

UNIVERSIDADE ESTADUAL PAULISTA

Instituto de Geociências e Ciências Exatas

Campus de Rio Claro

LUCIANO FERRO

**APLICAÇÃO DA REDE NEURAL MLP (MULTILAYER PERCEPTRON) EM
INDÚSTRIA DE PISOS E REVESTIMENTOS DO PÓLO CERÂMICO DE SANTA
GERTRUDES – SP**

Tese de Doutorado apresentada ao Instituto de Geociências e Ciências Exatas do Campus de Rio Claro, da Universidade Estadual Paulista Júlio de Mesquita Filho, como parte dos requisitos para obtenção do título de Doutor em Geociências e Meio Ambiente

Orientador: Prof. Dr. José Ricardo Sturaro

Rio Claro – SP

2013

006.32 Ferro, Luciano
F395a Aplicação da rede neural MLP (Multilayer Perceptron) em
indústria de pisos e revestimentos do pólo cerâmico de Santa
Gertrudes - SP / Luciano Ferro. - Rio Claro, 2013
143 f. : il., figs., gráfs., tabs.

Tese (doutorado) - Universidade Estadual Paulista,
Instituto de Geociências e Ciências Exatas
Orientador: José Ricardo Sturaro

1. Redes neurais (Computação). 2. Redes neurais
artificiais. 3. Rede MLP. 4. Argila. 5. Variáveis físicas. I.
Título.

COMISSÃO EXAMINADORA

Dr. JOSÉ RICARDO STURARO
IGCE/UNESP/Rio Claro (SP)

Dr. PAULO MILTON BARBOSA LANDIM
IGCE/UNESP/Rio Claro (SP)

Dr. RICARDO EGYDIO DE CARVALHO
IGCE/UNESP/Rio Claro (SP)

Dr. ALESSANDRO FIRMIANO DE JESUS
Divisão de Ensino/Academia da Força Aérea/Pirassununga (SP)

Dr. ALEXANDRE CAMPANE VIDAL
IG/UNICAMP/Campinas (SP)

Doutorando: LUCIANO FERRO

RESULTADO: APROVADO

Data da Defesa: 25/04/2013

DEDICATÓRIA

Aos meus familiares e, em especial, à Maria, ao Gastone e Violetta (in memoriam), e Claudia, Rodrigo, Giovanna e Gustavo.

AGRADECIMENTOS

Ao Prof. Dr. José Ricardo Sturaro pela orientação deste trabalho, pela dedicada amizade e confiança, pelo apoio e estímulos e pelos conhecimentos transmitidos.

À COPEMA (Comissão Permanente do Magistério), da Academia da Força Aérea, pelo apoio e pelas facilidades concedidas para que pudéssemos concluir este trabalho.

Aos professores e funcionários do Instituto de Geociências e Ciências Exatas da UNESP de Rio Claro (SP) pelo apoio, incentivos e ensinamentos transmitidos.

Aos colegas de curso Luiz Batista Castanheira, Natale Chierice Júnior e Roseli Aparecida Fernandes Chierice pela amizade e incentivos e ao Rogers R. da Rocha, proprietário das Cerâmicas Triunfo e Rochaforte que, além da amizade, proporcionou os materiais e os resultados das variáveis físicas, da sua tese de doutorado, para a nossa consequente aplicação através das Redes Neurais Artificiais.

Ao Sr. Mario Castellano Pieroni, da Mineração Pieroni Ltda., aos Srs. Antonio Vitti, Antonio Cláudio Vitti e Fábio Ramos Vitti, da Santa Amábilis Agropecuária e Mineração Ltda., ambas de Rio Claro, por permitirem a visita e a tomada de fotos das minas para este trabalho. Ao amigo Aldo José Colabone, Diretor de Meio Ambiente da Santa Amábilis Agropecuária e Mineração Ltda., por ter intermediado a permissão das visitas e ao seu técnico ceramista Sérgio Antonio Castilho.

A todos aqueles que, de alguma forma, colaboraram para a realização deste trabalho.

RESUMO

As Redes Neurais Artificiais se constituem numa alternativa à computação programada tradicional e foram aplicadas em quase todos os ramos do conhecimento humano. Em Geotecnologia, no entanto, ainda são escassas as aplicações de maneira que, com este trabalho, procura-se mostrar que elas também podem ser aplicadas em indústrias de pisos e revestimentos cerâmicos do Pólo Cerâmico de Santa Gertrudes, Estado de São Paulo. Para isso, foram utilizados corpos-de-prova elaborados, testados e analisados nas indústrias Triunfo Cerâmica e Rochaforte Cerâmica, com argilas oriundas de nove minas da região que constitui o Pólo Cerâmico de Santa Gertrudes, dentre aquelas que representavam toda a coluna estratigráfica da Formação Corumbataí com amostras bem diferenciadas. Os dados obtidos relativos às variáveis físicas foram gentilmente cedidos pelo proprietário das indústrias acima citadas e as variáveis físicas usadas neste estudo são a Densidade de Prensagem (DP), a Densidade Aparente de Corpos-de-Prova Secos (DAS), a Retração Linear de Secagem (RLS), a Retração Linear de Queima (RLQ), a Perda ao Fogo (PF), a Carga de Ruptura (CR), a Absorção de Água (Abs) e o Módulo de Resistência à Flexão (MRF). Para a análise, os corpos-de-prova foram submetidos a quatro temperaturas de queima 1000°C, 1020°C, 1040°C e 1060°C, onde cada um destes valores deu origem a uma rede neural MLP (Multilayer Perceptron) de três camadas, para as quais foi usada a Regra do Aprendizado de Retropropagação do Erro (Backpropagation, do original em inglês).

Palavras-chave: redes neurais artificiais, rede MLP, argila e variáveis físicas.

ABSTRACT

Artificial Neural Networks constitute an alternative to traditional programmed computation and have been applied in almost all branches of human knowledge. However, they are rarely applied in Geotechnology, so this work aims to show that they can be applied in the flooring and ceramic tile industries in the Principal Ceramic Region of Saint Gertrudes, São Paulo State. For this purpose, proof specimens elaborated, tested and analyzed in the industries of Triunfo Cerâmica and Rochaforte Cerâmica were used. These proof specimens were composed of well differentiated clays from nine mines in the Principal Ceramic Region of Saint Gertrudes, and these mines are representative of all the stratigraphic column of the Corumbataí Formation. The data relative to physical variables were graciously provided by the owner of the above mentioned industries, and the physical variables used in this study are Pressing Density (DP), Bulk Density of Dry Specimens (DAS), Linear Shrinkage Drying (RLS), Linear Shrinkage Firing (RLQ), Loss on Ignition (PF), Tensile Strength (CR), Water Absorption (Abs) and Flexural Modulus of Resistance (MRF). For analysis, the proof specimens were subjected to four firing temperatures, 1000° C, 1020° C, 1040° C and 1060°C. Each one of these values gave rise to a neural network MLP (Multilayer Perceptron) of three tiers for which the Backpropagation rule of learning was used.

Key words: artificial neural networks, MLP network, clay and physical variables.

LISTA DE FIGURAS

Figura 1 - O Neurônio Biológico Natural.....	21
Figura 2 - Uma rede direta.....	23
Figura 3 - Um neurônio artificial.....	25
Figura 4 - A função logística e a sua derivada.	25
Figura 5 - A função tangente hiperbólica e a sua derivada.	26
Figura 6 - O neurônio de McCulloch/Pitts.	28
Figura 7 - O Perceptron de Rosenblatt.	29
Figura 8 - Uma rede direta de três camadas.	34
Figura 9 - Fotos da mina Pieroni.	46
Figura 10 - Fotos da mina Santa Amábile.	47
Figura 11 - Resultado encontrado para os dados do ANEXO E, com N = 7 e 242 epochs.	59
Figura 12 - Resultado encontrado para os dados do ANEXO E, com N = 34 e 164 epochs.	62
Figura 13 - Resultado encontrado para os dados do ANEXO F, com N = 27 e 88 epochs.....	66
Figura 14 - Resultado encontrado para os dados do ANEXO F, com N = 33 e 83 epochs.....	67
Figura 15 - Resultado encontrado para os dados do ANEXO F, com N = 90 e 60 epochs.....	68
Figura 16 - Resultado encontrado para os dados do ANEXO G, com N = 27 e 85 epochs.	70
Figura 17 - Resultado encontrado para os dados do ANEXO G, com N = 33 e 82 epochs.	71
Figura 18 - Resultado encontrado para os dados do ANEXO G, com N = 34 e 73 epochs.	72
Figura 19 - Resultado encontrado para os dados do ANEXO H, com N = 38 e 215 epochs...	74
Figura 20 - Resultado encontrado para os dados do ANEXO H, com N = 38 e 94 epochs.	75
Figura 21 - Resultado encontrado para os dados do ANEXO H, com N = 40 e 127 epochs.	76
Figura 22 - Resultado encontrado para os dados do ANEXO H, com N = 40 e 126 epochs...	77
Figura 23 - Resultado encontrado para os dados do ANEXO H, com N = 40 e 118 epochs...	78
Figura 24 - Resultado encontrado para os dados do ANEXO H, com N = 40 e 78 epochs.	79
Figura 25 - Resultado encontrado para os dados do ANEXO I, com N = 56 e 64 epochs.....	84
Figura 26 - Resultado encontrado para os dados do ANEXO I, com N = 58 e 158 epochs.....	85
Figura 27 - Resultado encontrado para os dados do ANEXO I, com N = 60 e 263 epochs.....	86
Figura 28 - Resultado encontrado para os dados do ANEXO I, com N = 60 e 269 epochs.....	87
Figura 29 - Resultado encontrado para os dados do ANEXO J, com N = 60 e 80 epochs.	89
Figura 30 - Resultado encontrado para os dados do ANEXO J, com N = 62 e 74 epochs.	90
Figura 31 - Resultado encontrado para os dados do ANEXO J, com N = 62 e 81 epochs.	91
Figura 32 - Resultado encontrado para os dados do ANEXO J, com N = 63 e 66 epochs.	92
Figura 33 - Resultado encontrado para os dados do ANEXO J, com N = 65 e 75 epochs.	93

Figura 34 - Resultado encontrado para os dados do ANEXO J, com N = 65 e 167 epochs. ...	94
Figura 35 - Resultado encontrado para os dados do ANEXO K, com N = 55 e 76 epochs.	96
Figura 36 - Resultado encontrado para os dados do ANEXO K, com N = 55 e 92 epochs.	97
Figura 37 - Resultado encontrado para os dados do ANEXO K, com N = 65 e 65 epochs.	98
Figura 38 - Resultado encontrado para os dados do ANEXO K, com N = 67 e 69 epochs.	99
Figura 39 - Resultado encontrado para os dados do ANEXO K, com N = 67 e 97 epochs. ...	100
Figura 40 - Resultado encontrado para os dados do ANEXO K, com N = 70 e 81 epochs. ...	101
Figura 41 - Resultado encontrado para os dados do ANEXO K, com N = 71 e 60 epochs. ...	102

LISTA DE TABELAS

Tabela 1 - Classificação das placas cerâmicas quanto à porosidade	40
Tabela 2 - Especificações da NBR 13818 (ABNT, 1997).....	41
Tabela 3 - Coordenadas UTM obtidas por GPS das minas estudadas (Datum: SAD 69).....	43
Tabela 4 - Médias dos ANEXOS A, B, C e D, média geral e o padrão de produto estabelecido neste trabalho.....	51
Tabela 5 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 7 e 242 epochs.	61
Tabela 6 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 34 e 164 epochs.	63
Tabela 7 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 35 e 122 epochs.	63
Tabela 8 - Aplicação do método resiliente aos dados do ANEXO F.	64
Tabela 9 - Complementação da TABELA 8.	65
Tabela 10 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 27 e 88 epochs.	66
Tabela 11 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 33 e 83 epochs.	67
Tabela 12 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 90 e 60 epochs.	68
Tabela 13 - Aplicação do método resiliente aos dados do ANEXO G.....	69
Tabela 14 - Complementação dos dados da TABELA 13.	69
Tabela 15 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 27 e 85 epochs.	71
Tabela 16 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 33 e 82 epochs.	72
Tabela 17 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 34 e 73 epochs.	73
Tabela 18 - Aplicação do método resiliente aos dados do ANEXO H.....	73
Tabela 19 - Complementação dos dados da TABELA 18.	74
Tabela 20 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 38 e 215 epochs.	75
Tabela 21 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 38 e 94 epochs.	76
Tabela 22 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 40 e 127 epochs.	77
Tabela 23 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 40 e 126 epochs.	78

Tabela 24 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 40 e 118 epochs.	79
Tabela 25 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 40 e 78 epochs.	80
Tabela 26 - Aplicação do método resiliente aos dados do ANEXO I.	82
Tabela 27 - Complementação dos dados da TABELA 26.	83
Tabela 28 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 56 e 64 epochs.	84
Tabela 29 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 58 e 158 epochs.	85
Tabela 30 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 60 e 263 epochs.	86
Tabela 31 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 60 e 269 epochs.	87
Tabela 32 - Aplicação do método resiliente aos dados do ANEXO J.	88
Tabela 33 - Complementação dos dados da TABELA 32.	88
Tabela 34 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 60 e 80 epochs.	89
Tabela 35 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 62 e 74 epochs.	90
Tabela 36 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 62 e 81 epochs.	91
Tabela 37 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 63 e 66 epochs.	92
Tabela 38 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 65 e 75 epochs.	93
Tabela 39 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 65 e 167 epochs.	94
Tabela 40 - Aplicação do método resiliente aos dados do ANEXO K.	95
Tabela 41 - Complementação dos dados da TABELA 40.	95
Tabela 42 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 55 e 76 epochs.	97
Tabela 43 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 55 e 92 epochs.	98
Tabela 44 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 65 e 65 epochs.	99
Tabela 45 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 67 e 69 epochs.	100
Tabela 46 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 67 e 97 epochs.	101

Tabela 47 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 70 e 81 epochs.	102
Tabela 48 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 71 e 60 epochs.	103
Tabela 49 - Bloco B1 da matriz IW, fórmula (4.9).	106
Tabela 50 - Bloco B2 da matriz IW, fórmula (4.9).	107
Tabela 51 - Bloco B3 da matriz IW, fórmula (4.9).	108
Tabela 52 - Bloco B4 da matriz IW, fórmula (4.9).	109
Tabela 53 - Cálculo dos desvios, D(%), para os valores da TABELA 46.....	110
Tabela 54 - Cálculo dos desvios, D(%), para os valores da TABELA 47.....	111
Tabela 55 - Bloco B1 da matriz IW , fórmula (4.12).	112
Tabela 56 - Bloco B2 da matriz IW, fórmula (4.12).	113
Tabela 57 - Bloco B3 da matriz IW, fórmula (4.12).	114
Tabela 58 - Bloco B4 da matriz IW, fórmula (4.12).	115
Tabela 59 - Bloco B5 da matriz IW, fórmula (4.12).	116
Tabela 60 - Bloco B6 da matriz IW, fórmula (4.12).	117

LISTA DE ANEXOS

Anexo A - Variáveis físicas obtidas na temperatura de queima de 1000°C.....	133
Anexo B - Variáveis físicas obtidas na temperatura de queima de 1020°C.....	134
Anexo C - Variáveis físicas obtidas na temperatura de queima de 1040°C.....	135
Anexo D - Variáveis físicas obtidas na temperatura de queima de 1060°C.....	136
Anexo E - Variáveis físicas obtidas na temperatura de queima de 1000°C. (Minas CF, CR, PG, PT e PI).....	137
Anexo F - Variáveis físicas obtidas na temperatura de queima de 1020°C. (Minas CF, CR, PG, PT e PI).....	138
Anexo G - Variáveis físicas obtidas na temperatura de queima de 1040°C. (Minas CF, CR, PG, PT e PI).....	139
Anexo H - Variáveis físicas obtidas na temperatura de queima de 1060°C. (Minas CF, CR, PG, PT e PI).....	140
Anexo I - Variáveis físicas obtidas na temperatura de queima de 1020°C. (Minas CF, CR, PG, PT, PI e TU).....	141
Anexo J - Variáveis físicas obtidas na temperatura de queima de 1040°C. (Minas CF, CR, PG, PT, PI e TU).....	142
Anexo K - Variáveis físicas obtidas na temperatura de queima de 1060°C. (Minas CF, CR, PG, PT, PI e TU)	143

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
Abs	Absorção de Água
APL	Arranjo Produtivo Local
ASPACER	Associação Paulista das Cerâmicas de Revestimento
CF 1	Cristofolletti Mina 1
CF 2	Cristofolletti Mina 2
CR	Carga de Ruptura
CR 1	Cruzeiro Frente 1
CR 2	Cruzeiro Frente 2
DAS	Densidade Aparente de Corpos de Prova Secos
DP	Densidade de Prensagem
GPS	<i>Global Positioning System</i> ou Sistema de Posicionamento Global
MRF	Módulo de Resistência à Flexão
PCSG	Pólo Cerâmico de Santa Gertrudes
PF	Perda ao Fogo
PG	Mina Paganoti
PI	Mina Pieroni
PT 1	Partezani Mina 1
PT 2	Partezani Mina 2
PT 3	Partezani Mina 3
RLQ	Retração Linear de Queima
RLS	Retração Linear de Secagem
TU	Mina Tute
UTM	Sistema Universal de Coordenadas Transverso de Mercator

SUMÁRIO

1.	INTRODUÇÃO.....	16
1.1.	Objetivo Geral e Hipótese.....	17
1.2.	Estrutura.....	18
2.	REVISÃO BIBLIOGRÁFICA.....	19
2.1.	O Neurônio Biológico Natural.....	19
2.2.	As Redes Neurais Artificiais.....	21
2.3.	Breve Histórico sobre as Redes Neurais Artificiais.....	27
2.4.	Regra Delta e Regra Delta Generalizada	32
2.4.1.	Regra Delta.....	32
2.4.2.	Regra Delta Generalizada.....	33
3.	MATERIAIS E MÉTODOS.....	39
3.1.	O Pólo Cerâmico de Santa Gertrudes	39
3.2.	Caracterização das Argilas e das Cerâmicas.....	39
3.3.	Os Corpos-de-Prova.....	43
3.4.	Determinação das Variáveis Físicas dos Corpos-de-Prova.....	48
3.5.	Metodologia	50
4.	RESULTADOS E DISCUSSÕES.....	55
4.1.	Introdução	55
4.2.	Regra de Aprendizado <i>Backpropagation</i> (Formato Básico).....	55
4.3.	Regra de Aprendizado <i>Backpropagation</i> com Momento (<i>traingdm</i>)	57
4.4.	Regra de Aprendizado <i>Backpropagation</i> Resiliente (<i>trainrp</i>)	58
4.5.	Regra de Aprendizado <i>Backpropagation</i> de Levenberg-Marquadt (<i>trainlm</i>).....	103
4.6.	Conclusões	104
5.	CONSIDERAÇÕES FINAIS	121
	REFERÊNCIA BIBLIOGRÁFICA.....	123
	BIBLIOGRAFIA COMPLEMENTAR.....	127
	ANEXOS	132

1. INTRODUÇÃO

Para uma exploração economicamente viável e sustentada dos recursos minerais e sua consequente industrialização com uma minimização, na medida do possível, dos impactos causados inevitavelmente ao meio ambiente, há atualmente a possibilidade de se aplicar alguns dos modernos conceitos da Matemática, da Estatística, da Computação. Neste trabalho, consideram-se a mineração de argila e, em especial, a industrialização correspondente de pisos e revestimentos cerâmicos da região do Estado de São Paulo denominada de Pólo Cerâmico de Santa Gertrudes (PCSG) formado pelos municípios de Limeira, Cordeirópolis, Rio Claro, Ipeúna, Piracicaba, Araras e Santa Gertrudes. Este segmento da indústria, conforme dados da Associação Paulista das Cerâmicas de Revestimento, ASPACER, (ASPACER, 2012), é responsável por aproximadamente 15000 empregos diretos e 200000 empregos indiretos. Está inserido no Arranjo Produtivo Local (APL) de Pisos e Revestimentos Cerâmicos de Santa Gertrudes, o qual de acordo com Poletto (2007), é o maior produtor da América Latina e o quarto maior do mundo. É formado por indústrias de pequeno e de médio porte, utiliza basicamente o processo de monoqueima rápida, com produção, preponderantemente, pela chamada Via Seca usando argilas de boa qualidade.

