	49,1
4	444,9	551,6	-925,2	-34,3	-94,6	51,9	51,6
5	450,9	571,8	-947,9	-29,9	-100,9	48,1	49,0
6	476,6	602,3	-999,2	-32,7	-106,1	53	52,8
7	456,8	577,3	-965,1	-32,0	-99,9	51,7	51,4
8	451,1	551,3	-942,3	-44,2	-90,2	49,6	49,8
9	443,8	547,4	-925,9	-37,9	-90,1	51,9	51,6
10	453,9	567,1	-952,7	-34,8	-95,3	50,7	50,6
11	455,4	561,9	-960,3	-43,7	-90,0	51,7	51,4
12	448,5	556,9	-950,5	-41,6	-88,0	52,9	52,7
13	464,6	583,3	-980,9	-40,3	-95,7	49,7	49,9
14	456,8	576,1	-968,5	-34,6	-97,3	52,4	49,5
15	456,0	583,8	-965,2	-27,2	-105,3	49,5	49,7
16	452,2	566,8	-947,3	-32,3	-98,2	51	50,8
17	461,0	582,0	-960,9	-28,5	-103,8	52,1	51,8
18	452,6	574,1	-951,9	-28,6	-102,0	51,2	50,9
19	466,7	589,4	-980,5	-31,7	-102,6	49	49,5
20	445,6	555,6	-939,7	-35,6	-92,0	52,5	53,0
21	448,3	561,8	-938,3	-31,9	-98,0	53,4	49,5
22	442,9	555,6	-938,0	-37,1	-92,3	50,3	50,5
23	454,4	576,2	-957,5	-30,0	-101,9	51,6	50,3
24	457,9	572,6	-962,2	-36,7	-95,5	50,3	49,2
25	459,4	574,1	-969,2	-39,4	-94,6	49,4	49,5
26	453,8	574,5	-962,0	-34,2	-98,3	50	49,5
27	443,1	548,2	-930,1	-40,4	-90,3	51	50,3

Neurônio	W _i							
	CP 1	CP 2	CP 3	CP 4	CP 5	CP 6	CP 7	CP 8
1	2,1827	2,6840	1,6095	-1,1047	2,5425	2,6666	-2,7077	1,7349
2	0,5630	0,0946	0,6053	0,2210	0,9150	0,6700	0,9275	0,0673
3	-1,0573	-0,6463	1,6593	5,4536	-2,0048	0,3711	6,6570	-3,0917
4	0,3681	-2,0356	0,6277	0,1271	-1,4105	2,7485	1,4480	4,8543
5	0,9957	-1,4306	0,4392	-2,3488	-0,8032	0,4667	2,0882	2,8005
6	-3,9745	8,7875	-4,6252	10,8764	3,7713	0,2845	-4,1525	-9,4780
7	1,7634	2,9027	1,4977	-1,2351	3,3786	2,9233	-3,1759	2,8015
8	-0,4647	4,2232	-5,1528	4,8394	2,5631	6,8350	-4,9494	-1,9578
9	1,1509	-0,8868	-0,2837	-0,5315	0,8523	0,1583	0,6499	1,2938
10	0,2159	5,6472	2,2000	3,7627	2,6568	-0,0160	-9,0521	-3,2147

Neurônio	W_i			
	CP 9	CP 10	CP 11	CP 12
1	0,6004	0,1764	-0,5729	-1,9835
2	-0,2017	0,2119	1,4288	1,5525
3	-2,1461	6,0795	4,1074	6,0174
4	-2,3868	2,1784	-2,1108	3,7280
5	-1,4717	-0,9679	0,8167	0,2972
6	4,2844	4,1076	-8,4540	-3,2837
7	2,7762	-2,2487	1,4240	-1,2359
8	2,6231	1,2961	-12,1995	6,0686
9	-0,0272	0,8500	0,2547	1,1851
10	0,9483	3,5898	-4,1726	-2,3980

Neurônio	W_h
1	-1,8242
2	2,5819
3	-5,1403
4	5,6004
5	4,0219
6	-6,9286
7	-3,2429
8	-5,1338
9	4,2114
10	-3,6145