A preocupação com o meio ambiente tem-se intensificado sobremaneira nos últimos anos em vista das recentes pesquisas sobre a poluição das águas e da atmosfera, a ocupação dos espaços nas terras e nos mares, o desmatamento das florestas remanescentes, a exploração dos recursos minerais disponíveis, recursos estes indispensáveis à espécie humana.

Paralelamente, a indústria de transformação procura meios para aumentar a produção diminuindo os custos dos processos produtivos, aumentando os lucros e melhorando a qualidade do seu produto final. Atualmente, ela também busca por certificações ambientais como uma forma de demonstrar que também está consciente dos impactos ambientais que ela mesma provoca ao meio ambiente, utilizando-se para isso de medidas mitigadoras (planos de recuperação, de remediação, de reabilitação), mesmo que, às vezes, de forma incipiente, apesar dos baixos custos, quando bem planejadas. Contudo, persistem ainda os conflitos entre as mineradoras e indústrias e a comunidade onde elas estão inseridas. Se, por um lado, as mineradoras e as indústrias provocam a poluição ambiental, por outro lado promovem o desenvolvimento econômico gerando empregos e renda, que são muito importantes para a população. O controle de qualidade do produto final, o controle de qualidade nos processos e nos mecanismos de industrialização associados a uma diminuição do consumo de energia

podem ser, quando bem planejados, instrumentos de promoção na busca pelas certificações ambientais.

Dentro deste contexto, pode-se admitir que com a escassez de aplicações do conceito estatístico-matemático das Redes Neurais Artificiais (RNAs) na indústria cerâmica, vislumbrou-se um farto e interessante material para esta pesquisa, tendo em vista que com este conceito pode-se estabelecer com bastante rigor o valor das variáveis, dentro dos seus próprios limites de tolerância de especificação, estabelecidos pela Associação Brasileira de Normas Técnicas (ABNT), as quais determinam as características do produto final, no caso, piso e revestimento cerâmico. Ademais, dentro das sete ferramentas estatísticas para o controle de qualidade de um produto industrial introduzidas por Kaoru Ishikawa, podem ser estabelecidos o limite inferior de controle e o limite superior de controle com valores bem próximos um do outro, diminuindo sensivelmente a amplitude do intervalo. Para este propósito será utilizado o software MATLAB® (MATrix LABoratory) 7.0, da “MathWorks, Inc.” – User’s Guide : Neural Networks Toolbox.

Originariamente, em função dos dados e do problema apresentados, delimitou-se a aplicação entre o conceito das RNAs e o conjunto de técnicas de otimização conhecido como Metodologia de Superfície de Resposta, introduzido por G. E. P. Box e K. B. Wilson no início dos anos cinquenta do século passado, já que ambos se inserem, em alguns casos, no conceito de Aproximação de Funções da Análise Numérica.

A escolha recaiu sobre as RNAs tendo em vista a facilidade de aplicação, o baixo custo para a obtenção e o rigor na determinação das especificações do produto industrial, o qual é o próprio padrão de saída da RNA.

1.1. Objetivo Geral e Hipótese

O objetivo geral deste trabalho é o de encontrar uma rede neural artificial, dentre as várias arquiteturas e as diversas regras de aprendizado, aquela que melhor se adapta para maximizar o aproveitamento das argilas na indústria cerâmica do PCSG e melhorar a qualidade dos pisos e revestimentos cerâmicos ali produzidos, mediante uma rigorosa caracterização.

Este objetivo geral é consequência da seguinte hipótese:

“Mostrar que é possível aplicar o conceito das redes neurais artificiais na indústria de pisos e revestimentos cerâmicos”.

1.2. Estrutura

Este trabalho foi dividido em cinco capítulos, onde, além deste introdutório, no Capítulo 2, será desenvolvida uma revisão bibliográfica sobre o conceito estatístico-matemático das Redes Neurais Artificiais, dentro daquilo que se concebeu como Inteligência Artificial.

Em seguida, no Capítulo 3, serão apresentados os materiais utilizados, a localização das minas e a metodologia usada.

No Capítulo 4, serão comentados e discutidos os resultados encontrados com a aplicação da rede neural artificial MLP (*Multilayer Perceptron*), mostrando que, de fato, elas podem ser utilizadas, inclusive em futuro próximo, para melhorar a qualidade dos pisos e revestimentos cerâmicos dentro das especificações técnicas do produto já previamente estabelecidas. Finalizando este capítulo, foi acrescentado um roteiro para os interessados em aplicar as RNAs.

No Capítulo 5, serão mostradas as conclusões encontradas e feitas as considerações finais com sugestões para trabalhos futuros.

Por fim, são indicados na Referência Bibliográfica os livros, os artigos e outras publicações e as publicações pesquisadas junto à rede “internet”, usados neste trabalho. Foi também acrescentada uma Bibliografia Complementar, importante para o entendimento das RNAs.

2. REVISÃO BIBLIOGRÁFICA

2.1. O Neurônio Biológico Natural

O cérebro humano é constituído principalmente por dois tipos diferentes de células, as células glias e os neurônios. As células glias, com um número aproximado dez vezes maior do que o número de neurônios, são responsáveis pela sustentação do cérebro, enquanto os neurônios são basicamente as unidades ou elementos de processamento dos sinais (ou pulsos) e estímulos que recebe e sobre eles estão concentrados os principais estudos no sentido de se simular ou de se modelar mediante um algoritmo o seu comportamento. O neurônio é constituído por um corpo celular ou soma, pelo axônio e pelos dendritos. O cérebro humano através da rede de neurônios e de suas interconexões, onde ocorrem sinapses, é responsável pelo pensamento, emoção, cognição. As sinapses ocorrem entre axônios de diferentes neurônios, entre o axônio e o soma e, também, entre os dendritos de um mesmo neurônio, segundo Wasserman (1989). Ainda, de acordo com o mesmo autor, o cérebro humano, que pesa somente 2% da massa corporal, consome 20% de todo o oxigênio liberado no corpo humano e somente de 20 a 30 W de potência para o seu saudável funcionamento.

É através das sinapses que um neurônio se interconecta a até outros 10.000 neurônios, num total de aproximadamente 100 bilhões de neurônios dentro do nosso cérebro. Eles não são todos idênticos, diferem quimicamente, estruturalmente ou funcionalmente e já foram encontrados mais de 250 tipos diferentes de neurônios. A região intersináptica é eletroquimicamente ativa, local onde já foram descobertas mais de 50 substâncias químicas que executam a rápida intercomunicação, via corrente iônica, entre um neurônio pré-sináptico e um pós-sináptico, por isso essas substâncias são denominadas apropriadamente de neurotransmissores.

A membrana do neurônio é de grande importância, em função da intensa intercomunicação neuronal, porque é através dela que os neurotransmissores atuam podendo ser excitadores quando a despolarizam mediante a atuação do potencial elétrico de ação ou impulso nervoso ou podendo ser inibidores quando a hiperpolarizam, visto que em repouso a membrana encontra-se a -70 mV, segundo Eccles (1957). A complexidade do funcionamento de um único neurônio reside, principalmente, no fato de que a concentração dos neurotransmissores depende cada um deles de uma série de fatores que até o presente momento não são bem conhecidos e por isso encontra-se, ainda, em fase de intensos estudos.

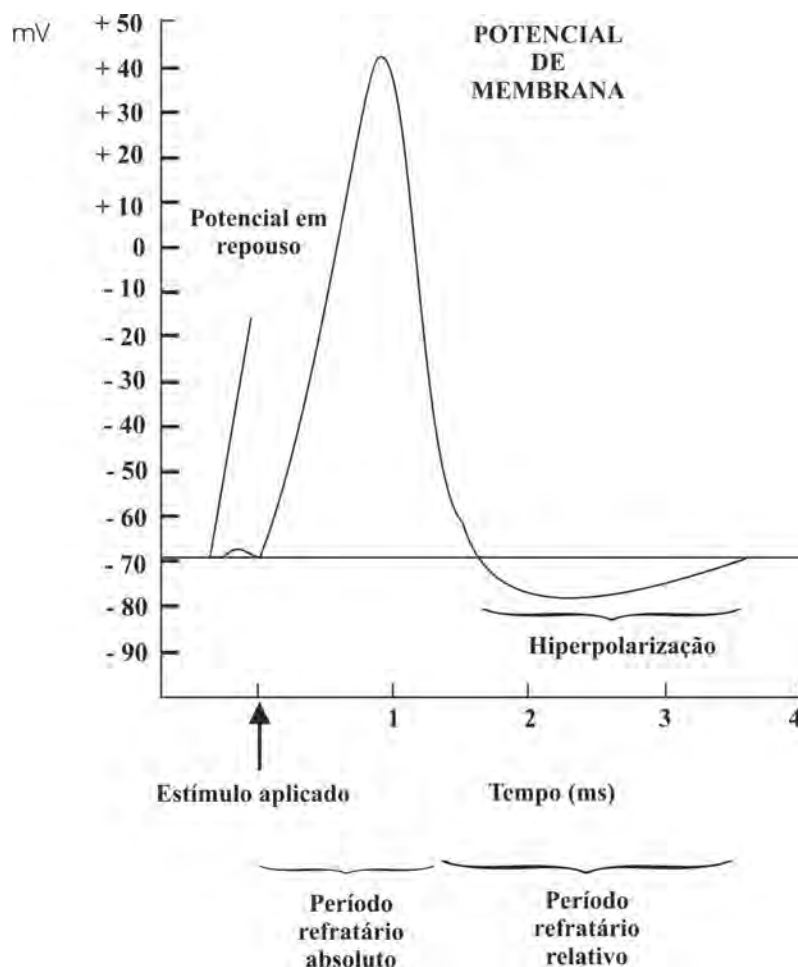
É importante observar que o mesmo neurotransmissor pode ser excitatório para uma sinapse e inibitório para outra, de acordo com Wasserman (1989).

O neurônio foi identificado pelo neurologista espanhol Ramón y Cajal; as suas manifestações elétricas foram observadas pela primeira vez por DuBois Reymond, com o auxílio de galvanômetros (KOVÁCS, 2002). Identificado pelo pesquisador E. D. Adrian, o potencial de ação consiste em um pacote de ondas e é obtido pela despolarização da membrana do neurônio com o auxílio da chamada *bomba de sódio/potássio*, a qual permite a entrada do sódio e a consequente saída do potássio. Depois de emitido o impulso, ocorre a hiperpolarização com os íons fazendo o caminho inverso. Toda esta operação ocorre no intervalo de tempo de 1 a 3 ms, com a superposição de um período refratário e um estado de repouso ou relaxação, o que impossibilita uma retomada pelo neurônio de um novo impulso durante esse período de tempo (WASSERMAN, 1989), como pode ser visto na Figura 1. O neurônio natural apresenta muitas entradas (conexões sinápticas), mas uma só saída (um único impulso nervoso), de forma que, dependendo dos sinais ou estímulos que recebe, um neurônio pode ou não emitir um pulso. A superposição de todos esses sinais ou estímulos, excitatórios ou inibitórios, é o que constitui a atividade cerebral.

Os neurônios organizados em sistemas são adaptativos, visto que com mudanças nas interconexões sinápticas, eles aprendem e se auto-organizam fazendo emergir ordem da desordem e, também, o que é mais importante, estes sistemas apresentam propriedades coletivas (memória), mediante a competição e cooperação entre os neurônios constituintes, as quais diferem das propriedades individuais.

O cérebro humano é um sistema dinâmico complexo com uma grande quantidade de elementos organizados em sistemas que, por sua vez, também se organizam em outros sistemas cada vez mais complexos, de maneira similar à própria origem da vida e a evolução das espécies, conforme Damásio (1996). De acordo com Haykin (2001), o cérebro humano processa informações como se fosse um computador altamente complexo, não linear e paralelo. Em função dessa complexidade, atualmente há pelo menos dois grandes ramos da neurociência; o primeiro que estuda a estrutura e o funcionamento dos sistemas nervosos da maneira como interessam aos biólogos e aos profissionais de estudos correlacionados, enquanto que o segundo estuda o processamento computacional dos dados de maior interesse para os físicos e matemáticos no intuito de se construir computadores úteis ou máquinas mais efetivas, segundo Nussenzveig (1999).

Figura 1 - O potencial de ação durante a aplicação de um estímulo nervoso.



Fonte: Disponível em: < <http://faculty.washington.edu.chudler/ap.html> >.
Acesso em: 03 mar. 2007. Tradução nossa.

2.2. As Redes Neurais Artificiais

As redes neurais artificiais, constituídas de neurônios artificiais em analogia com os neurônios naturais humanos, são modelos estatístico-matemáticos que buscam simular alguns processos biológicos do Sistema Nervoso Central. Elas são modelos adaptáveis, da mesma maneira que os neurônios naturais, e é dessa forma que devemos entendê-las, pois através da variação de alguns parâmetros de controle elas conseguem aprender e, conseqüentemente, realizar operações de controle, de classificação e de reconhecimento de padrões previamente fixados. A simulação deve ser feita com o auxílio de algoritmos e de programas computacionais. Estes modelos surgiram na mesma época em que foram construídos os primeiros computadores, década de 40 do século passado, para se lidar com problemas complexos, especialmente, aqueles da teoria matemática dos sistemas dinâmicos, onde grande

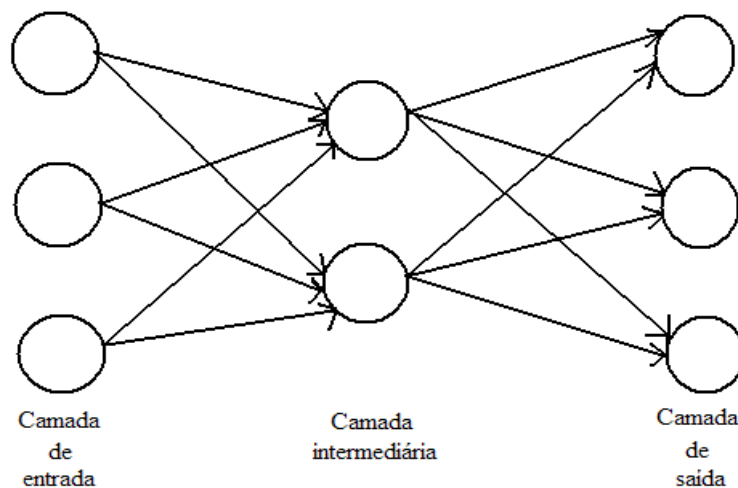
quantidade de dados deve ser modelada e analisada estatisticamente e computacionalmente, de acordo com Abdi et al. (1999), Haykin (2001), Kovács (2002) e Braga et al. (2007). As RNAs constituem uma alternativa à computação programada tradicional conduzida pela elaboração de um algoritmo, por um conjunto de rotinas e por uma sólida base lógica, visto que são capazes de reagir e de se auto-organizar; elas aprendem, sua maior virtude, mas, infelizmente, como qualquer ser humano, também esquecem. Elas são capazes de gerar as suas próprias regras e é importante ressaltar que no processo de adaptação elas podem gerar regras internas desconhecidas. São muito utilizadas, em função destas características, como simulação dos processos mentais na ciência da cognição, conforme Abdi et al.(1999), Haykin (2001) e Braga et al. (2007). Braga et al. (2007) ressaltam que as redes neurais são utilizadas em sistemas de processamento paralelo e distribuído.

A ideia original foi a de se aproximar o máximo possível do funcionamento dos sistemas de neurônios humanos, mas apesar de todo o avanço tecnológico que se seguiu e da sua rápida transferência aos modernos computadores, esta ideia teve que ser deixada de lado, pois paralelamente avançou-se também na compreensão da fisiologia de um único neurônio biológico, onde se percebeu que o seu funcionamento era demasiadamente complexo, o qual reunido a outros neurônios em estruturas cada vez mais complexas dentro do Sistema Nervoso Central ainda não permite que esta desejada aproximação se concretize. No entanto, o estudo das redes neurais artificiais revelou-se muito importante na resolução de problemas de controle, pois mesmo quando a informação é parcial, a rede pode escolher um padrão (ou informação de saída) mais próximo ao desejado, pois uma característica muito importante das redes neurais é a de que elas são tolerantes a falhas (NUSSENZVEIG, 1999). As redes neurais, atualmente, são aplicadas em inúmeros campos do conhecimento humano, onde se destacam a filtragem de ruídos (em telefonia), a análise do eletrocardiograma e do eletroencefalograma, a compressão de imagens e a realização de efeitos especiais na indústria de entretenimento, a simulação de vôo e dos sistemas de controle de aviões na indústria aeroespacial, a avaliação da aplicação de créditos no sistema bancário. Mas, conforme foi salientado no capítulo anterior, há poucas aplicações notadamente na indústria cerâmica, objeto deste estudo.

Na constituição de uma rede neural artificial, as unidades ou elementos de processamento, denominados apropriadamente de neurônios artificiais, são organizados basicamente em camadas: uma camada de entrada, que recebe os dados ou padrão de entrada, uma camada de saída, que fornece as respostas da rede ou padrão de saída, ambas interligadas

ao exterior e, entre elas, podem ser incluídas uma ou mais camadas chamadas de intermediárias ou ocultas (internas). A cada elemento de processamento é associado um peso sináptico, que é o responsável pelas conexões em uma analogia com a realidade das sinapses. É através das mudanças destes pesos sinápticos de ligação entre as conexões que uma rede neural aprende. Esta rede, pela sua arquitetura ou topologia, recebe o nome de rede direta ou *feedforward* ou, ainda, de acordo com Haykin (2001), rede alimentada para frente (Figura 2). Além desta, há outras arquiteturas ou topologias.

Figura 2 - Uma rede direta.



Fonte: Abdi et al. (1999).

A primeira simplificação introduzida no modelo do elemento de processamento foi a determinação de que cada neurônio podia assumir somente dois estados: ativo, quando o axônio emite um sinal ou inativo quando o axônio não emite sinal.

Uma rede neural artificial exhibe duas fases de operação: o aprendizado e a recapitulação. No aprendizado, os pesos sinápticos são adaptados ou modificados no sentido de se obter o resultado desejado. Quando a resposta (padrão de saída) é conhecida, diz-se que o aprendizado é supervisionado e quando a resposta não é conhecida, mas é esperada uma saída ótima para resolver o problema, diz-se que o aprendizado é não supervisionado, porque neste caso não há a necessidade de um supervisor (ou um professor) que encaminhe a rede para o resultado esperado. Complementando, a rede pode ser heteroassociativa quando o vetor (padrão) de saída for diferente do vetor (padrão) de entrada e autoassociativa quando eles forem iguais. Na fase de recapitulação (ou operação propriamente dita), tem-se que o

resultado é obtido em resposta a um dado exemplo, sem que ocorra qualquer modificação nos pesos das conexões, de acordo com Campanha (1994).

Em resumo, pode-se dizer que as características fundamentais de uma rede neural artificial são a sua arquitetura ou topologia (a forma como as unidades de processamento estão interligadas), as suas próprias unidades de processamento e as suas regras de aprendizado.

Quanto à arquitetura, dentre os vários tipos de redes, destacam-se as redes diretas ou *feedforward*, do original em inglês, ou rede alimentada adiante com camada única ou com múltiplas camadas, conforme denominação de Haykin (2001), onde os elementos de processamento aparecem interconectados em camadas sequencialmente colocadas da entrada até a saída, passando pelas camadas ocultas ou intermediárias (ou ainda, *hidden*) - que será utilizada neste trabalho -, e as redes recorrentes, em especial a rede de Hopfield, a qual é uma rede simétrica (a matriz dos pesos sinápticos é simétrica) com ciclos ou com realimentação (ou retroalimentação), como quando um neurônio se auto realimenta da mesma forma que um neurônio biológico natural.

Basicamente, uma unidade de processamento é constituída de vários sinais de entrada (x_1, \dots, x_n) , cada qual com o seu peso sináptico (conexão) associado (w_1, \dots, w_n) . A soma ponderada

$$\sum x_i \cdot w_i \tag{2.1}$$

é a entrada efetiva que dará origem a uma só saída. Se a soma ponderada (2.1) for superior a um limiar (*threshold*) previamente estabelecido, quando necessário, então o sinal de saída é gerado mediante a aplicação de uma função de transferência (ativação) ou função de saída do neurônio, a qual deve ser uma função que mais se aproxima do efeito de ativação do potencial de ação do neurônio natural. Pode ser estabelecida por qualquer função contínua, monotonicamente crescente, com imagens reais dentro dos intervalos $[0,1]$ ou $[-1,1]$. Caso contrário, se a soma (2.1) for inferior ao limiar, nada acontece, ou seja, não há sinal de saída (Figura 3).


As principais funções de transferência são: a função linear

$$f(x) = kx, \tag{2.2}$$

a função logística (Figura 4)


$$f(x) = (1 + e^{-kx})^{-1} \quad (2.3)$$

Figura 3 - Um neurônio artificial.



Fonte: Abdi et al. (1999).

Figura 4 – A função logística e a sua derivada.




Fonte: Ferro (2007).

e a função tangente hiperbólica (Figura 5),

$$f(x) = \tanh(kx). \quad (2.4)$$

Figura 5 – A função tangente hiperbólica e a sua derivada.



Fonte: Ferro (2007).

Em todas estas funções, k é uma constante (em especial, o MATLAB usa $k = 1$). As derivadas das duas últimas funções apresentam características sigmoidais.

De acordo com Abdi et al. (1999), o processamento do conhecimento é conseguido através das mudanças nos pesos das conexões (sinápticos) entre os elementos de processamento. Em termos estatísticos, este processo é equivalente à interpretação de que os valores dos pesos das conexões entre os elementos de processamento são parâmetros estimadores. O processo de aprendizado especifica o algoritmo usado para estimar esses parâmetros. O aprendizado, então, está ligado a uma regra que modifica ou adapta os pesos das conexões.

Em 1949, o neuropsicólogo Donald Hebb propôs a regra, chamada de Regra do Aprendizado de Hebb, a qual estabelece que “quando um axônio da célula A está próximo o suficiente para excitar uma célula B e repetidamente ou persistentemente a estimula, algum processo de crescimento ou mudança metabólica ocorre em uma ou em ambas as células de tal forma que a eficiência de A, como uma das células que estimula B, aumenta”, conforme Abdi et al. (1999), tradução nossa. Na década de 60, do século passado, B. Widrow e M. Hoff desenvolveram a Regra do Aprendizado Delta, que é baseada no método dos mínimos quadrados (WIDROW & HOFF, 1960), dentro daquilo que é chamado em matemática de ajustamento de curvas ou aproximação polinomial de funções; no caso particular em que o polinômio de aproximação é do primeiro grau, o método recebe o nome bem conhecido de

regressão linear. Neste método, o mínimo da função do erro acontece no vértice da sua superfície de resposta, visto que o erro de aproximação é quadrático com curva ou superfície de mínimo. A Regra de Aprendizado Delta foi generalizada por Rumelhart e outros pesquisadores, ainda na década de 80 do século passado, com o nome de Regra Delta Generalizada ou Regra de Retropropagação do Erro (*Backpropagation*), tornando-se a mais poderosa regra de aprendizado das redes neurais artificiais. Esta regra foi desenvolvida originalmente por P. Werbos, (1974), e redescoberta, independentemente, por D. Parker, (1982), Y. LeCun, (1985), e por Rumelhart et al., (1986), de acordo com os seus próprios idealizadores. Ela usa o método do gradiente descendente para a correção do erro. Como o gradiente é um vetor cujo sentido aponta sempre na direção do crescimento máximo da função sobre a qual ele é aplicado, quando o seu sentido é invertido, ele passa a apontar na direção do decréscimo máximo da função. Assim, o mínimo da função de erro, neste caso, depende do gradiente com sinal negativo. A Regra Delta e a Regra Delta Generalizada serão apresentadas ainda neste capítulo. Acrescentam-se a estas regras, dentre outras, a Regra de Aprendizagem de Kohonen, (KOHONEN, 1982), a Regra de Aprendizagem por Cooperação-Competição de von der Malsburg e Grossberg, segundo seus próprios criadores von der Malsburg (1973) e Grossberg (1976, 1980).

2.3. Breve Histórico sobre as Redes Neurais Artificiais

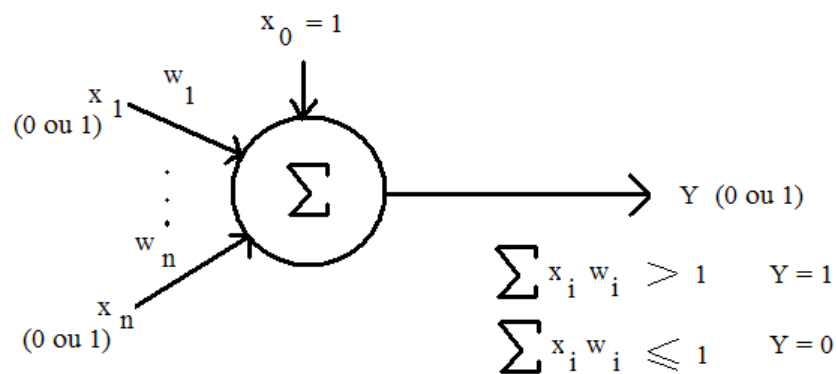
A seguir destacam-se os fatos históricos relevantes para o objetivo geral deste trabalho e para isto foram adotados os textos de Campanha (1994), Abdi et al. (1999), Azevedo et al. (2000), Haykin (2001) e Kovács (2002).

Em 1943, o neurologista Warren S. McCulloch junto com o seu aluno Walter Pitts, estatístico, publicaram o artigo “*A logical calculus of the ideas immanent in nervous activity*” no *Bulletin of Mathematical Biophysics*, considerado o marco zero no desenvolvimento das redes neurais artificiais. Acredita-se que este artigo tenha influenciado cientistas como John von Neumann que se voltou para a construção de cérebros eletrônicos ou computadores, Marvin Minsky que se dedicou a aplicação da inteligência artificial em sistemas autônomos, Norbert Wiener que se preocupou com aquilo que veio a denominar-se cibernética e, principalmente, Frank Rosenblatt que, preocupado com o aspecto computacional da visão, criou o “*Perceptron*”, em 1957. Alguns historiadores acreditam que McCulloch e Pitts foram,

por seu turno, também influenciados pelas pesquisas de Alan Turing e do próprio John von Neumann.

O neurônio de McCulloch/Pitts é do tipo lógico, que admite somente dois estados: dispara ou não dispara o pulso ou sinal. As suas entradas pertencem ao conjunto formado pelos números 0 e 1, possui um limiar constante igual a 1 e as suas sinapses tanto excitatórias quanto inibitórias possuem valores idênticos. Neste caso, as sinapses são excitatórias quando o peso da conexão é positivo e são inibitórias quando o peso da conexão é negativo. Se a soma ponderada for superior ao limiar o neurônio dispara o sinal e em, caso contrário, não dispara o sinal, conforme estabelecido pelos próprios autores McCulloch & Pitts (1943), (Figura 6).

Figura 6 – O neurônio de McCulloch/Pitts.



Fonte: McCulloch/Pitts (1943).

Frank Rosenblatt, na Universidade de Cornell, construiu o Perceptron, Figura 7, equipamento que se constituía em uma rede neural de uma só camada e era um classificador de padrões capaz de identificar formas geométricas. Também foi construído com neurônios do tipo lógico, entretanto já apresentava conexões modificáveis, mas a saída fornecia os mesmos resultados 0 e 1. Usava a regra Hebbiana para o aprendizado. Os neurônios do Perceptron eram discriminadores (ou separadores) lineares, tendo em vista que a soma ponderada:

$$\sum w_i \cdot x_i = \theta, \quad (2.5)$$

onde θ é o limiar, comportava-se no caso em que $n = 2$, onde n é o número de entradas, como a equação de uma reta no plano formado pelos eixos x_1 e x_2 . Assim, se

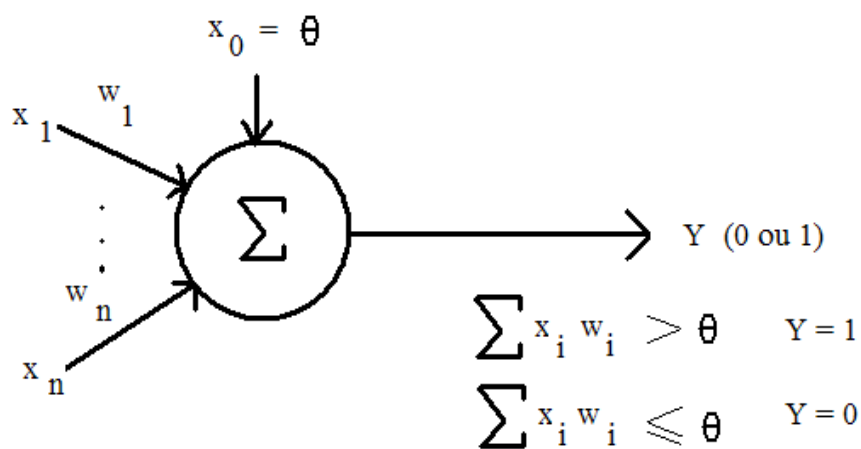
$$w_1 \cdot x_1 + w_2 \cdot x_2 \geq \theta \quad (2.6)$$

é obtida uma parte do plano (acima da reta) e se

$$w_1 \cdot x_1 + w_2 \cdot x_2 < \theta \quad (2.7)$$

é encontrada a outra parte do plano (abaixo da reta). Quando $n = 3$ o elemento separador $w_1 x_1 + w_2 x_2 + w_3 x_3 = \theta$ passa a ser um plano no espaço gerado pelas coordenadas x_1 , x_2 e x_3 . Quando n é superior a 3, tem-se aquilo que os matemáticos chamam de hiperplanos (ROSENBLATT,1958).

Figura 7 – O Perceptron de Rosenblatt.



Fonte: Rosenblatt (1958).

Na Universidade de Stanford, em 1959, Bernard Widrow desenvolveu filtros que eliminaram os ruídos nas linhas telefônicas e se confirmou como a primeira aplicação das redes neurais artificiais ao mundo real. Estudou também a aplicação das redes neurais no reconhecimento da fala e de objetos, na previsão do tempo, no ajuste de antenas parabólicas, na regulação da pressão sanguínea. Criou o ADALINE (*ADaptative LINear Element*), onde as unidades de processamento são adaptadores lineares e também o MADALINE (*Multiple Adaline*) com várias camadas ADALINE. Com Marcian Hoff desenvolveu a Regra de

Aprendizado Delta (ou de Widrow-Hoff), aquela que estabeleceu que “quando você comete um erro, preste menos atenção à célula de entrada que levou você a cometer este erro e preste mais atenção à célula de entrada que não levou você a cometer este mesmo erro”. Esta regra causou uma grande euforia junto a outros pesquisadores crentes na imensa potencialidade de aplicações das redes neurais, acreditando, naqueles tempos, que havia sido descoberta uma chave da inteligência humana (WIDROW e HOFF, 1960).

Entretanto, M. Minsky e S. Papert provaram, posteriormente, que o Perceptron não seria capaz de discriminar a operação lógica do tipo “*ou exclusivo (XOR)*” e o seu complemento e, significava que, para os conjuntos “mais interessantes” (linearmente não separáveis) ele não conseguiria exibir nenhum conjunto de pesos sinápticos (w_i) para efetuar a classificação de padrões (MINSKY e PAPERT, 1969). Isto provocou uma estagnação nos estudos sobre as redes neurais, principalmente, pela indisponibilidade de verbas para as pesquisas por quase duas décadas, de acordo com as referências indicadas no início deste item.

Mesmo assim, isto não impediu que Teuvo Kohonen, Stephen Grossberg, James Anderson, Igor Aleksander (redes sem pesos), Kunihiko Fukushima (cognitron e neocognitron), notadamente, continuassem os seus trabalhos de pesquisa dentro da computação neural. De acordo com Wasserman (1989), o choque provocado pelo livro “Perceptrons” de Minsky e Papert permitiu que houvesse um período de latência de modo a se atingir a necessária maturidade neste campo de estudos. Hoje as redes neurais artificiais rotineiramente resolvem alguns dos problemas que foram colocados no livro de Minsky e Papert. As redes diretas exigem apenas camadas intermediárias para solucionar os problemas não linearmente separáveis. Provou-se, mais tarde, que bastava uma só camada, no entanto, a solução ficaria ainda na dependência da quantidade de neurônios desta camada oculta.

Destaca-se que Kohonen, da Universidade de Helsinque, nos anos 70 do século passado, desenvolveu a Regra do Aprendizado Competitivo e a rede neural correspondente, na qual as unidades de processamento competem entre si. Também desenvolveu alguns algoritmos adaptativos locais (mapa auto-organizável). James Anderson, na Universidade de Brown, desenvolveu um Modelo Associativo Linear similar aos modelos biológicos de memória e reconhecimento. Por seu turno, Stephen Grossberg utilizando-se da clássica experiência de Pavlov sobre reflexos condicionados, construiu modelos em computação neural. Desenvolveu, também, a partir dos anos 60, a Teoria da Ressonância Adaptativa (ART), para classificar padrões, com os modelos ART1 (padrões binários), ART2 (padrões

analógicos) e, junto com Gail Carpenter, o ART3, redes diretas espaço temporais, esta em 1978.

Com a publicação do artigo “*Neural networks and physical systems with emergent collective computational abilities*” na renomada *Proceedings of the National Academy of Sciences* por J. J. Hopfield, da Caltech, em 1982, promoveu-se o retorno à respeitabilidade dos estudos sobre as redes neurais artificiais. Hopfield desenvolveu uma Rede Associativa com neurônios do tipo lógico, introduzindo o conceito de função de energia (ou função de Lyapunov) para analisar a evolução da rede. O mecanismo de resposta da rede é uma particularização dos trabalhos de Grossberg, no entanto, ele concebeu uma notável síntese de ideias com um adequado tratamento matemático, conforme destaca Wasserman (1989).

Complementando, dentre outros precursores, pode-se destacar o neuroanatomista Brian G. Gragg e o físico H. N. V. Temperley que, ainda em 1954, estabeleceram uma analogia entre as Redes de Neurônios e as Redes de Átomos com Spins. Analogia que foi aproveitada por William A. Little, em 1974, que associou as redes neurais e os sistemas de spins (Ising). Em 1976, D. Marr e T. Poggio estudando como o cérebro humano construía a noção de profundidade, que permite a visão tridimensional, desenvolveram um algoritmo cooperativo semelhante ao modelo de Hopfield .

Em 1986, com a publicação do clássico “*Parallel Distributed Processing*” por D. Rumelhart e J. McClelland consolidou-se definitivamente o avanço nos estudos sobre as redes neurais com a criação de associações de pesquisadores e estudiosos, com a fundação de empresas de software para a sua exploração comercial e com uma proliferação de publicações e de periódicos. Com a introdução do algoritmo de Retropropagação do Erro (*Backpropagation*) houve um aumento substancial nas aplicações das redes neurais. Atualmente, há diversos grupos utilizando-as em Neurologia, Psicologia, Medicina, Ciência da Computação e em outros ramos do conhecimento humano, o que demonstra a grande capacidade que elas possuem para a resolução de problemas de grande complexidade com resultados impressionantes. Para finalizar, em 1987, os pesquisadores Sejnowsky e Rosenberg desenvolveram redes para a conversão de texto e a correspondente representação fonética. Burr desenvolveu redes para o reconhecimento de caracteres escritos manualmente enquanto Cottrell, Munro e Zipser desenvolveram redes para a compressão de imagens. Acrescentam-se as redes de Funções de Base Radial, desenvolvida por M. J. D. Powell, em 1985, Renals, em 1989, Moody e Darken, em 1990, Poggio e Girosi, também em 1990 e Park e Sandberg, em

1991, que são utilizadas para a classificação e para a aproximação de funções introduzidas pela função de ativação gaussiana nos neurônios das camadas intermediárias.

2.4. Regra Delta e Regra Delta Generalizada

2.4.1 Regra Delta

Basicamente as regras de aprendizado aqui analisadas consistem em um processo iterativo de ajuste dos pesos das conexões da rede. Na forma matricial, se a matriz dos pesos das conexões (pesos sinápticos) for \mathbf{W} , então o processo iterativo é desenvolvido pela fórmula:

$$\mathbf{W}(n + 1) = \mathbf{W}(n) + \Delta \mathbf{W}(n), \quad (2.8)$$

onde $\mathbf{W}(n + 1)$ representa a matriz dos pesos no instante (ou passo) $n + 1$, $\mathbf{W}(n)$ a matriz no instante n e $\Delta \mathbf{W}(n)$ representa a matriz de ajustes aplicado aos pesos das conexões. Para cada maneira diferente de se calcular $\Delta \mathbf{W}(n)$ há um algoritmo de aprendizado diferente.

A regra delta elaborada por B. Widrow e M. Hoff (WIDROW & HOFF, 1960), com base na regra de Hebb, é um processo de minimização do erro calculado entre a saída desejada (alvo) e a saída obtida através da aproximação pelo método dos mínimos quadrados. É uma regra supervisionada, segundo Abdi et al. (1999), Haykin (2001) e Braga et al. (2007). A regra básica (FÓRMULA 2.8) na forma matricial pode ser decomposta para cada peso, conforme a equação a seguir

$$w_{ij}(n + 1) = w_{ij}(n) + \Delta w_{ij}(n), \quad (2.9)$$

onde i representa a célula de entrada e j a célula de saída. Considerando t_j o valor desejado, \hat{t}_j o valor encontrado pela rede no instante n , o erro de aproximação é

$$e_j = t_j - \hat{t}_j. \quad (2.10)$$

Assim,

$$w_{ij}(n + 1) = w_{ij}(n) + \eta \cdot e_j \cdot x_i(n) \quad (2.11)$$

onde η é uma constante positiva denominada de taxa de aprendizado, $\eta \in [0,1]$, e $x_i(n)$ é o valor de ativação (entrada) i do neurônio. Ainda, de acordo com Braga et al., 2007, a Equação (2.11) aparece também no algoritmo de treinamento do Perceptron, no algoritmo de treinamento das redes ADALINE, de B. Widrow, e na generalização do algoritmo de Retropropagação do Erro (*Backpropagation*).