Neurônio	$Teta$
1	1,3659
2	1,0468
3	0,8687
4	0,9971
5	1,2669
6	1,1801
7	1,2101
8	0,9985
9	1,4357
10	1,4043
Bias	0,0000

**APÊNDICE 3 – DADOS UTILIZADOS PARA O DESENVOLVIMENTO DA
RNA PARA O CENÁRIO C**

Amostra	Perda ao fogo (%)	R7 (MPa)	Resíduo insolúvel (%)	Al₂O₃ (%)	MgO (%)	Água de consistência (%)
1	5,3	37,9	1,1	5,4	5,5	27,8
2	5,4	37,7	1,1	5,5	5,6	28,0
3	5,1	38,5	1,2	5,4	5,1	28,0
4	5,0	38,7	1,0	5,7	5,4	28,2
5	4,5	36,4	1,1	6,0	5,5	28,0
6	4,0	39,3	0,9	5,3	5,2	27,8
7	5,4	41,8	1,0	5,5	5,7	28,2
8	5,5	39,3	1,1	5,7	5,5	27,4
9	5,1	41,4	1,2	5,3	5,2	27,2
10	5,2	40,9	1,3	5,4	5,3	27,2
11	5,1	40,8	1,0	5,4	5,2	27,8
12	5,3	43,1	1,3	5,4	5,2	28,1
13	5,2	40,9	1,1	5,7	5,5	27,9
14	4,7	40,7	1,2	5,8	5,6	27,8
15	4,8	40,5	1,0	5,4	5,6	27,8
16	5,0	42,3	0,7	5,5	5,6	28,0
17	4,9	42,0	1,1	5,5	5,7	27,7
18	5,0	40,8	1,1	5,2	5,6	27,8
19	4,4	42,0	1,2	5,6	5,9	28,0
20	4,9	42,2	1,2	5,6	5,5	28,4
21	4,8	42,3	1,5	5,5	5,5	28,8
22	5,1	39,3	1,3	5,3	5,5	28,3
23	5,2	38,9	1,5	5,4	5,4	28,4
24	4,9	39,1	1,4	5,4	5,5	28,4
25	4,9	39,5	1,2	5,3	5,0	28,4
26	5,0	40,5	1,2	5,1	5,1	28,7
27	5,0	40,8	1,6	5,1	5,0	28,6

Amostra	Alita (%)	Belita (%)	C₃A ortorrômico (%)	C₃A cúbico (%)	Periclásio (%)	Langbeinita (%)	Dolomita (%)
1	50,6	10,5	0,0	5,1	4,6	0,0	0,4
2	47,9	10,4	0,0	4,7	4,1	0,0	0,3
3	49,0	11,5	0,0	4,0	4,5	0,0	0,4
4	58,3	9,0	0,3	5,5	3,6	0,0	0,0
5	48,9	9,4	0,0	5,1	4,3	0,0	0,5
6	48,3	10,9	0,0	5,6	4,1	0,0	0,3
7	47,4	11,4	0,1	5,4	4,5	0,0	0,6
8	54,8	8,2	0,0	5,8	4,2	0,0	0,5
9	49,8	8,5	0,0	5,3	4,2	0,0	0,8
10	45,2	8,9	0,0	5,7	4,0	0,0	0,6
11	49,2	10,2	0,2	5,3	4,3	0,0	0,6
12	46,9	11,2	0,0	4,6	4,1	0,0	0,3
13	46,6	10,3	0,0	4,4	4,2	0,0	0,5
14	49,7	10,4	0,0	4,9	4,5	0,0	0,4
15	47,2	12,6	0,0	4,4	4,1	0,0	0,2
16	53,2	9,5	0,0	4,5	4,3	0,0	0,4
17	51,9	9,5	0,0	4,3	4,7	0,0	0,3
18	51,2	10,3	0,0	4,2	4,7	0,0	0,4
19	50,9	10,2	0,1	3,6	4,8	0,0	0,3
20	50,1	8,5	0,0	5,2	4,0	0,0	0,5
21	49,0	10,9	0,0	3,9	4,3	0,0	0,4
22	46,9	11,2	0,0	4,6	4,1	0,0	0,3
23	47,6	10,1	0,1	4,6	4,0	0,0	0,3
24	48,3	9,1	0,2	4,3	4,2	0,0	0,5
25	48,4	10,2	0,3	4,4	4,4	0,0	0,7
26	49,0	11,5	0,0	4,0	4,5	0,0	0,4
27	48,6	11,9	0,5	5,0	4,1	0,0	0,5