A minimização do erro deve ocorrer quando se aplicam as derivadas parciais na soma dos erros quadráticos das saídas

$$e^2 = \frac{1}{2} \sum_{j=1}^p e_j^2, \quad (2.12)$$

onde p é o número de exemplos de treinamento da rede, o número $\frac{1}{2}$ é um fator de controle e não afeta o resultado, de acordo com o ajustamento pelo Método dos Mínimos Quadrados. No caso do aprendizado Hebbiano, tem-se:

$$\Delta w_{ij} = \eta \cdot y_j(n) \cdot x_i(n), \quad (2.13)$$

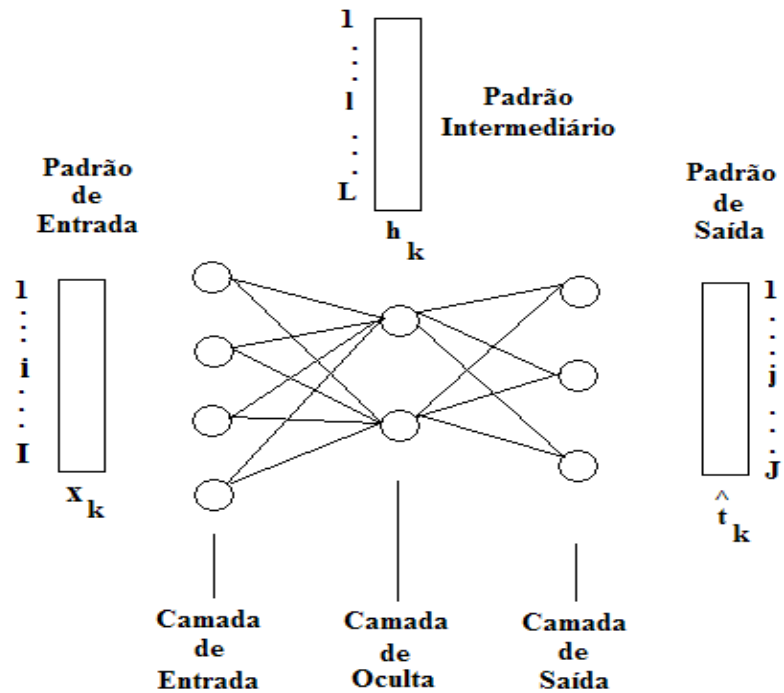
onde $y_j(n)$ é a saída j do neurônio e $x_i(n)$ é a entrada i do neurônio. Especificamente para o Perceptron, os autores Braga et al. (2007), apresentam este algoritmo de aprendizado com o auxílio do que chamam de Portas de Limiar (*Threshold gates*) Linear, Quadrática e Polinomial e, novamente, neste caso, fica bem evidente a similaridade entre os conceitos de Portas de Limiar e a Análise de Regressão, com fórmulas semelhantes e com a minimização efetuada com a fórmula da soma quadrática dos erros. Ressaltam ainda que o ADALINE é também um aproximador linear de funções.

2.4.2 Regra Delta Generalizada

A Regra Delta Generalizada ou Regra de Retropropagação do Erro ou, ainda, Regra *Backpropagation*, é de aprendizado supervisionado e pode ser aplicada à qualquer rede direta multicamadas com unidades de processamento não lineares. A diferença entre uma unidade linear e outra não linear é a função de transferência ou de ativação, que no segundo caso é não linear.

O desenvolvimento do algoritmo será feito, sem perda de generalidade, com uma camada de entrada, uma camada oculta (intermediária ou *hidden*) e uma camada de saída, conforme a Figura 8.

Figura 8 – Uma rede direta de três camadas.



Fonte: Abdi et al. (1999).

Na Figura 8, a camada de entrada é constituída por I neurônios, a camada oculta é constituída por L neurônios e a camada de saída é constituída por J neurônios. A matriz dos pesos sinápticos Z , que conecta os neurônios da camada de entrada aos neurônios da camada oculta (no MATLAB, esta matriz é denotada por IW) é de ordem $I \times L$, a matriz de pesos sinápticos W , que conecta os neurônios da camada oculta aos neurônios da camada de saída (no MATLAB, ela é denotada por LW) é de ordem $L \times J$, o vetor do padrão de entrada x_k é de ordem $I \times 1$. Da mesma forma, o vetor h_k é de ordem $L \times 1$, \hat{t}_k é de ordem $J \times 1$. A saída desejada é o vetor t_k , também de ordem $J \times 1$, de acordo com Abdi et al. (1999).

A diferença entre a resposta obtida (estimada) \hat{t}_k de uma unidade de saída e a resposta desejada t_k é o erro produzido pela rede. As células da camada de saída usam este erro

diretamente para corrigir os seus pesos nas conexões. O mesmo não acontece com as células da camada oculta, que não estão em contato direto com alguma fórmula de erro, de forma que elas estimam os próprios erros. Neste ponto entra o erro de retropropagação. O crescimento do erro cometido é inicialmente um sinal de erro proporcional à razão de mudança (tangente ou derivada) da função de ativação não linear. Este sinal de erro é passado para trás através dos pesos das conexões da unidade oculta. Em seguida, todos os pesos das conexões são atualizados, conforme Abdi et al. (1999).

Na Regra Delta de unidades lineares a correção dos pesos é proporcional ao erro cometido e ao valor da célula de entrada, enquanto na Regra Delta Generalizada, a correção dos pesos sinápticos é proporcional à razão de mudança da função de transferência não linear (ABDI et al.,1999). Na camada de saída, tem-se, então,

$$\Delta W_{lj} = f'(a_j) \cdot (t_j - \hat{t}_j) \cdot h_l = \quad (2.14)$$

$$= f'(a_j) \cdot e_j \cdot h_l = \quad (2.15)$$

$$= \delta_j \cdot h_l, \quad (2.16)$$

onde a_j é a saída para a função de transferência. O sinal de erro é $\delta_j = f'(a_j) \cdot e_j$. Na camada oculta o erro é estimado mediante a aplicação da Equação (2.17)

$$\hat{e}_l = \sum_j w_{lj} \delta_j \quad e, \quad (2.17)$$

consequentemente, na camada de entrada tem-se

$$\Delta Z_{il} = [f'(a_l) \cdot \hat{e}_l] \cdot x_i = \quad (2.18)$$

$$= \delta_l \cdot x_i, \quad (2.19)$$

onde a_l é a saída para a função de transferência.

Na modalidade de único estímulo (termos com índice k), de acordo com Abdi et al. (1999), é mostrado o funcionamento da Regra Delta Generalizada através da sequência das equações que seguem abaixo. Na ida ou no sentido da propagação do erro, a sequência se caracteriza pelos seguintes passos, onde o símbolo T , que acompanha as matrizes Z e W , significa que a matriz é transposta:

Camada de entrada \mathbf{x}_k ;

Camada oculta $\mathbf{h}_k = f(\mathbf{Z}^T \mathbf{x}_k)$;

Camada de saída $\hat{t}_k = f(\mathbf{W}^T \mathbf{h}_k)$;

Erro de sinal $\hat{t}_k = f(\mathbf{W}^T \mathbf{h}_k)$.

Agora, no retorno, no sentido da retropropagação do erro, tem-se:

Camada de saída (s) $\mathbf{e}_k = t_k - \hat{t}_k$;

$$\delta_{s,k} = f'(\mathbf{W}^T \cdot \mathbf{h}_k) \cdot \mathbf{e}_k ;$$

$$\mathbf{W}(n+1) = \mathbf{W}(n) + \eta \cdot \mathbf{h}_k \cdot \delta_{s,k}^T = \mathbf{W}(n) + \Delta \mathbf{W}(n).$$

Camada oculta (o) $\delta_{o,k} = f'(\mathbf{Z}^T \mathbf{x}_k) \cdot \mathbf{e}_k$;

$$\mathbf{Z}(n+1) = \mathbf{Z}(n) + \eta \cdot \mathbf{x}_k \cdot \delta_{o,k}^T = \mathbf{Z}(n) + \Delta \mathbf{Z}(n).$$

Ao retornar à camada de entrada, inicia-se novamente o processo de ida e de volta até que o erro seja minimizado para resolver o problema. No MATLAB, cada uma dessas passagens é considerada como um passo ou um *epoch*, do original em inglês. Para facilitar os cálculos, pode-se também colocar, de forma simplificada (Formulas 2.20),

$$\begin{aligned} \mathbf{b} &= \mathbf{Z}^T \mathbf{x} \\ \mathbf{h} &= f(\mathbf{b}) \\ \mathbf{a} &= \mathbf{W}^T \mathbf{h} \\ \hat{t} &= f(\mathbf{a}) \\ \mathbf{e} &= t - \hat{t} \\ \delta_s &= f'(\mathbf{a}) \cdot \mathbf{e} \\ \hat{\mathbf{e}} &= \mathbf{W} \cdot \delta_s \\ \delta_o &= f'(\mathbf{b}) \cdot \hat{\mathbf{e}} \end{aligned} \tag{2.20}$$

$$\mathbf{Z}(n+1) = \mathbf{Z}(n) + \eta \cdot \mathbf{x} \cdot \delta_o^T$$

$$\mathbf{W}(n+1) = \mathbf{W}(n) + \eta \cdot \mathbf{h} \cdot \delta_s^T$$

Nestas fórmulas, o índice s está relacionado à camada de saída, o índice o está relacionado à camada oculta e η é a taxa de aprendizado.

O objetivo deste algoritmo é o de encontrar iterativamente o mínimo da função do erro (superfície de erro), usando o método do gradiente descendente. O gradiente é um operador diferencial que aplicado a uma função de no mínimo duas variáveis aponta, sempre, no sentido do crescimento máximo dessa função. No sentido contrário, encontra-se o mínimo. Esta regra está intimamente relacionada com a técnica estatística da Análise de Regressão Não Linear. Considerando novamente a forma matricial do erro e usando a regra da cadeia adaptada para matrizes, demonstra-se o método do gradiente descendente conforme desenvolvimento a seguir. Assim, se

$$E_k = \frac{1}{2} (t_k - \hat{t}_k)^T (t_k - \hat{t}_k) = \frac{1}{2} [t_k^T t_k + \hat{t}_k^T \hat{t}_k - 2t_k^T \hat{t}_k] \quad (2.21)$$

é a função de erro, então o gradiente aplicado a esta função é

$$\nabla_W E_k = \frac{\partial E_k}{\partial W} = \frac{\partial E_k}{\partial \hat{t}_k} \frac{\partial \hat{t}_k}{\partial W^T h_k} \frac{\partial W^T h_k}{\partial W}, \quad (2.22)$$

onde cada derivada parcial, calculada em separado, fornece os resultados

$$\frac{\partial E_k}{\partial \hat{t}_k} = -(t_k - \hat{t}_k), \quad (2.23)$$

$$\frac{\partial \hat{t}_k}{\partial W^T h_k} = \frac{\partial f(W^T h_k)}{\partial W^T h_k} = f'(W^T h_k), \text{ e} \quad (2.24)$$

$$\frac{\partial W^T h_k}{\partial W} = 2h_k^T. \quad (2.25)$$

$$\text{Donde se conclui que } -\nabla_W E_k = \delta_{s,k} h_k^T, \text{ e} \quad (2.26)$$

$$\Delta W(n) = \eta h_k \delta_{s,k}^T. \quad (2.27)$$

Novamente, usando a regra da cadeia adaptada para matrizes e considerando que:

$$\hat{t}_k = f(W^T f(Z^T x_k)), \quad (2.28)$$

$$\nabla_Z E_k = \frac{\partial E_k}{\partial Z} = \left(\frac{\partial E_k}{\partial \hat{t}_k} \frac{\partial \hat{t}_k}{\partial W^T h_k} \frac{\partial W^T h_k}{\partial h_k} \right) \frac{\partial h_k}{\partial Z^T x_k} \frac{\partial Z^T x_k}{\partial Z} = -\delta_{o,k} \frac{\partial h_k}{\partial Z^T x_k} \frac{\partial Z^T x_k}{\partial Z}. \quad (2.29)$$

Calculando cada derivada parcial em separado, encontram-se as expressões:

$$\frac{\partial W^T h_k}{\partial h_k} = W, \quad (2.30)$$

$$\frac{\partial h_k}{\partial Z^T x_k} = \frac{\partial f(Z^T x_k)}{\partial Z^T x_k} = f'(Z^T x_k), \mathbf{e} \quad (2.31)$$

$$\frac{\partial Z^T x_k}{\partial Z} = 2x_k^T. \quad (2.32)$$

Consequentemente,

$$-\nabla_Z E_k = \delta_{o,k} x_k^T, \mathbf{e} \quad (2.33)$$

$$\Delta Z(n) = \eta x_k \delta_{o,k}^T. \quad (2.34)$$

Com estes resultados conclui-se a demonstração do método do gradiente descendente, aplicado na elaboração da Regra Delta Generalizada, conforme Abdi et al. (1999).

Além das três regras de aprendizado aqui apresentadas, Haykin (2001) acrescenta o processo de aprendizagem baseado em memória e a aprendizagem de Boltzmann com excelente detalhamento. Também complementa com outros tópicos relacionados com as redes neurais artificiais.

Por seu turno, Braga et al. (2007) apresenta em detalhes o modelo ADALINE, as redes auto-organizáveis, o desenvolvimento dos Sistemas Neurais Híbridos, tema de pesquisa mais recente, onde um dos subsistemas é uma rede neural artificial, e as redes neurais sem pesos.

3. MATERIAIS E MÉTODOS

3.1. O Pólo Cerâmico de Santa Gertrudes

O Pólo Cerâmico de Santa Gertrudes (PCSG) constituído pelos municípios de Limeira, Cordeirópolis, Santa Gertrudes, Rio Claro, Ipeúna, Piracicaba e Araras é integrado por 34 indústrias cerâmicas, de um total de 47, dentro do Estado de São Paulo, que são filiadas à Associação Paulista das Cerâmicas de Revestimento, ASPACER, (ASPACER, 2012).

Por ter acompanhado as inovações e mudanças tecnológicas pela importação, principalmente, de máquinas e equipamentos de países sobre os quais foram impostas severas regras para o controle ambiental da produção industrial de transformação, ainda de acordo com Poletto (2007), os impactos ambientais causados pelas indústrias do já citado APL de Santa Gertrudes sofreram uma sensível redução, contrário ao das mineradoras que ainda, na ocasião em que foi elaborada a sua pesquisa, não haviam modernizado os seus processos de lavra. Contudo, o mesmo autor pondera que com uma fiscalização mais rigorosa por parte dos órgãos e das entidades governamentais associadas a melhorias técnicas advindas das modernas máquinas e dos equipamentos de mineração e, também, com mudanças na forma de extração das argilas, inclusive as mineradoras estão se esforçando no sentido de diminuir os impactos ambientais por elas causados, dentro das possibilidades e orientações de cada uma delas. Novamente, Poletto (2007) considera que o maior impacto ambiental causado pelas mineradoras é aquele da desfiguração topográfica, para a qual sugere algumas soluções como, por exemplo, a revegetação, além da reversão da área já explorada em terras produtivas e autosustentáveis.

3.2. Caracterização das Argilas e das Cerâmicas

De acordo com Christofolletti e Moreno (2004), as argilas da Formação Corumbataí constituída basicamente de argilitos, siltitos, arenitos, calcários, predominante no APL de Santa Gertrudes, são argilominerais que permitem, dentre outros, o seu aproveitamento dentro, principalmente, do grupo BIIb, segundo a norma NBR 13818 da Associação Brasileira de Normas Técnicas, ABNT, (ABNT, 1997). Conforme os textos de Christofolletti et al. (2005), Poletto (2007b) e Prado et al. (2008), as argilas de boa qualidade dessa formação ocorrem no interior do Estado de São Paulo, onde se localiza o PCSG com aproximadamente

90 m de espessura (altura) numa largura que atinge aproximadamente 10 km. De acordo com a ASPACER (2012) esta formação possui uma continuidade aproximada de 200 km.

Em sua composição mineralógica destacam-se a illita, a montmorillonita, a clorita, o quartzo, o feldspato, os carbonatos (em níveis localizados), os compostos de Fe e Ti, além da presença de argilominerais interestratificados, segundo Gaidzinski (2006) e Prado et al. (2008), ressaltando que a ocorrência das argilas não é homogênea. Ocorrem variações nos teores de uma mina para outra e, mesmo dentro de uma cava de lavra, a composição das argilas pode variar tanto horizontalmente quanto verticalmente, esta, porém, menos frequente. Em complemento, de acordo com Christofolletti et al. (2005), Gaidzinski (2006), Poletto (2007) e Prado et al. (2008), essas argilas apresentam em sua composição química alguns óxidos, principalmente, SiO_2 e AlO_3 , ambos responsáveis pelas propriedades refratárias, os carbonatos (terrosos) CaO , MgO , Na_2O , que juntos ao óxido K_2O são responsáveis pelas propriedades de queima (ou sinterização). Completam esta lista Fe_2O_3 , TiO_2 , MnO , P_2O_5 e Mn_2O_3 . Da mesma maneira há variações, visto que a porcentagem destes óxidos presentes nas argilas é diferente em cada cava de lavra.

Prado (2007) verificou que as indústrias cerâmicas misturam, no máximo, argilas provenientes de três fontes diferentes e que na preparação da massa para moagem executam uma mistura de matérias-primas. Também, complementa que o grupo BIIb especificado na norma NBR 13818 (ABNT, 1997) caracteriza um produto semi-poroso, com alta absorção de água mas com baixa resistência mecânica. Devido à porosidade, medida em porcentagem pela variável física absorção de água (Abs), a classificação das placas cerâmicas é apresentada na Tabela 1.

Tabela 1 – Classificação das placas cerâmicas quanto à porosidade.

PRODUTO	Abs (%)
Poroso	10 – 20
Semi-poroso	6 – 10
Semi-grês	3 – 6
Grês	0.5 – 3
Porcelanato	< 0.5

Fonte: Prado (2007).

O porcelanato é um produto cerâmico de alto valor agregado e a sua produção é a que mais cresce no mundo. Paralelamente aos dados da Tabela 1, Prado (2007) acrescenta a Tabela 2 (como consta da norma NBR 13818, ABNT,1997).

Tabela 2 – Especificações da NBR 13818 (ABNT, 1997).

MÉTODOS DE FABRICAÇÃO			
Abs(%)	Extrudado (A)	Prensado (B)	Outros (C)
Abs ≤ 0.5	AI	BIa	CI
0.5 < Abs ≤ 3.0	AI	BIb	CI
3.0 < Abs ≤ 6.0	AIIa	BIIa	CIIa
6.0 < Abs ≤ 10.0	AIIb	BIIb	CIIb
Abs > 10.0	AIII	BIII	CIII

Fonte: (ABNT, 1997) e (PRADO, 2007).

A indústria de revestimentos cerâmicos está inserida na indústria de materiais de construção que, por sua vez, faz parte da indústria de transformação. No APL de Santa Gertrudes, o principal processo de fabricação é o chamado Processo Via Seca (CORREIA et al., 2007), com o qual, em princípio, não há misturas e nem homogeneização, mas inferioriza a qualidade do produto final, ou seja, os pisos e revestimentos cerâmicos. Porém, este processo industrial é largamente usado porque é aplicado com menores custos energéticos, menores custos de manutenção, menores impactos ambientais como um importante resultado, apesar de apresentar limitações tecnológicas. Conforme Moreno et al. (2009), a argila é moída a seco, os ciclos são de monoqueima rápida com intervalos de tempo de 20 a 30 minutos, com uma temperatura máxima superior a 1000° C. Christofolletti (1999) reforça que na moagem a seco a umidade é de valor aproximado de 5%, enquanto na prensagem a seco a umidade é de ordem aproximada a 10%. A monoqueima rápida é considerada melhor do que a biqueima, outro processo de fabricação. Recentemente foi implantado por algumas indústrias brasileiras, um terceiro processo de fabricação denominado de terceira queima, o qual permite alguns efeitos especiais na produção. Em resumo, Christofolletti (1999) e Prado (2007) consideram as seguintes fases nas operações de mineração:

1. Pesquisa mineral;
2. Remoção da cobertura vegetal (ou desmatamento);

3. Decapeamento;
4. Desmonte (por explosivos ou por meios mecânicos);
5. Carregamentos;
6. Britagem (ou trituração);
7. Sazonamento (em pilhas) ou
8. Pátio de secagem e de homogeneização; e
9. Armazenamento (para o posterior transporte de argila).

E, para as operações industriais:

1. Extração e transporte da argila;
2. Preparação da massa (via seca) e moagem;
3. Atomização;
4. Prensagem (ou moldagem) e secagem;
5. Preparação do esmalte e esmaltação (ou não esmaltados) – faz parte do conceito de decoração;
6. Queima (monoqueima rápida);
7. Retífica e polimento;
8. Classificação do produto e embalagem;
9. Transporte interno (empilhamento e carregamento de caixas);
10. Lavagem de equipamentos e pisos;
11. Geração de resíduos sólidos; e
12. Seleção, expedição e comercialização.

Com relação à homogeneização das argilas, Gaidzinski (2006) fez uma análise de sazonalidade, que consiste na estocagem das argilas a céu aberto por períodos de tempo que variam de 6 meses a 2 anos, e concluiu que para se conseguir esta homogeneização o período de tempo deve ser superior a um ano, com as pilhas mantidas em local aberto. Para os seus estudos, também usou argilas provenientes do APL de Santa Gertrudes.

Finalmente, a argila, como qualquer outro mineral, é um recurso não renovável, significando que uma mina é temporária e, levando isto em consideração, pode-se dizer que ela possui um ciclo de vida (AMBIENTE BRASIL, 2009). Este ciclo de vida de uma mina é constituído pelas seguintes fases:

1. Planejamento (pesquisa mineral, estudos ambientais, estudos de viabilidade);

2. Implantação;
3. Operação;
4. Desativação (preparação para o fechamento);
5. Fechamento; e
6. Transferência de responsabilidade.

Neste momento, convém salientar que o Ambiente Brasil (2009) sugere que para se aumentar o ciclo de vida de uma mina, as alternativas são a redução de consumo e a reciclagem das matérias-primas.

3.3. Os Corpos-de-Prova

As amostras para a confecção e moldagem dos corpos-de-prova foram retiradas das nove minas: Cristofolletti minas 1 e 2, Cruzeiro frentes 1 e 2, Paganoti, Partezani minas 1, 2 e 3, Pieroni e Tute, identificadas e localizadas conforme os dados que constam da Tabela 3.

Tabela 3 – Coordenadas UTM obtidas por GPS das minas estudadas (Datum: SAD 69).

MINAS	SIGLA	COORDENADA		ALTITUDE (m)
		N - S	E - W	
Cristofolletti Mina 1	CF1	0231532	7521059	540
Cristofolletti Mina 2	CF2	0230592	7526781	598
Cruzeiro Frente 1	CR1	0248481	7505118	654
Cruzeiro Frente 2	CR2	0249023	7505458	641
Paganoti	PG	0251306	7531241	690
Partezani Mina 1	PT1	0234656	7506449	573
Partezani Mina 2	PT2	0235424	7507416	567
Partezani Mina 3	PT3	0234843	7507990	560
Pieroni	PI	0232239	7512374	552
Tute	TU	0241575	7535652	639

Fonte: Rocha (2012).

A Tabela 3 apresenta as coordenadas de localização das minas, zona 23K e, também, as altitudes das minas escolhidas, as quais foram obtidas com a utilização do Sistema de Posicionamento Global, GPS (Global Positioning System).

A Mina Cruzeiro pertence ao município de Limeira, a Mina Paganoti faz parte do município de Araras, enquanto as Minas Cristofoletti, as Minas Partezani, a Mina Pieroni e a Mina Tute pertencem ao município de Rio Claro. As áreas das minas Cruzeiro Frente 1 e Cruzeiro Frente 2, embora próximas, possuem características distintas e dessa maneira foram consideradas em separado. As minas Partezani 1, 2 e 3 encontram-se dentro da mesma propriedade, mas estão localizadas em áreas bem distintas devido a grande extensão territorial da propriedade. De acordo com Rocha (2012), a escolha destas minas foi feita em função de que elas permitiram a obtenção de amostras bem diferenciadas e, principalmente, por representarem toda a coluna estratigráfica da Formação Corumbataí.

Ainda, conforme Rocha (2012), para a coleta sistemática das amostras foi utilizada uma perfuratriz de acionamento pneumático e máquinas escavadeiras. O material recolhido foi armazenado em sacos plásticos com a respectiva identificação, a qual consistiu das seguintes informações: o nome da amostra (com referência à bancada – designadas por B1, B2, B3, B4 e B5, respectivamente, da base ao topo da mina – e a mina de onde ela foi recolhida), a data da coleta, a profundidade do furo e o posicionamento obtido pelo GPS. Foi estabelecida uma quantidade mínima de 30 kg por amostra de forma a permitir que fossem feitos todos os testes necessários durante a etapa laboratorial. Os corpos-de-prova foram preparados pelo método de moagem pela Via Seca, à semelhança do método empregado no PCSG.

A Figura 9 apresenta duas fotos da mina Pieroni, as quais não expõem claramente a superposição das bancadas. Por isto, foi acrescentada a Figura 10 que apresenta duas fotos da mina Santa Amábile, também de Rio Claro que, apesar de não constar da relação das minas estudadas, no momento das fotos, expôs de forma bem clara a superposição das bancadas. Nestas fotos, entre a base e o topo tem-se aproximadamente um desnível de 45 m, onde a bancada B1 de coloração bem escura e contaminada com calcário, possui uma espessura aproximada de 25 m, a seguir são visíveis bancadas de coloração roxa, todas elas com uma espessura total de 15 a 20 m. Ainda, a bancada B2 apresenta argilas duras, B3 argilas intermediárias e, por fim, a bancada B4 apresenta argilas moles, seguindo o modelo utilizado pelas indústrias da região do PCSG, de acordo com Rocha (2012).

Na preparação dos corpos-de-prova, as matérias-primas foram previamente moídas e homogeneizadas. Em seguida, foi adicionada água para que a umidade atingisse um teor de 10%, em cujo controle foi utilizada uma balança com infravermelho (marca Gehaka, modelo BK 6000) e, também, com uma peneira de malha 8 ABNT (2.36 mm). Em sequência, as

matérias-primas foram completamente homogeneizadas, com o teor de umidade em 10%, após um período de 24 horas. Finalmente, utilizando-se do método de prensagem a seco num molde de dimensões 10.0 X 3.5 cm e com uma espessura mínima inferior a 7.5 mm foi aplicada uma pressão de 250 kgf/cm² numa prensa hidráulica, cujo controle foi obtido com a determinação da densidade aparente do corpo-de-prova úmido em 2g/cm³, com massa de 50 g.

Figura 9 – Fotos da mina Pieroni.



Fonte: Autor (2012).

Figura 10 – Fotos da mina Santa Amábile.



Fonte: Autor (2012).

3.4. Determinação das Variáveis Físicas dos Corpos-de-Prova

Para amostras secas foram calculadas as variáveis físicas Retração Linear de Secagem (RLS), Densidade de Prensagem (DP) e a Densidade Aparente dos Corpos-de-Prova Secos (DAS). Para as amostras sinterizadas foram calculadas as variáveis físicas Módulo de Resistência à Flexão (MRF), Retração Linear de Queima (RLQ), Absorção de Água (Abs), Carga de Ruptura (CR) e Perda ao Fogo (PF). Os ensaios para o cálculo das variáveis Abs, CR e MRF seguiram as especificações técnicas da norma NBR 13818 (ABNT, 1997), cujos valores são: $6 \leq \text{Abs} < 10$ (grupo BIIb), $\text{CR} > 500 \text{ N}$ e $\text{MRF} > 18 \text{ MPa}$.

Tanto a variável DP como a variável DAS foram calculadas pela fórmula

$$\text{Densidade} = \frac{m}{V}, \quad (3.1)$$

onde m é a massa do corpo-de-prova, em g, e V é o volume do corpo-de-prova, em cm^3 . A unidade de densidade é g/cm^3 .

Medindo-se com um paquímetro o comprimento, em mm, dos corpos-de-prova úmidos após a prensagem (L_p) e o comprimento dos mesmos corpos-de-prova após a secagem (L_s) em uma estufa mantida à temperatura constante de 110°C por 24 horas, a variável RLS foi calculada, em porcentagem, usando-se a expressão:

$$\text{RLS} = \frac{L_s - L_p}{L_p} * 100. \quad (3.2)$$

Em seguida, os corpos-de-prova foram secados até o teor de umidade atingir um valor inferior a 1% e queimados (forno de rolo de laboratório – marca Cifel) em um ciclo de 30 minutos nas temperaturas de 1000°C , 1020°C , 1040°C e 1060°C .

Para o cálculo do MRF, em MPa, os corpos-de-prova já prensados, secos e queimados, utilizou-se de um flexímetro (marca Nannetti, modelo FM/96) durante os ensaios. A fórmula usada foi

$$\text{MRF} = \frac{3FL}{2be_{\min}^2} * 9.8066, \quad (3.3)$$

onde F é a força de ruptura, em kgf (1 kgf = 9.9066 N – fator de correção das unidades na fórmula (3.3)), L é a distância entre as barras de apoio, em mm, b é a largura do corpo-de-prova ao longo da ruptura após o ensaio, em mm, e e_{\min} é a espessura mínima do corpo-de-prova, também em mm.

Analogamente, foram calculadas:

$$Abs = \frac{m_2 - m_1}{m_1} * 100, \quad (3.4)$$

onde Abs é a absorção de água, em porcentagem, m_1 é a massa seca, em g, e m_2 é a massa úmida ou saturada, em g ;

$$CR = \frac{FL}{b}, \quad (3.5)$$

onde CR é a carga de ruptura, em N, F é a força de ruptura, em N, L é a distância entre as barras de apoio, em mm e b é a largura do corpo-de-prova ao longo da ruptura após o ensaio, em mm;

$$RLQ = \frac{L_q - L_s}{L_s} * 100, \quad (3.6)$$

onde RLQ é a retração linear de queima, em porcentagem, L_q é o comprimento do corpo-de-prova queimado, em mm, e L_s é o comprimento do corpo-de-prova seco, em mm; e, finalmente

$$PF = \frac{m_q - m_s}{m_s} * 100, \quad (3.7)$$

onde PF é a perda ao fogo, em porcentagem, m_q é a massa do corpo-de-prova queimado, em g, e m_s é a massa do corpo-de-prova seco, em g. Neste caso, foi usada uma balança de precisão (mediu a massa com três casas decimais).

Os dados dos ensaios realizados, de acordo com Rocha (2012), constam dos ANEXOS A (1000°C), B (1020°C), C (1040°C) e D (1060°C). No ANEXO A entre as minas e suas bancadas foram encontrados um total de 24 valores para as variáveis físicas RLQ, PF, Abs,

CR e MRF. Da mesma maneira, nos ANEXOS B, C e D as variáveis são DP, DAS, RLS, RLQ, PF, Abs, CR e MRF, sendo que o número de valores encontrados foram 25, 24 e 23, respectivamente. Nestes ANEXOS, foram calculadas também a amplitude, a média aritmética e o desvio padrão.

3.5. Metodologia

Em princípio, o método empregado neste trabalho será o dedutivo.

A indústria cerâmica busca se estabelecer em um nicho de mercado e para isso precisa determinar para o seu produto um padrão de qualidade, dentro das normas técnicas brasileiras emanadas pela ABNT. Por outro lado, de acordo com Rocha (2012), o Brasil já atingiu o segundo lugar no mundo com a produção de pisos e revestimentos cerâmicos, mas ainda encontra-se em quinto lugar dentro do pequeno grupo de países exportadores, por isso há a esperança de que num futuro próximo o Brasil também se aproxime dos primeiros lugares. Em busca de novos mercados, as indústrias cerâmicas brasileiras terão que se preparar para enfrentar uma dura concorrência num mundo cada vez mais globalizado, competitivo e cada vez mais carente de produtos e serviços. Em função da sua política e dos seus interesses em como penetrar nestes novos mercados, cada indústria cerâmica, via de regra, deverá estabelecer um padrão de especificação diferente para cada um dos seus produtos. Em vista disso, optou-se neste trabalho de pesquisa por um padrão de saída (especificação) da rede neural (particular e independente dos valores especificados por qualquer indústria do PCSG) baseado nos valores próximos aos da média aritmética geral das médias aritméticas dos ANEXOS A (1000°C), B (1020°C), C (1040°C) e D (1060°C), que são aqueles que apresentam os dados completos dos ensaios dos corpos-de-prova do maior número de bancadas e de minas, que fazem parte da Tabela 4, a seguir:

Tabela 4 – Médias dos ANEXOS A, B, C e D, média geral e o padrão de produto estabelecido neste trabalho.

MÉDIAS	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(Mpa)
ANEXO A	-	-	-	3.7030	3.3355	10.2555	473.34	37.34
ANEXO B	2.0288	1.8666	0.3078	5.2342	3.9364	7.3188	599.79	50.77
ANEXO C	2.0241	1.8559	0.3052	6.1957	4.1189	5.8655	649.04	56.13
ANEXO D	2.0272	1.8604	0.2926	6.6995	4.5172	4.5365	684.4	59.41
Média Geral	2.0267	1.8610	0.3019	5.4581	3.9770	6.9941	601.64	50.91
PADRÃO	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

É interessante observar que na Tabela 4, com exceção das variáveis físicas DP e DAS, as variáveis RLQ, PF, CR e MRF apresentam valores crescentes em função do aumento da temperatura, contrário ao das variáveis físicas RLS e Abs, que apresentaram valores decrescentes, tendência que será utilizada para reforçar a aplicação das redes neurais artificiais.

Esta escolha garante uma independência com relação aos padrões especificados nas indústrias do PCSG. Como há um padrão pré-estabelecido, com relação à aplicação mediante a utilização das redes neurais artificiais, optou-se pela rede que apresenta um padrão (ou vetor) de saída desejado. A escolha recaiu então na rede MLP (*Multilayer Perceptron*) ou rede Perceptron de múltiplas camadas, conforme Haykin (2001). A vantagem desta escolha é a sua arquitetura, a qual permite que a rede neural seja montada com uma camada de entrada (ou padrão de entrada), uma camada intermediária ou oculta e uma camada de saída (ou padrão de saída) que corresponde ao já citado padrão de especificação. Com isto, a diferenciação entre uma rede e outra para encontrar o padrão de saída desejado fica por conta do número de neurônios da camada oculta. Além da arquitetura, pode-se dizer que outra vantagem é que a rede MLP permite a aplicação da Regra de Aprendizado Delta Generalizada (ou regra *backpropagation*, do original em inglês) ou Regra de Retropropagação do Erro, uma das mais poderosas regras de aprendizado das redes neurais (ABDI et al., 1999). Outra vantagem é a facilidade de aplicação desta rede dentro dos *softwares* conhecidos atualmente.

Para aplicar a regra de aprendizado *backpropagation* na rede MLP foi utilizado o *software* MATLAB® (MATrix LABoratory), da *MathWorks, Inc.*, cujo programa detalhado consta do *Neural Networks Toolbox User's Guide*. Neste trabalho, além da regra básica foram escolhidas outras três variações da mesma regra, dentre outras que constam do mesmo *software*, que são a Regra *Backpropagation* com Momento, a Regra *Backpropagation* Resiliente e a Regra *Backpropagation* de Levenberg-Marquadt, sendo que cada uma destas variações apresenta uma velocidade diferente de convergência. Inicialmente, foram padronizadas as tabelas para que as mesmas variáveis físicas fossem mostradas nas mesmas bancadas das mesmas minas e submetidas às mesmas temperaturas de queima. Dessa forma, com cinco variáveis físicas (RLQ, PF, Abs, CR e MRF) reuniram-se as tabelas de dados dos ANEXOS E (1000°C), F (1020°C), G (1040°C) e H (1060°C), as quais apresentam 16 linhas de amostras de dados, e com as oito variáveis físicas (DP, DAS, RLS, RLQ, PF, Abs, CR e MRF) apresentam-se as tabelas de dados dos ANEXOS I (1020°C), J (1040°C) e K (1060°C), nas quais constam 20 linhas de amostras de dados. Também, nestas tabelas, foram calculadas as respectivas amplitudes, médias aritméticas e o desvio padrão correspondente. Os dados que constam dos ANEXOS E, F, G, H, I, J e K são inseridos como o padrão (ou vetor) de entrada que, no MATLAB, é designado pela letra latina *p* (ANEXO L).

Para empregar o MATLAB foram considerados os seguintes parâmetros de controle em função das quatro variações da regra de aprendizado *backpropagation*. São eles: *show*, *epochs*, *lr*, *mc* e *goal*.

O parâmetro *show* significa que os resultados de saída do programa serão apresentados no gráfico correspondente ao erro (mse: erro médio quadrático) de acordo com um valor pré-estabelecido (o valor utilizado foi 200, para visualização conveniente do gráfico); o parâmetro *lr* (learning rate, do original em inglês) é a taxa de aprendizado e que para dar estabilidade ao processo deve ser pequena, de acordo com sugestão inserida no *software* (foi usado $lr = 0.05$); o parâmetro *mc* é o do momento, para o qual o programa sugere um valor alto (neste caso, $mc = 0.9$). Tanto o parâmetro *lr* como o parâmetro *mc* assumem valores que pertencem ao intervalo de números reais $[0,1]$. Os parâmetros *epochs* e *goal* são parâmetros de parada do processo, isto é, independentemente de ter sido atingido ou não o ponto de convergência ótimo, eles finalizam o processo de execução do programa. No caso do *epochs*, ele significa quantas vezes o processo deve ser propagado (no sentido da camada de entrada para a de saída) e retropropagado (no sentido contrário) para se calcular o erro entre o valor obtido e o

valor desejado (iniciou-se com o valor 2000). E, finalmente, o parâmetro goal é o valor do erro médio quadrático (mse), que o *software* calcula mediante a aplicação da fórmula:

$$mse = \frac{1}{n * n} \{ summation(square[M1 - M2]) \}, \quad (3.8)$$

onde n é o número de dados, $M1$ é a matriz correspondente ao padrão de saída esperado e $M2$ é a matriz correspondente ao padrão de saída encontrado durante o processo. Em função dos dados das tabelas constantes dos ANEXOS E, F, G, H, I, J e K (três casas decimais no máximo), o valor do parâmetro goal foi fixado em $1e-5$.

Em seguida, foi estabelecido que a camada oculta de cada rede neural seria montada com um número que iria de 2 a 35 neurônios ($N=2,3,4,\dots,35$) ou $N= 5,10,15,20,25,30,35$, em alguns casos, e o processo, para cada número de neurônios, deveria ser aplicado em três testes diferentes para verificar a convergência. O número de testes de convergência foi colocado tendo em vista que é muito comum a superfície de resposta do erro (relacionado ao mse), além de apresentar um mínimo global, não necessariamente, indicando uma otimizada convergência, pode também apresentar vários mínimos locais (diferentes do mínimo global), por vezes intransponíveis durante a execução do processo, constituindo-se em verdadeiras armadilhas, antagônicas à convergência esperada. Dessa forma, verificado que nos três testes de convergência os erros, localizados na sua própria superfície de resposta de erro, ficaram presos nestas armadilhas, a aplicação do processo era encerrado no momento em que o número de neurônios da camada oculta atingisse o valor de $N=35$. Caso contrário, se entre os três testes fosse detectada alguma possibilidade de convergência na direção de um mínimo global, o número de testes poderia ser ampliado até para dez, e, da mesma maneira, o número de neurônios na camada oculta também poderia ser aumentado e, de fato, o foi alcançando o valor $N=100$, desde que se atingisse a estabilidade da rede neural; o mesmo poderia acontecer com o número de epochs que, em alguns casos, chegou a ser ampliado para 5000, 10000 ou até 20000.

Como todos os dados são positivos, as funções de transferência usadas foram a logística (no MATLAB, *logsig*) entre a camada de entrada e a camada oculta e a linear (no MATLAB, *purelin*) entre a camada oculta e a camada de saída. Nestes programas, o *software* coloca como padrão de saída a letra latina t . Em tempo, ele usa como matriz dos pesos entre a camada de entrada e a camada oculta a sigla IW (no capítulo 2, a notação usada foi Z , conforme a Figura 8) e a matriz de limiar correspondente a notação b e como matriz dos pesos

entre a camada oculta e a camada de saída foi usada a sigla LW (novamente, no capítulo 2 a notação usada foi W , de acordo com a Figura 8) e a matriz de limiar correspondente a mesma notação b . O resultado da simulação é denotado pela letra latina a .