Amostra	Gipsita (%)	Escória (%)	Portlandita (%)	R28 observada (MPa)	R28 predita (MPa)
1	3,3	7,6	0,4	48,1	48,1
2	3,4	8,9	0,5	48,1	48,1
3	3,2	6,5	0,5	48,2	48,1
4	3,4	14,6	0,7	51,9	51,4
5	2,9	10,5	0,9	48,1	48,1
6	3,4	8,9	0,6	53	53,0
7	2,9	8,7	0,8	51,7	51,7
8	3,4	8,8	0,7	49,6	49,6
9	2,8	9,1	0,7	51,9	51,9
10	2,7	12,0	0,9	50,7	50,7
11	3,5	8,1	0,7	51,7	51,7
12	6,1	7,1	0,3	52,9	52,9
13	2,4	8,8	0,4	49,7	49,7
14	4,4	8,3	0,4	52,4	52,4
15	4,3	10,9	0,2	49,5	52,2
16	2,4	5,7	0,6	51	51,3
17	2,9	5,3	0,6	52,1	50,7
18	2,9	5,7	0,6	51,2	48,9
19	4,4	6,0	0,4	49	51,3
20	3,0	9,9	0,6	52,5	52,9
21	3,5	8,3	0,4	53,4	52,0
22	6,1	7,1	0,3	50,3	51,0
23	5,2	9,3	0,2	51,6	49,1
24	5,3	8,7	0,3	50,3	49,7
25	4,2	8,3	0,3	49,4	49,6
26	3,2	6,5	0,5	50	49,1
27	3,4	7,2	0,3	51	51,9

Neurônio	W_i							
	Perda ao fogo (%)	R7 (MPa)	Resíduo insolúvel (%)	Al₂O₃ (%)	MgO (%)	Água de consistência (%)	Alita (%)	Belita (%)
1	0,5899	-0,2444	-0,6411	0,9987	-0,3139	-0,6222	0,0728	0,4388
2	-0,7567	2,4830	0,8879	-1,3744	0,1775	-0,3469	0,0070	0,4591
3	1,9508	-6,3142	-1,4493	0,6650	0,3663	1,3483	-0,4722	0,1399
4	0,9085	-1,6591	-1,1091	-0,1286	0,1607	-0,1744	0,6361	-0,8179
5	2,1442	-5,9450	0,3471	-0,6876	-0,2125	-0,3939	-0,3205	-0,5669
6	-1,4080	1,2262	-0,4407	0,7829	-0,0726	0,4925	-0,4919	-0,0495
7	1,7707	-2,1426	0,6770	-0,0472	-0,0768	0,5696	-0,5904	0,3482
8	-0,3607	-0,6734	0,4008	0,1052	-0,0394	-0,4404	-1,1723	-1,2872
9	0,9061	-2,8651	-0,9084	-0,1000	1,8855	-0,3686	0,3237	-0,2211

Neurônio	W_i					
	C3A ortorrômbico (%)	C3A cúbico (%)	Periclásio (%)	Langbeinita (%)	Dolomita (%)	Gipsita (%)
1	0,0665	-1,3485	0,9051	-0,2555	0,8986	-1,0075
2	-0,3004	0,3051	-0,4827	0,2310	0,5379	0,7947
3	0,3496	-2,0065	1,4679	0,4690	-0,5512	-1,3601
4	-0,5107	-1,0935	0,9116	-0,9384	-0,8157	-0,8342
5	0,5195	-1,3220	0,3522	1,1668	0,5091	-1,3452
6	0,6988	1,6507	-1,1870	0,3895	-1,3978	-0,1919
7	0,1174	-2,2602	0,6304	0,8164	0,7547	-0,8832
8	0,6000	-1,0281	-1,0752	0,3241	0,5181	-0,3453
9	-0,5294	-2,0016	0,5286	-0,9161	-0,7480	-0,4563