Para a validação desta metodologia e conseqüentemente para garantir a efetiva aplicação das redes neurais artificiais à indústria de pisos e revestimentos cerâmicos do PCSG, a solução foi a de que encontrada, numa temperatura de queima (1000° C, 1020° C, 1040° C e 1060° C) para as cinco variáveis físicas, ou nas temperaturas de queima de 1020° C, 1040° C e 1060° C, para as oito variáveis, um valor convergente compatível com o erro (mse) pré-estabelecido (goal), ou ainda, compatível com o padrão especificado originalmente determinado, as matrizes de pesos encontradas, LW e IW , junto com as matrizes de limiares, seriam então aplicadas às outras temperaturas de queima. Caso os resultados fossem conformes com o padrão de saída, ou ainda, dentro das especificações da norma NBR 13818 (ABNT, 1997), a validação desta metodologia estaria comprovada.

4. RESULTADOS E DISCUSSÕES

4.1. Introdução

Em testes preliminares para viabilizar se uma rede neural artificial e o algoritmo de aprendizado, contudo com uma padronização dos valores das tabelas de dados para que todos eles ficassem restritos ao intervalo real $[0,1]$ (observado que os valores das tabelas são todos positivos e que a função logística assume somente valores positivos dentro do mesmo intervalo real), iniciou-se o processo de análise com a regra de aprendizado *backpropagation*, no seu formato básico mas, como não se conseguiu um resultado satisfatório, avançou-se com a inclusão das variações ao método até que fosse encontrado um resultado que pudesse garantir a validade do método e, por consequência, ficasse comprovada a hipótese deste trabalho. Além disto, o processo deve ser viável, isto é, que o trabalho de pesquisa por parte da indústria consuma pouco tempo, seja de fácil manipulação e que os resultados sejam rigorosos para que se atinja um excelente controle de qualidade dos pisos e revestimentos cerâmicos nas indústrias incluídas no PCSG.

4.2. Regra de Aprendizado *Backpropagation* (Formato Básico)

Escolhidas a rede neural artificial Perceptron de três camadas, a regra de aprendizado *backpropagation* e o *software* MATLAB 7.0, o processo de aplicação envolveu inicialmente a regra de aprendizado na sua forma básica (*traingd*) às tabelas de dados dos ANEXOS E, F, G, H, I, J e K. Para os dados do ANEXO E que envolve cinco variáveis físicas e temperatura de queima em 1000°C foram determinados os parâmetros $\text{show} = 200$, $\text{lr} = 0.05$, $\text{epochs} = 2000$ e $\text{goal} = 1\text{e-}5$. A performance do programa que corresponde ao cálculo do erro médio quadrático (*mse*) e aparece como valor inferior ao parâmetro *goal* foi encerrado após a realização de três testes, pois os resultados obtidos foram de que para $N = 2$ neurônios até $N = 29$ neurônios na camada oculta não ocorreu nenhum indício de convergência e o *mse* ficou preso num mínimo local (armadilha) com um valor extremamente alto igual a 55090.8. Com $N = 30, 31$ e 34 neurônios, além do valor anterior, foi encontrado um segundo valor como mínimo local, também muito alto. Com $N = 32, 33$ e 35 neurônios foram encontrados até três mínimos locais diferentes, sempre com valores altíssimos, e, inclusive, uma tendência de máximo absoluto em completa divergência.

Para os dados do ANEXO F (cinco variáveis físicas) com temperatura de queima igual a 1020° C foram utilizados os mesmos parâmetros e as mesmas condições. Os resultados encontrados foram de que para $N = 2$ até $N = 31$ neurônios na camada oculta, o mse ficou preso no mesmo mínimo local do caso anterior (55090.8), da mesma forma que com $N = 33$, 34 e 35 neurônios. Quando $N = 32$ neurônios ocorreu uma tendência de divergência (máximo absoluto).

Em virtude destes resultados, para os dados das tabelas dos ANEXOS G e H, submetidos aos mesmos parâmetros e condições o processo foi aplicado somente para $N = 5$, 10, 15, 20, 25, 30 e 35 neurônios na camada oculta e, conforme o que se esperava, em todos os casos, o mse (goal) ficou preso no mesmo mínimo local de 55090.8, com exceção da tabela do ANEXO H, onde quando $N = 30$ neurônios, ocorreu novamente um resultado divergente.

Em seguida, para as tabelas de dados dos ANEXOS I, J e K, agora com oito variáveis físicas, mas com os mesmos parâmetros e condições, o processo foi iniciado com os dados da tabela do ANEXO I (temperatura de queima de 1020° C) e aplicados de $N = 2$ até $N = 35$ neurônios na camada oculta, mas nada mudou, o mse ficou da mesma forma preso num mínimo local, agora com o valor igual a 38546.7, ainda muito alto, com uma única exceção quando $N = 34$ neurônios, onde ocorreu uma divergência. Com estes resultados, para os outros ANEXOS, o processo foi aplicado somente para $N = 5$, 10, 15, 20, 25, 30 e 35 neurônios na camada oculta e todos indistintamente ficaram presos no mesmo mínimo local de 38546.7, com uma única exceção, para $N = 30$ neurônios do ANEXO J onde, novamente, ocorreu a divergência.

Onde se concluiu que depois de efetuados todos os testes para as tabelas de dados dos ANEXOS E, F, G, H, I, J e K, a regra de aprendizado *backpropagation* no seu formato básico não permitiu a aplicação das redes neurais artificiais à indústria cerâmica, tendo em vista que em quase todos os casos o erro médio quadrático (mse) ficou sempre preso num mínimo local de valor muito alto. Houve alguns casos excepcionais, onde ao invés da esperada convergência viu-se a ocorrência da divergência do processo. Isto assim colocado, este processo foi abandonado e, em seu lugar, foi testado uma variação que, teoricamente acelera a convergência, que é o *backpropagation* com momento dentro do próprio MATLAB, conforme item a seguir.

4.3. Regra de Aprendizado *Backpropagation* com Momento (traingdm)

O método seguinte aplicado (com convergência acelerada) foi o da regra de aprendizado *backpropagation* com momento e, da mesma forma que o *software* sugere uma taxa de aprendizado pequena (próxima de zero) para a estabilidade da rede neural, ele também sugere que o momento deve ser grande (próximo de um). O valor utilizado foi $mc = 0.9$. Assim, para a modelagem da rede neural os parâmetros utilizados foram $show = 200$, $lr = 0.05$, $mc = 0.9$, $epochs = 2000$ e $goal (mse) = 1e-5$, com três testes para verificar se há algum indício de que a rede neural converge.

Para a tabela de dados do ANEXO E (5 variáveis, $1000^\circ C$) foram usados de $N = 2$ até $N = 35$ neurônios na camada oculta e, sem exceção, todos os testes ficaram presos no mesmo mínimo local e sempre igual a $mse = 55090.8$, como no item anterior deste capítulo. É interessante observar que no caso em que $N = 34$ e 35 o número de epochs ficou entre 440 e 570 e da mesma maneira o processo ficou preso na armadilha do mínimo local em dois testes dos três previstos.

Analogamente, para a tabela de dados do ANEXO F (5 variáveis, $1020^\circ C$) com $N = 2, 3, 4, \dots, 35$, o resultado foi sempre o mesmo, isto é, $mse = 55090.8$, inclusive com o fato de que o número de epochs não atingia o máximo previsto de 2000; ficou entre 440 e 570.

Com isto, para as tabelas de dados dos ANEXOS G (5 variáveis, $1040^\circ C$) e H (5 variáveis, $1060^\circ C$), o número de neurônios da camada oculta foi pré-fixado em $N = 5, 10, 15, 20, 25, 30$ e 35 e, novamente, não ocorreu nenhuma tendência de convergência.

Para a tabela de dados do ANEXO I (8 variáveis, $1020^\circ C$), inicialmente, com $N = 2, 3, 4, \dots, 35$ neurônios na camada oculta não ocorreu nenhum indício de convergência em todos os testes. Todos eles ficaram presos no mesmo mínimo local igual a $mse = 38546.7$ e da mesma maneira, para $N = 8, 17, 18, 19, 22, 23, 25, 26, 28, 29$ e 32 neurônios o valor do erro foi atingido com valores entre 440 e 570 epochs, não atingindo o máximo pré-estabelecido de 2000 epochs.

Para as tabelas dos ANEXOS J (8 variáveis, $1040^\circ C$) e K (8 variáveis, $1060^\circ C$), o mínimo local (armadilha) atingido ficou em $mse = 38546.7$ quando $N = 5, 10, 15, 20, 25, 30$ e 35 neurônios na camada oculta. No caso dos dados do ANEXO J e $N = 10, 20, 30$ e 35 neurônios e dos dados do ANEXO K com $N = 25$ e 35 neurônios o mínimo local foi atingido quando o número de epochs ficou entre 440 e 570.

Desta forma, como no caso do item anterior, esta regra não apresentou nenhum indício de convergência. Em função destes resultados, fizeram-se necessários a aplicação de processos com convergência bem mais acelerada do que este processo com momento. Foram então selecionadas as regras de aprendizado *backpropagation* resiliente e de Levenberg-Marquadt, variações da regra no formato básico, sempre dentro do MATLAB. Aqui, convém lembrar que Cintra (2003) aplicou a regra de Levenberg-Marquadt para o controle de teores de cobre e ouro no depósito de Chapada (GO); a rede se estabilizou com $N = 32$ neurônios na camada oculta.


4.4. Regra de Aprendizado *Backpropagation* Resiliente (trainrp)

Para a aplicação desta regra de aprendizado, os parâmetros de controle são apenas três: $show = 200$, $epochs = 2000$ e $goal(mse) = 1e-5$ e, como sempre inicialmente, foram realizados três testes.

Com relação à tabela de dados do ANEXO E (5 variáveis, $1000^\circ C$), iniciou-se o processo com $N = 2$ neurônios na camada oculta. Novamente, o processo ficou preso no mesmo mínimo local (armadilha) igual a 55090.8. Com $N = 3$ neurônios, o primeiro indício de convergência surgiu, apesar de ser muito lento. Por isto, o número de epochs foi ampliado para 5000 e o número de testes aumentado para 5. Para $N = 4$ neurônios, a tendência de convergência persistiu e com isso o número de epochs foi gradativamente sendo aumentado para 5000, 10000 e 20000, com o intuito de verificar a convergência do processo na direção do mínimo global. O número de testes permaneceu em 5. Mesmo assim, a convergência mostrou-se muito lenta. Os mesmos resultados se repetiram para $N = 5$ e 6 neurônios.

Quando foi fixado $N = 7$ neurônios na camada oculta, o número de testes mantido em 5, e em contrapartida o número de epochs sendo aumentado gradativamente para 5000, 10000 e 20000, apesar de algumas falhas, houve convergência rápida com apenas 242 epochs (Figura 11).

Figura 11 – Resultado encontrado para os dados do ANEXO E com $N = 7$ e 242 epochs.



Fonte: MATLAB® 7.0.

A Figura 11 acima mostra que o erro médio quadrático (mse), dentro da performance é de $8.76838e-6$. A simulação obtida pela aplicação da regra de aprendizado resiliente é recuperada pelo comando

$$a = \text{sim}(\text{net}, p), \quad (4.1)$$

onde net significa a rede, p é o padrão de entrada e matriz encontrada a é dada por

$$a = [5.5008 \ 4.0002 \ 7.0064 \ 601.9992 \ 50.9986].$$

Para efeito de comparação, o padrão pré-estabelecido para estas cinco variáveis físicas foi fixado através da matriz:

$$\text{PADRÃO}(5) = [5.5 \ 4 \ 7 \ 602 \ 51].$$

Designando por $p1$ a matriz do padrão de entrada referente aos dados da tabela do ANEXO E e, da mesma forma, $p2$ para os dados da tabela do ANEXO F, $p3$ para os dados da tabela do ANEXO G e $p4$ para os dados da tabela do ANEXO H e recuperando a matriz de

pesos IW, entre os neurônios da camada de entrada e os neurônios da camada oculta, através do comando

$$\text{celldisp}(\text{net.IW}), \quad (4.2)$$

a matriz de pesos LW, entre os neurônios da camada oculta e os neurônios da camada de saída, através do comando

$$\text{celldisp}(\text{net.LW}) \text{ e} \quad (4.3)$$

as matrizes de limiares b1 e b2, ambas através do mesmo comando

$$\text{celldisp}(\text{net.b}), \quad (4.4)$$

pode-se aplicar os resultados das fórmulas dos comandos (4.2), (4.3) e (4.4) aos dados das tabelas dos outros ANEXO F, G e H com o auxílio das seguintes fórmulas, dentro das denominações definidas no MATLAB,

$$\text{IW} * \text{pi} + \text{b1} * \text{ones}(1,5), \quad (4.5)$$

$$\text{Ai} = \text{logsig}(\text{IW} * \text{pi} + \text{b1} * \text{ones}(1,5)), \quad (4.6)$$

$$\text{Ti} = \text{LW} * \text{Ai} + \text{b2}, \quad (4.7)$$

$$i = 1, 2, 3 \text{ e } 4,$$

a matriz Ai indica a aplicação da função de transferência

$$y = \text{logsig}(x), \quad (4.8)$$

na forma matricial, e Ti, é a matriz dos padrões de saída. Neste caso, T1 é o resultado para os dados da tabela do ANEXO E, T2 referente ao ANEXO F, T3 referente ao ANEXO G e T4 referente do ANEXO H.

Aplicando-se as fórmulas (4.5), (4.6) e (4.7) às matrizes de pesos e de limiares encontradas e aos dados das tabelas dos ANEXOS E, F, G e H, chegam-se aos resultados que constam da Tabela 5.

Tabela 5 – As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 7 e 242 epochs.

Variáveis	RLQ	PF	Abs	CR	MRF
Físicas	(%)	(%)	(%)	(N)	(MPa)
a	5.5008	4.0002	7.0064	601.9992	50.9986
T1 (1000°C)	5.4943	3.9915	6.9803	601.2047	50.8284
T2 (1020°C)	6.4059	3.8566	3.6228	296.1997	21.5664
T3 (1040°C)	6.3043	3.9856	4.4235	257.7497	12.6877
T4 (1060°C)	5.3570	4.3453	6.5846	227.7777	-4.9783
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborado pelo autor.

O valor a é o resultado da simulação da rede neural, com N =7 neurônios e 242 epochs, feito pelo próprio *software*. O valor a e o valor encontrado quando a temperatura é de 1000° C (T1), referente ao teste, estão bem próximos, mas não são os mesmos valores em virtude da propagação do erro em função dos truncamentos e arredondamentos, quando o processo é calculado diretamente. No caso desta Tabela, tem-se:

$$e(\text{RLQ}) = a(\text{RLQ}) - T1(\text{RLQ}) = 5.5008 - 5.4943 = 0.0065.$$

Analogamente,

$$e(\text{PF}) = 4.0002 - 3.9915 = 0.0087;$$

$$e(\text{Abs}) = 7.0064 - 6.9803 = 0.0261;$$

$$e(\text{CR}) = 601.9992 - 601.2047 = 0.7945; e$$

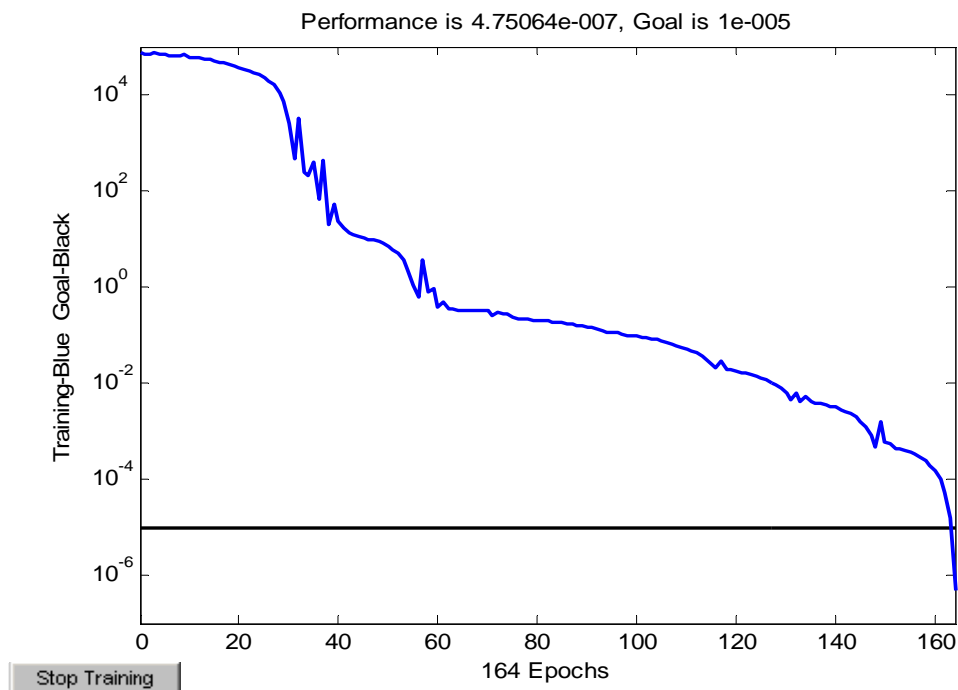
$$e(\text{MRF}) = 50.9986 - 50.8284 = 0.1702.$$

É um erro que, infelizmente, é inerente ao processo e não há como evitá-lo. Este resultado não pode ser usado em virtude dos dados das linhas 3, 4 e 5 e das colunas 5 e 6, constantes da Tabela 5, onde apareceu até um valor negativo para a variável física MRF quando a temperatura de queima é de 1060° C (T4). É bom lembrar que a norma NBR 13818 (ABNT, 1997) especifica que $6 \leq \text{Abs} < 10$, que $\text{CR} > 500\text{N}$ e que $\text{MRF} > 18\text{MPa}$.

Continuando o processo, para $N = 8$ e 9 neurônios, os resultados repetiram uma convergência muito lenta e nada pode ser aproveitado. Com $N = 10, 11, \dots, 22$ neurônios, o número de testes foi aumentado para 10, enquanto que em alguns casos o número de epochs chegou a 20000, mas nenhum resultado pode ser usado. A partir de $N = 23$ neurônios na camada oculta o método apresentou novamente uma convergência rápida e com isso o número de epochs para os 10 testes foi fixado em 5000. A melhor solução ocorreu quando $N = 34$ neurônios, com 164 epochs e performance (mse) = $4.75064e-7$, cujos dados podem ser vistos na Figura 12 e constam da Tabela 6.

Nesta Tabela 6, o resultado inconsistente é o valor da variável física Abs para a temperatura de queima em 1060°C , pois contrariando a tendência de queda, ultrapassou o valor da escala de classificação do grupo BIIb. É bom observar que para $N = 35$ neurônios, a convergência ocorreu com apenas 122 epochs, mas os resultados não foram convenientes, como pode ser visto na Tabela 7. Também, devem ser observados os erros médios quadráticos (mse).

Figura 12 – Resultado encontrado para os dados do ANEXO E com $N = 34$ e 164 epochs.



Fonte: MATLAB® 7.0.

Tabela 6 – As fórmulas (4.5), (4.6) e (4.7) aplicadas as dados dos ANEXOS E, F, G e H, com N = 34 e 164 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
T1 (1000°C)	5.5129	4.0126	7.0096	602.3708	51.2143
T2 (1020°C)	6.2948	3.5409	3.8028	513.9377	35.6558
T3 (1040°C)	6.9630	3.5255	3.2918	539.5973	44.8043
T4 (1060°C)	6.6550	3.6279	12.3915	550.7220	39.3721
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Tabela 7 – As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 35 e 122 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
T1 (1000°C)	5.4958	3.9969	6.9857	601.9150	50.9923
T2 (1020°C)	7.7770	4.2938	4.9043	446.7413	36.9043
T3 (1040°C)	8.2346	4.2443	2.9948	452.1809	44.2455
T4 (1060°C)	7.8101	4.6059	1.7728	480.7872	38.6263

Fonte: Elaborada pelo autor.

Em função dos resultados anteriores, a partir da tabela de dados do ANEXO F (cinco variáveis físicas e temperatura de queima de 1020° C), fixaram-se os parâmetros de controle do MATLAB em show = 200, epochs = 5000 e goal (mse) = 1e-5 e, também, o número de testes em 10. Com isto, para o ANEXO F, encontraram-se os dados da Tabela 8.