Neurônio	W_i	
	Escória (%)	Portlandita (%)
1	-0,1571	-0,2972
2	0,3179	-0,2126
3	-0,4554	0,5018
4	-1,1132	-1,0190
5	-0,7207	0,9083
6	-0,3502	0,0800
7	-0,2896	0,4024
8	-0,5737	0,9146
9	-0,5495	1,1641

Neurônio	W_h
1	-0,2378
2	1,6532
3	-3,4343
4	-1,2940
5	-3,2394
6	1,6137
7	-1,8076
8	-0,6661
9	-1,7551

Neurônio	1	2	3	4	5	6	7	8	9	Bias
Teta	0,9935	0,6164	1,1772	0,8941	1,4830	0,6855	0,6080	0,9381	0,5924	0,8827

**APÊNDICE 4 – DADOS UTILIZADOS PARA O DESENVOLVIMENTO DA
RNA PARA O CENÁRIO D**

Amostra	R7 (MPa)	Fim de pega (min)	Resíduo insolúvel (%)	SiO₂ (%)	Fe₂O₃ (%)	MgO (%)	K₂O (%)
1	3,0	240,0	1,1	18,7	2,5	5,5	0,8
2	37,7	290,0	1,1	18,9	2,5	5,6	0,8
3	38,5	255,0	1,2	18,2	2,4	5,1	0,8
4	38,7	260,0	1,0	19,4	2,5	5,4	0,8
5	36,4	250,0	1,1	20,2	2,5	5,5	0,8
6	39,3	260,0	0,9	17,6	2,6	5,2	0,8
7	41,8	280,0	1,0	18,9	2,4	5,7	0,8
8	39,3	295,0	1,1	19,0	2,5	5,5	0,8
9	41,4	280,0	1,2	18,5	2,4	5,2	0,8
10	40,9	280,0	1,3	18,2	2,5	5,3	0,8
11	40,8	320,0	1,0	18,0	2,5	5,2	0,7
12	43,1	320,0	1,3	18,2	2,5	5,2	0,8
13	40,9	310,0	1,1	18,7	2,7	5,5	0,8
14	40,7	295,0	1,2	19,1	2,6	5,6	0,7
15	40,5	255,0	1,0	18,6	2,6	5,6	0,8
16	42,3	270,0	0,7	18,8	2,6	5,6	0,7
17	42,0	240,0	1,1	18,9	2,6	5,7	0,8
18	40,8	260,0	1,1	18,6	2,4	5,6	0,8
19	42,0	265,0	1,2	18,5	2,7	5,9	0,8
20	42,2	300,0	1,2	18,3	2,4	5,5	0,8
21	42,3	260,0	1,5	19,1	2,9	5,5	0,9
22	39,3	295,0	1,3	18,5	2,7	5,5	0,9
23	38,9	260,0	1,5	18,4	2,7	5,4	0,8
24	39,1	280,0	1,4	18,5	2,6	5,5	0,8
25	39,5	300,0	1,2	18,6	2,6	5,0	0,8
26	40,5	290,0	1,2	17,6	2,6	5,1	0,8
27	40,8	285,0	1,6	17,6	2,7	5,0	0,8