Para analisar a estabilidade da rede, o número de neurônios na camada oculta foi sendo aumentado gradativamente e os resultados foram incluídos na Tabela 9 (complemento da anterior).

Tabela 8 – Aplicação do método resiliente aos dados do ANEXO F.

N	Performance (mse)	Observações
2	Mínimo local (10 testes)	55090.8
3	Mínimo local (10 testes)	55090.8
4	1 teste convergente	-
5	1 teste convergente	-
6	2 testes convergentes	-
7	2 testes convergentes	-
8	2 testes convergentes	-
9	4 testes convergentes	-
10	6 testes convergentes	-
11	6 testes convergentes	-
12	7 testes convergentes	-
13	7 testes convergentes	-
14	8 testes convergentes	-
15	10 testes convergentes	Número de epochs muito alto (3997)
16	8 testes convergentes	-
17	9 testes convergentes	-
18	9 testes convergentes	-
19	9 testes convergentes	-
20	10 testes convergentes	Número de epochs muito alto
21	10 testes convergentes	Número de epochs muito alto (2259)
22	10 testes convergentes	Número de epochs muito alto
23	10 testes convergentes	Número de epochs muito alto
24	10 testes convergentes	Número de epochs muito alto
25	10 testes convergentes	Número de epochs muito alto
26	10 testes convergentes	Número de epochs muito alto
27	10 testes convergentes	(88)
28	10 testes convergentes	Número de epochs muito alto


Fonte: Elaborada pelo autor.

Tabela 9 - Complementação da Tabela 8.

N	Performance	Observações
29	10 testes convergentes	Número de epochs muito alto
30	10 testes convergentes	Número de epochs muito alto
31	10 testes convergentes	Número de epochs muito alto
32	10 testes convergentes	Número de epochs muito alto
33	9 testes convergentes	(83)
34	10 testes convergentes	Número de epochs muito alto
35	10 testes convergentes	Número de epochs muito alto
40	10 testes convergentes	Número de epochs muito alto
45	10 testes convergentes	Número de epochs muito alto
50	10 testes convergentes	Número de epochs muito alto
60	10 testes convergentes	Número de epochs muito alto
70	10 testes convergentes	Número de epochs muito alto
80	10 testes convergentes	Número de epochs muito alto
90	10 testes convergentes	(60)
100	10 testes convergentes	Número de epochs muito alto

Fonte: Elaborada pelo autor.

Ficou bem evidente nas Tabelas 8 e 9 que a regra de aprendizado *backpropagation* resiliente é de convergência rápida, pois na maioria dos casos em 10 testes foram encontrados 10 testes convergentes, apesar de que na maioria das vezes o número de epochs era muito alto (acima de 2259, no caso, pois quando $N = 15$ neurônios, o menor número de epochs foi de 3997, para $N = 21$ neurônios, 2259 epochs, para $N = 24$ neurônios, 2403 epochs e para $N = 28$ neurônios, 3611 epochs). Quando foram aplicadas as fórmulas (4.5), (4.6) e (4.7) com estes dados os resultados não foram nem mesmo satisfatórios. Entretanto, quando $N = 27$ neurônios na camada oculta e com 88 epochs, quando $N = 33$ neurônios e 83 epochs e, finalmente, quando $N = 90$ neurônios e 60 epochs apareceram as melhores soluções e elas constam das Tabelas 10, 11 e 12. As Figuras 13, 14 e 15 mostram os gráficos em correspondência com as Tabelas 10, 11 e 12, respectivamente.

Figura 13 – Resultado encontrado para os dados do ANEXO F, com N = 27 e 88 epochs.


Fonte: MATLAB® 7.0.

Tabela 10 – As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 27 e 88 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
T1 (1000°C)	3.8176	4.3852	9.8580	341.7696	20.7748
T2 (1020°C)	5.4917	4.0012	6.9926	601.7553	50.8131
T3 (1040°C)	7.2374	4.0660	10.9442	598.5219	55.0452
T4 (1060°C)	7.0804	4.1405	19.0759	597.0924	55.0565
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 14 – Resultado encontrado para os dados do ANEXO F, com N = 33 e 83 epochs.




Fonte: MATLAB® 7.0.

Tabela 11 – As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 33 e 83 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
T1 (1000°C)	4.2713	4.2152	9.9552	492.0558	34.1350
T2 (1020°C)	5.4974	3.9935	6.9875	601.9989	50.9171
T3 (1040°C)	7.2452	4.0279	5.7282	607.0999	59.1992
T4 (1060°C)	8.1126	4.0150	11.0738	610.0570	54.9349
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 15 – Resultado encontrado para os dados do ANEXO F, com n = 90 e 60 epochs.



Fonte: MATLAB® 7.0.

Tabela 12 – As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 90 e 60 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
T1 (1000°C)	4.1489	3.6117	9.0583	572.1501	33.9442
T2 (1020°C)	5.4955	4.0015	7.0058	601.8821	50.9997
T3 (1040°C)	5.7914	3.9837	4.1276	603.5703	63.6037
T4 (1060°C)	6.2612	4.0810	1.3956	603.4972	73.9983
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Mesmo assim, fica evidente, que as Tabelas 10, 11 e 12 mostram valores que não atendem as especificações técnicas da ABNT, apesar de terem sido obtidos como sendo os melhores resultados dos testes.

Com relação aos dados da tabela do ANEXO G (5 variáveis físicas e temperatura de queima de 1040°C), foram mantidos os mesmos parâmetros de controle do MATLAB, ou seja, show = 200, epochs = 5000 e goal (mse) = 1e-5. O processo foi aplicado inicialmente para N = 5, 10, 15, 20, 25, 30 e 35 neurônios na camada oculta, cujos resultados são mostrados na Tabela 13.

Tabela 13 – Aplicação do método resiliente aos dados do ANEXO G.

N	Performance (mse)	Observações
5	Mínimo local	55090.8
10	Mínimo local	55090.8
15	Mínimo local	55090.8
20	6 testes convergentes	Número de epochs muito alto
25	10 testes convergentes	Número de epochs muito alto
30	9 testes convergentes	Número de epochs muito alto
35	10 testes convergentes	Número de epochs muito alto

Fonte: Elaborada pelo autor.

Em virtude dos resultados nada satisfatórios mostrados pela Tabela 13, foi realizada uma complementação para testar a estabilidade da rede neural e os dados constam da Tabela 14.

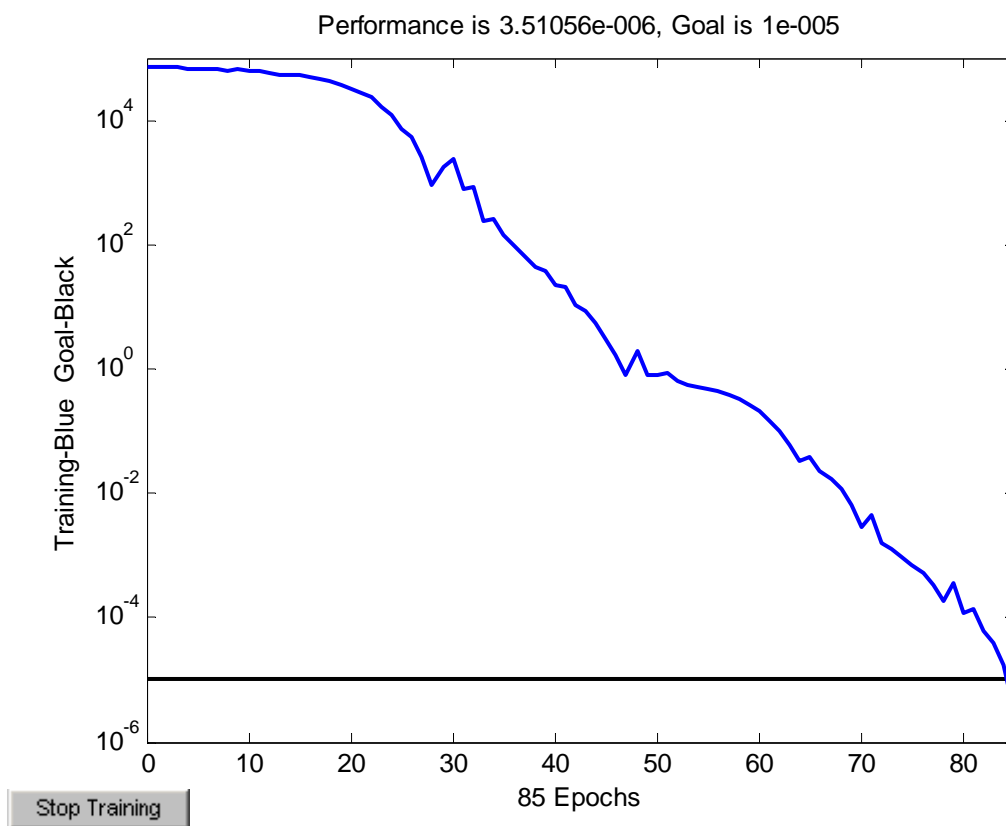
Tabela 14 – Complementação dos dados da Tabela 13.

N	Performance (mse)	Observações
21	9 testes convergentes	Número de epochs muito alto
22	8 testes convergentes	Número de epochs muito alto
23	9 testes convergentes	Número de epochs muito alto
24	10 testes convergentes	Número de epochs muito alto
26	10 testes convergentes	Número de epochs muito alto
27	10 testes convergentes	(85)
28	8 testes convergentes	Número de epochs muito alto
29	10 testes convergentes	Número de epochs muito alto
31	9 testes convergentes	Número de epochs muito alto
32	10 testes convergentes	Número de epochs muito alto
33	10 testes convergentes	(82)
34	10 testes convergentes	(73)

Fonte: Elaborada pelo autor.

As melhores soluções aconteceram quando $N = 27$ neurônios com 85 epochs, quando $N = 33$ neurônios com 82 epochs e quando $N = 34$ com 73 epochs. Novamente, quando o número de epochs é muito alto, os resultados não permitem as suas aplicações no processo, por isso, os resultados anteriores foram considerados os melhores. As Tabelas 15, 16 e 17 mostram os dados encontrados quando da aplicação das fórmulas (4.5), (4.6) e (4.7) às tabelas de dados dos ANEXOS E, F, G e H. Em correspondência aos dados destas Tabelas, são mostradas as Figuras 16, 17 e 18.

Figura 16 - Resultado encontrado para os dados do ANEXO G, com $N=27$ e 85 epochs.




Fonte: MATLAB® 7.0.

Tabela 15 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 27 e 85 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
T1 (1000°C)	3.3854	4.5142	9.9596	580.4700	39.6761
T2 (1020°C)	3.9784	4.0617	5.2503	596.7161	44.6927
T3 (1040°C)	5.5046	4.0054	7.0062	601.9684	51.0574
T4 (1060°C)	6.1106	4.0444	12.5082	603.4387	52.6749
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 17 - Resultado encontrado para os dados do ANEXO G, com N = 33 e 82 epochs.




Fonte: MATLAB® 7.0.

Tabela 16 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 33 e 82 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
T1 (1000°C)	5.3218	2.9787	29.6079	601.0522	16.5579
T2 (1020°C)	9.3116	3.7019	17.2727	597.8778	29.0875
T3 (1040°C)	5.4951	3.9957	6.9866	602.0411	50.6939
T4 (1060°C)	0.4765	3.5444	7.9963	602.7652	93.1350
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborado pelo autor.

Figura 18 - Resultado encontrado para os dados do ANEXO G, com N = 34 e 73 epochs.



Fonte: MATLAB® 7.0.

Tabela 17 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 34 e 73 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
T1 (1000°C)	2.3421	3.1560	30.2824	469.8984	16.1915
T2 (1020°C)	6.1257	3.7758	15.6994	599.6521	48.3919
T3 (1040°C)	5.4791	4.0018	6.9984	602.0983	50.7668
T4 (1060°C)	6.4976	4.0933	0.1437	601.9720	101.8092
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborado pelo autor.

Dentre as Tabelas anteriores, é visível que o melhor resultado ocorreu com os dados da Tabela 15. Os dados das outras duas Tabelas estão, em alguns casos, bem afastados dos valores especificados em norma da ABNT.

Neste momento, chega-se ao ANEXO H que exibe cinco variáveis físicas e temperatura de queima de 1060° C. Os parâmetros de controle permanecem com os mesmos valores, ou seja, show = 200, epochs = 5000 e goal (mse) = 1e-5. Da mesma maneira com N = 5, 10, 15, 20, 25, 30 e 35 foram efetuados 10 testes, conforme Tabela 18.

Tabela 18 – Aplicação do método resiliente aos dados do ANEXO H.

N	Performance (mse)	Observações
5	Mínimo local	55090.8
10	Mínimo local	55090.8
15	4 testes convergentes	Muito lenta
20	4 testes convergentes	Muito lenta
25	5 testes convergentes	Muito lenta
30	8 testes convergentes	Lenta
35	7 testes convergentes	Lenta

Fonte: Elaborado pelo autor.


Em função dos indícios de convergência do processo, a Tabela 18 foi complementada com a Tabela 19, a seguir.

Tabela 19 – Complementação dos dados da Tabela 18.

N	Performance (mse)	Observações
36	9 testes convergentes	
37	7 testes convergentes	
38	10 testes convergentes	(94), (215)
39	8 testes convergentes	
40	9 testes convergentes	(118), (126), (127)

Fonte: Elaborada pelo autor.

Os resultados encontrados estão expostos nas Tabelas 20, 21, 22, 23, 24 e 25 e, em correspondência, os erros mínimos quadráticos (mse) junto às Figuras 19, 20, 21, 22, 23 e 24.

Figura 19 - Resultado encontrado para os dados do ANEXO H, com N = 38 e 215 epochs.


Fonte: MATLAB® 7.0.

Tabela 20 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 38 e 215 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	5.4978	4.0028	6.9992	602.0013	51.0046
T1 (1000°C)	-1.4555	3.4268	14.7742	15.5033	1.8843
T2 (1020°C)	0.0025	4.1779	18.7575	596.9313	8.7448
T3 (1040°C)	2.8703	4.3912	14.3653	596.4031	6.8872
T4 (1060°C)	5.4825	3.9943	6.9943	601.5592	50.9025
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 20 - Resultado encontrado para os dados do ANEXO H, com N = 38 e 94 epochs.




Fonte: MATLAB® 7.0.

Tabela 21 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 38 e 94 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	5.5026	3.9951	7.0000	602.0000	51.0040
T1 (1000°C)	3.5936	4.0055	6.4765	489.6407	21.5601
T2 (1020°C)	4.7546	3.9940	6.1944	537.3637	32.5325
T3 (1040°C)	5.4814	3.8803	5.0144	582.0974	44.3654
T4 (1060°C)	5.5026	3.9953	6.9990	601.6696	50.9433
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 21 - Resultado encontrado para os dados do ANEXO H, com N =40 e 127 epochs.




Fonte: MATLAB® 7.0.

Tabela 22 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 40 e 127 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	5.4990	4.0050	7.0012	602.0003	51.0005
T1 (1000°C)	4.1497	3.9542	6.8460	541.4200	20.0360
T2 (1020°C)	4.7328	4.0004	4.6428	586.6600	32.9680
T3 (1040°C)	5.6274	4.0113	5.6135	599.3200	45.1340
T4 (1060°C)	5.5071	4.0079	7.0021	602.2700	51.2140
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 22 - Resultado encontrado para os dados do ANEXO H, com N = 40 e 126 epochs.




Fonte: MATLAB® 7.0.

Tabela 23 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 40 e 126 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	5.4997	4.0040	6.9970	601.9994	50.9991
T1 (1000°C)	3.7022	3.8332	7.3212	599.5800	18.8490
T2 (1020°C)	4.4276	3.9802	5.8040	602.0100	32.0970
T3 (1040°C)	5.0879	3.9885	4.7899	602.0100	35.6620
T4 (1060°C)	5.5001	4.0043	6.9975	602.0000	51.1200
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 23 - Resultado encontrado para os dados do ANEXO H, com N = 40 e 118 epochs.




Fonte: MATLAB® 7.0.

Tabela 24 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 40 e 118 epochs.

Variáveis Físicas	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	5.5026	3.9968	6.9996	602.0003	51.0016
T1 (1000°C)	6.0240	4.6738	8.0256	433.9165	29.3281
T2 (1020°C)	6.1732	4.1264	3.6558	314.9238	9.6733
T3 (1040°C)	6.3421	3.8372	3.2981	556.7295	35.5169
T4 (1060°C)	5.4954	4.0008	7.0008	602.1945	50.9625
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 24 - Resultado encontrado para os dados do ANEXO H, com N = 40 e 78 epochs.



Fonte: MATLAB® 7.0.

Tabela 25 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS E, F, G e H, com N = 40 e 78 epochs.

Variáveis	RLQ	PF	Abs	CR	MRF
Físicas	(%)	(%)	(%)	(N)	(MPa)
a	5.5063	4.0001	6.9978	601.9992	50.9997
T1 (1000°C)	4.7132	4.3448	5.3693	547.1919	21.5839
T2 (1020°C)	5.2488	4.0439	3.4622	502.2522	25.9255
T3 (1040°C)	5.7853	4.0347	4.0992	585.9482	41.8421
T4 (1060°C)	5.5167	4.0045	7.0017	602.0606	51.0640
PADRÃO 5	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Em resumo, com cinco variáveis físicas, como constam das tabelas de dados dos ANEXOS E, F, G e H, os melhores resultados ocorreram para a temperatura de queima de 1000° C, Tabela 6 (Figura 12), quando N = 34 neurônios com 164 epochs, entretanto, três valores da variável Abs ficaram fora dos limites preconizados pela ABNT ($6 \leq \text{Abs} < 10$). Na temperatura de queima de 1020° C, Tabela 11 (Figura 14), a melhor solução apresentada pela rede neural com o método resiliente surgiu quando N = 33 e 83 epochs, apesar de que dois valores da variável Abs ficaram fora dos limites citado anteriormente e de que um valor da variável CR ficou abaixo de 500N. Com a temperatura de queima em 1040° C, Tabela 15 (Figura 17), encontraram-se somente dois valores da variável Abs fora dos limites já citado e, neste caso, pode-se dizer que a resposta foi relativamente boa porque as variáveis CR e MRF encontradas, ambas, estão na ordem crescente. E, finalmente, com a temperatura de queima em 1060° C, Tabela 22 (Figura 21), ocorreu a melhor de todas as soluções quando N = 40 neurônios e 126 epochs, tendo em vista que os desvios entre a simulação a e a resposta fornecida pela rede T4 foram muito pequenos, as respostas da rede para a variável Abs apareceram no sentido decrescente, com exceção do último dado em T4, (os valores da variável ficaram bem próximos), enquanto que os valores da variável MRF, apesar de estarem afastados, da mesma forma que a variável CR se apresentaram dentro dos limites impostos pela norma NBR 13818 (ABNT, 1997) e no sentido crescente. Com estes resultados pode-se concluir que a melhor resposta da rede neural artificial, com a regra de aprendizado *backpropagation* resiliente, para as cinco variáveis RLQ, PF, Abs, CR e MRF, foi obtida quando a temperatura de queima foi de 1060° C, a maior de todas, o que valida o processo para todos os anexos com cinco variáveis.

Isto colocado, em sequência continuou-se com a aplicação do processo para as tabelas de dados dos ANEXOS I, J e K, agora com oito variáveis físicas, que são: DP, DAS, RLS, RLQ, PF, Abs, CR e MRF. As temperaturas de sinterização são três: 1020° C, 1040° C e 1060° C, respectivamente, para cada um dos anexos.

Pelos indícios de convergência do processo resiliente nos quatro casos já tratados, os parâmetros de controle continuam com os mesmos valores, ou seja, show = 200, epochs = 5000 e goal (mse) = 1e-5. Continuam, também, os testes num total de 10 e o número de neurônios na camada oculta para a temperatura de queima de 1020° C será N = 2, 3, 4,..., 35 e para as outras duas temperaturas de queima, a análise será feita, inicialmente, com N = 5, 10, 15, 20, 25, 30 e 35 neurônios.