Amostra	MS	Alita (%)	Belita (%)	C₃A ortorrômbico (%)	C₃A cúbico (%)	Aftalitita (%)	Langbeinita (%)
1	2,4	50,6	10,5	0,0	5,1	0,1	0,0
2	2,3	47,9	10,4	0,0	4,7	0,1	0,0
3	2,3	49,0	11,5	0,0	4,0	0,0	0,0
4	2,4	58,3	9,0	0,3	5,5	0,6	0,0
5	2,4	48,9	9,4	0,0	5,1	0,1	0,0
6	2,2	48,3	10,9	0,0	5,6	0,1	0,0
7	2,4	47,4	11,4	0,1	5,4	0,1	0,0
8	2,3	54,8	8,2	0,0	5,8	0,1	0,0
9	2,4	49,8	8,5	0,0	5,3	0,0	0,0
10	2,3	45,2	8,9	0,0	5,7	0,2	0,0
11	2,3	49,2	10,2	0,2	5,3	0,0	0,0
12	2,3	46,9	11,2	0,0	4,6	0,1	0,0
13	2,2	46,6	10,3	0,0	4,4	0,0	0,0
14	2,3	49,7	10,4	0,0	4,9	0,2	0,0
15	2,3	47,2	12,6	0,0	4,4	0,2	0,0
16	2,3	53,2	9,5	0,0	4,5	0,1	0,0
17	2,3	51,9	9,5	0,0	4,3	0,1	0,0
18	2,4	51,2	10,3	0,0	4,2	0,1	0,0
19	2,3	50,9	10,2	0,1	3,6	0,1	0,0
20	2,3	50,1	8,5	0,0	5,2	0,0	0,0
21	2,3	49,0	10,9	0,0	3,9	0,0	0,0
22	2,3	46,9	11,2	0,0	4,6	0,1	0,0
23	2,3	47,6	10,1	0,1	4,6	0,1	0,0
24	2,3	48,3	9,1	0,2	4,3	0,0	0,0
25	2,4	48,4	10,2	0,3	4,4	0,0	0,0
26	2,3	49,0	11,5	0,0	4,0	0,0	0,0
27	2,3	48,6	11,9	0,5	5,0	0,0	0,0

Amostra	Calcita	Escória	R28 observada	R28 predita
	(%)	(%)	(MPa)	(MPa)
1	8,6	7,6	48,1	48,1
2	10,5	8,9	48,1	50,3
3	9,1	6,5	48,2	48,8
4	8,3	14,6	51,9	50,3
5	8,0	10,5	48,1	48,1
6	8,5	8,9	53,0	49,1
7	9,1	8,7	51,7	50,1
8	5,5	8,8	49,6	48,6
9	9,6	9,1	51,9	50,5
10	9,6	12,0	50,7	50,6
11	8,0	8,1	51,7	50,1
12	9,8	7,1	52,9	50,7
13	9,8	8,8	49,7	50,7
14	8,4	8,3	52,4	50,7
15	7,3	10,9	49,5	50,6
16	9,1	5,7	51,0	50,6
17	9,7	5,3	52,1	50,3
18	9,2	5,7	51,2	49,3
19	8,6	6,0	49,0	50,7
20	9,8	9,9	52,5	50,7
21	8,5	8,3	53,4	50,6
22	9,8	7,1	50,3	50,5
23	9,0	9,3	51,6	49,8
24	9,5	8,7	50,3	50,4
25	9,2	8,3	49,4	48,6
26	9,1	6,5	50,0	50,7
27	8,0	7,2	51,0	48,5

Neurônio	Wi							
	R7 (MPa)	Fim de pega (min)	Resíduo insolúvel (%)	SiO ₂ (%)	Fe ₂ O ₃ (%)	MgO (%)	K ₂ O (%)	MS
1	-4,4896	-4,6145	-1,7468	0,1865	-0,8821	-0,1855	2,1092	2,5139
2	-1,9904	-2,0380	-0,1194	-1,1607	-0,8048	0,2708	-0,1483	-1,1061
3	-4,5677	-5,3003	-1,3359	-0,2809	0,2885	-0,3135	2,6629	2,7206
4	-5,5198	-1,3872	-2,2580	-0,6383	-0,3842	-1,7624	3,0056	1,7584

Neurônio	Wi							
	Alita (%)	Belita (%)	C ₃ A ortorrômbico (%)	C ₃ A cúbico (%)	Aftalitita (%)	Langbeinita (%)	Calcita (%)	Escória (%)
1	1,0598	-0,3761	-1,7890	0,4314	-2,0469	-0,1111	-1,2254	-1,5011
2	-0,5396	-1,2940	0,4836	-0,9070	-0,6113	1,0002	-1,5013	-1,2446
3	-0,4517	-1,2591	-1,2957	2,2492	-2,5216	-0,5095	-1,2550	-1,5378
4	0,3836	-0,4047	1,9390	3,9131	-4,1150	1,2257	-2,3954	-1,8266

Neurônio	Wh
1	-2,8702
2	-0,1861
3	-3,6906
4	-3,4786

Neurônio	Teta
1	1,2084
2	0,5299
3	1,2001
4	1,2228
Bias	0,0000