Começando com a tabela de dados do ANEXO I, a aplicação do método resiliente forneceu os dados da Tabela 26.

Tabela 26 – Aplicação do método resiliente aos dados do ANEXO I.

N	Performance (mse)	Observações
2	Vários mínimos locais	Desiguais
3	1 teste convergente	-
4	Vários mínimos locais	Desiguais
5	Vários mínimos locais	Desiguais
6	Vários mínimos locais	Desiguais
7	Vários mínimos locais	Desiguais
8	1 teste convergente	-
9	2 testes convergentes	-
10	Vários mínimos locais	Desiguais
11	Vários mínimos locais	Desiguais
12	Vários mínimos locais	Desiguais
13	1 teste convergente	-
14	2 testes convergentes	-
15	2 testes convergentes	-
16	Vários mínimos locais	Desiguais
17	Vários mínimos locais	Desiguais
18	4 testes convergentes	-
19	2 testes convergentes	Número de epochs muito alto
20	3 testes convergentes	Número de epochs muito alto
21	3 testes convergentes	Número de epochs muito alto
22	2 testes convergentes	Número de epochs muito alto
23	3 testes convergentes	-
24	Vários mínimos locais	Desiguais
25	3 testes convergentes	-
26	3 testes convergentes	-
27	4 testes convergentes	-
28	3 testes convergentes	-
29	2 testes convergentes	-
30	6 testes convergentes	-
31	3 testes convergentes	-
32	3 testes convergentes	-
33	5 testes convergentes	-
34	3 testes convergentes	-
35	4 testes convergentes	-

Fonte: Elaborada pelo autor.


Há convergência, mas com muitas falhas e com um número de epochs muito alto, por isto esta Tabela foi complementada com a seguinte Tabela 27.

Tabela 27 – Complementação dos dados da Tabela 26.

N	Performance (mse)	Observações
36	6 testes convergentes	Número de epochs muito alto
37	5 testes convergentes	Número de epochs muito alto
38	4 testes convergentes	Número de epochs muito alto
39	6 testes convergentes	Número de epochs muito alto
40	4 testes convergentes	Número de epochs muito alto
41	5 testes convergentes	Número de epochs muito alto
42	6 testes convergentes	Número de epochs muito alto
43	5 testes convergentes	Número de epochs muito alto
44	7 testes convergentes	Número de epochs muito alto
45	5 testes convergentes	Número de epochs muito alto
50	5 testes convergentes	Número de epochs muito alto
55	5 testes convergentes	Número de epochs muito alto
56	7 testes convergentes	(64)
57	6 testes convergentes	Número de epochs muito alto
58	8 testes convergentes	(158)
59	8 testes convergentes	Número de epochs muito alto
60	10 testes convergentes	(263), (269)
61	8 testes convergentes	Número de epochs muito alto
62	6 testes convergentes	Número de epochs muito alto

Fonte: Elaborado pelo autor.

Foram selecionados os melhores resultados como sendo aqueles que ocorreram quando $N = 56$ neurônios na camada oculta com 64 epochs, quando $N = 58$ neurônios com 158 epochs e quando $N = 60$ neurônios com 263 e 269 epochs. Eles constituem as Tabelas 28, 29, 30 e 31. As fórmulas (4.5), (4.6) e (4.7) podem ser usadas agora com $i = 1, 2$ e 3 . Em sequência, as Figuras 25, 26, 27 e 28 correspondentes aos dados das Tabelas 28, 29, 30 e 31.


Figura 25 - Resultado encontrado para os dados do ANEXO I, com N = 56 e 64 epochs.

Fonte: MATLAB® 7.0.

Tabela 28 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 56 e 64 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	1.9962	1.9063	0.3006	5.4959	4.0002	7.0001	601.9990	51.0000
T1 (1020°C)	2.0005	1.9102	0.3007	5.5018	4.0099	7.0311	601.7692	51.1454
T2 (1040°C)	1.9994	1.9104	0.3460	6.8791	4.1394	5.0437	605.7800	59.1417
T3 (1060°C)	2.0037	1.9147	0.2936	7.4347	4.1704	2.2264	607.8878	64.8783
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborado pelo autor.

Figura 26 - Resultado encontrado para os dados do ANEXO I, com N = 58 e 158 epochs.


Fonte: MATLAB® 7.0.

Tabela 29 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 58 e 158 epochs.

Variáveis Físicas	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	2.0052	1.8937	0.3000	5.4980	4.0023	6.9986	602.0000	51.0002
T1 (1020°C)	2.0062	1.8947	0.3001	5.5012	4.0022	7.0027	601.9548	51.0176
T2 (1040°C)	2.0100	1.9111	0.3287	6.9740	4.0842	4.7241	601.9124	62.5422
T3 (1060°C)	2.0185	1.9173	0.2894	7.5741	4.0828	3.0673	583.6256	68.3699
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 27 - Resultado encontrado para os dados do ANEXO I, com N = 60 e 263 epochs.




Fonte: MATLAB® 7.0.

Tabela 30 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 60 e 263 epochs.

Variáveis Físicas	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	2.0070	1.8947	0.3004	5.4988	3.9994	7.0000	602.0000	51.0003
T1 (1020°C)	1.9989	1.8872	0.2995	5.4776	3.9852	6.9785	601.8094	50.7172
T2 (1040°C)	1.9983	1.8591	0.2901	5.9603	3.8205	5.9671	579.4804	64.9740
T3 (1060°C)	2.0018	1.8705	0.3239	5.8842	4.0053	4.2970	571.7003	85.8344
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 28 - Resultado encontrado para os dados do ANEXO I, com N = 60 e 269 epochs.

Fonte: MATLAB® 7.0.

Tabela 31 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 60 e 269 epochs.

Variáveis Físicas	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	2.0066	1.8940	0.3002	5.5000	4.0000	6.9998	602.0000	51.0001
T1 (1020°C)	2.0054	1.8928	0.2997	5.4953	3.9968	6.9973	601.5843	50.9632
T2 (1040°C)	2.0059	1.8857	0.2903	6.7786	3.9716	3.9624	600.7590	67.0975
T3 (1060°C)	2.0107	1.8934	0.3022	7.6396	4.1245	1.8284	589.5212	99.2379
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Com relação aos dados da tabela do ANEXO J (8 variáveis físicas e temperatura de queima de 1040° C), continuou-se com show = 200, epochs = 5000, goal (mse) = 1e-5, 10 testes e N = 5, 10, 15, 20, 25, 30 e 35, onde foram encontrados os valores da Tabela 32.

Tabela 32 – Aplicação do método resiliente aos dados do ANEXO J.

N	Performance (mse)	Observações
5	1 teste convergente	-
10	1 teste convergente	-
15	Vários mínimos locais	Desiguais
20	1 teste convergente	-
25	6 testes convergentes	-
30	2 testes convergentes	-
35	3 testes convergentes	-

Fonte: Elaborada pelo autor.

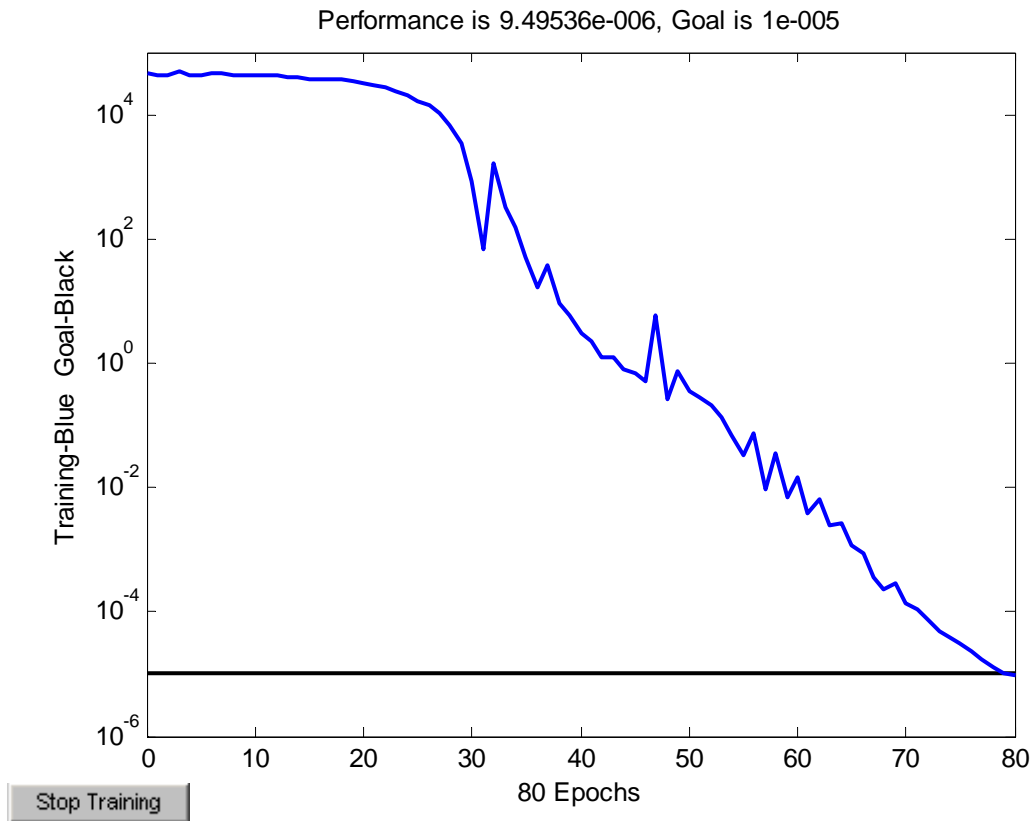
Houve necessidade de complementação devido aos indícios de convergência e os dados constam da Tabela 33.

Tabela 33 – Complementação dos dados da Tabela 32.

N	Performance (mse)	Observações
40	6 testes convergentes	-
45	6 testes convergentes	-
50	6 testes convergentes	-
55	8 testes convergentes	-
60	7 testes convergentes	(80)
61	7 testes convergentes	-
62	10 testes convergentes	(74), (81)
63	9 testes convergentes	(66)
64	4 testes convergentes	-
65	9 testes convergentes	(75), (167)
66	8 testes convergentes	-
67	9 testes convergentes	-

Fonte: Elaborada pelo autor.

Os resultados foram compensadores quando $N = 60$ neurônios na camada oculta e com 80 epochs; analogamente, para $N = 62$ neurônios com 74 e 81 epochs, $N = 63$ neurônios com 66 epochs e $N = 65$ neurônios com 75 e 167 epochs. Eles constam das Tabelas 34, 35, 36, 37, 38 e 39, enquanto as performances podem ser vistas através das Figuras 29, 30, 31, 32, 33 e 34.


Figura 29 - Resultado encontrado para os dados do ANEXO J, com N = 60 e 80 epochs.

Fonte: MATLAB® 7.0.

Tabela 34 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 60 e 80 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	2.0066	1.8949	0.3005	5.5014	3.9990	6.9985	601.9999	51.0001
T1 (1020°C)	2.0082	1.9004	0.3111	4.2524	3.9722	11.6430	601.6900	43.3420
T2 (1040°C)	2.0072	1.8954	0.3010	5.5052	3.9991	6.9931	602.0100	51.0660
T3 (1060°C)	2.0118	1.9005	0.2938	6.6704	4.0913	2.7039	601.0700	59.7200
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 30 - Resultado encontrado para os dados do ANEXO J, com N = 62 e 74 epochs.

Fonte: MATLAB® 7.0.

Tabela 35 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 62 e 74 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	2.0068	1.8965	0.3011	5.4992	3.9963	7.0025	601.9999	51.0001
T1 (1020°C)	2.0106	1.9011	0.3219	4.4838	4.0869	6.8584	596.5225	43.1884
T2 (1040°C)	2.0102	1.8997	0.3019	5.5122	4.0058	7.0106	602.8015	51.2447
T3 (1060°C)	2.0190	1.9102	0.3302	6.0188	4.0890	4.1550	562.3329	64.5364
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 31 - Resultado encontrado para os dados do ANEXO J, com N = 62 e 81 epochs.

Fonte: MATLAB® 7.0.

Tabela 36 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 62 e 81 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	2.0016	1.8980	0.2996	5.4975	4.0054	7.0054	601.9999	51.0001
T1 (1020°C)	2.0082	1.9035	0.3304	4.0838	3.9501	9.7248	599.7006	44.4462
T2 (1040°C)	2.0090	1.9049	0.3004	5.5243	4.0201	7.0245	602.0086	51.4463
T3 (1060°C)	2.0149	1.9137	0.3390	6.3542	4.0528	4.2268	602.4022	60.6326
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 32 - Resultado encontrado para os dados do ANEXO J, com N = 63 e 66 epochs.

Fonte: MATLAB® 7.0.

Tabela 37 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 63 e 66 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	2.0025	1.9001	0.3034	5.5032	3.9981	6.9986	602.0000	50.9999
T1 (1020°C)	2.0010	1.9005	0.3052	3.8416	3.9267	10.8099	601.7305	41.6519
T2 (1040°C)	2.0013	1.8990	0.3032	5.5010	3.9936	6.9879	602.0000	50.9413
T3 (1060°C)	2.0037	1.9022	0.3006	6.6933	4.0041	3.6489	595.6186	64.3518
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 33 - Resultado encontrado para os dados do ANEXO J, com N = 65 e 75 epochs.

Fonte: MATLAB® 7.0.

Tabela 38 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 65 e 75 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	1.9999	1.9029	0.2991	5.5055	3.9976	7.0041	601.9993	50.9999
T1 (1020°C)	2.0043	1.9150	0.3395	3.8566	4.0272	11.3280	582.1600	39.4020
T2 (1040°C)	1.9998	1.9028	0.2988	5.5059	3.9965	7.0027	603.2200	50.9320
T3 (1060°C)	2.0108	1.9132	0.3398	6.9754	4.0909	1.5772	618.0100	86.4140
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 34 - Resultado encontrado para os dados do ANEXO J, com N = 65 e 167 epochs.

Fonte : MATLAB® 7.0.

Tabela 39 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 65 e 167 epochs.

Variáveis Físicas	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
a	1.9932	1.9056	0.2998	5.5001	4.0010	7.0002	602.0000	51.0000
T1 (1020°C)	1.9830	1.8752	0.3076	3.8657	3.6533	10.5070	599.0200	42.6860
T2 (1040°C)	1.9926	1.9052	0.2999	5.4961	4.0017	7.0030	602.6100	50.9790
T3 (1060°C)	2.0014	1.9084	0.2950	7.4494	3.7336	3.5958	578.0500	54.4640
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Finalmente, para os dados da tabela do ANEXO K (8 variáveis físicas e temperatura de sinterização de 1060° C), usaram-se os mesmos valores show = 200, epochs = 5000 e goal (mse) = 1e-5, 10 testes e N = 5, 10, 15, 20, 25, 30 e 35. Quando da aplicação do método resiliente foram encontrados os valores que constam da Tabela 40.

Tabela 40 – Aplicação do método resiliente aos dados do ANEXO K.

N	Performance (mse)	Observações
5	Vários mínimos locais	Desiguais
10	1 teste convergente	-
15	3 testes convergentes	-
20	2 testes convergentes	-
25	4 testes convergentes	-
30	4 testes convergentes	-
35	8 testes convergentes	-

Fonte: Elaborada pelo autor.

Em função dos indícios de convergência, houve a necessidade de complementação, conforme TABELA 41.


Tabela 41 – Complementação dos dados da Tabela 40.

N	Performance (mse)	Observações
40	6 testes convergentes	-
45	6 testes convergentes	-
50	7 testes convergentes	-
55	8 testes convergentes	(76), (92)
60	7 testes convergentes	-
65	9 testes convergentes	(65)
66	7 testes convergentes	-
67	10 testes convergentes	(69), (97)
68	9 testes convergentes	-
69	9 testes convergentes	-
70	10 testes convergentes	(81)
71	8 testes convergentes	(60)
72	9 testes convergentes	-
73	9 testes convergentes	-
74	9 testes convergentes	-

Fonte: Elaborada pelo autor.

Os resultados mostraram-se úteis quando $N = 55$ neurônios na camada oculta, com 76 e 92 epochs, quando $N = 65$ neurônios com 65 epochs, quando $N = 67$ neurônios com 69 e 97 epochs, quando $N = 70$ neurônios com 81 epochs e quando $N = 71$ neurônios com 60 epochs. Nas observações, espaço reservado nestas tabelas, nada foi colocado porque o número de epochs era muito alto; o mesmo aconteceu em todas as tabelas anteriores. Estas soluções da rede neural constam das Tabelas 42, 43, 44, 45, 46, 47 e 48 em correspondência com as Figuras 35, 36, 37, 38, 39, 40 e 41.

Figura 35 - Resultado encontrado para os dados do ANEXO K, com $N = 55$ e 76 epochs.




Fonte: MATLAB® 7.0.

Tabela 42 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 55 e 76 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	1.9946	1.9045	0.2990	5.4992	4.0043	6.9981	601.9998	51.0001
T1 (1020°C)	1.9897	1.8735	0.3225	3.2483	3.9584	9.6778	599.8834	35.1371
T2 (1040°C)	1.9910	1.8985	0.3356	4.2641	3.9230	8.7417	601.8029	40.2199
T3 (1060°C)	1.9939	1.9039	0.2985	5.4968	3.9999	6.9905	601.9747	51.0167
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 36 - Resultado encontrado para os dados do ANEXO K, com N = 55 e 92 epochs.

Fonte: MATLAB® 7.0.

Tabela 43 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 55 e 92 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	1.9957	1.9063	0.2975	5.5018	3.9977	7.0009	602.0000	50.9977
T1 (1020°C)	1.9568	1.8129	0.3608	1.5532	3.9402	11.1489	545.1705	-10.0082
T2 (1040°C)	1.9731	1.8988	0.3144	2.9577	4.0003	8.8076	473.5459	-13.1180
T3 (1060°C)	1.9936	1.9045	0.2973	5.4953	3.9947	6.9984	601.9981	50.6856
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 37 - Resultado encontrado para os dados do ANEXO K, com N = 65 e 65 epochs.

Fonte: MATLAB® 7.0.

Tabela 44 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 65 e 65 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	1.9977	1.9005	0.2997	5.4997	4.0007	7.0004	602.0045	50.9999
T1 (1020°C)	1.9878	1.8885	0.3090	3.5373	4.0022	5.8352	588.9179	39.2767
T2 (1040°C)	1.9914	1.8932	0.4073	4.7389	4.0610	6.1922	599.2251	44.6545
T3 (1060°C)	1.9972	1.9001	0.2994	5.4961	3.9981	6.9995	602.4032	50.9507
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 38 - Resultado encontrado para os dados do ANEXO K, com N = 67 e 69 epochs.

Fonte: MATLAB® 7.0.

Tabela 45 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 67 e 69 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	2.0043	1.8998	0.3028	5.5011	3.9989	6.9981	602.0006	50.9998
T1 (1020°C)	1.9987	1.8922	0.3055	3.2714	3.9207	12.0186	591.9261	38.5242
T2 (1040°C)	2.0070	1.8964	0.3493	4.1951	4.0123	9.9698	600.2105	45.7710
T3 (1060°C)	2.0045	1.9000	0.3028	5.4998	3.9985	7.0007	601.8002	50.9753
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 39 - Resultado encontrado para os dados do ANEXO K, com N = 67 e 97 epochs.

Fonte: MATLAB® 7.0.

Tabela 46 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 67 e 97 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	1.9935	1.9052	0.2998	5.5002	4.0008	7.0014	602.0000	51.0000
T1 (1020°C)	1.9906	1.8988	0.2768	6.1225	3.9056	7.2003	574.5857	55.2187
T2 (1040°C)	1.9943	1.9087	0.3497	6.2407	4.0325	7.6008	597.0215	59.8810
T3 (1060°C)	1.9947	1.9063	0.2999	5.019	4.0016	7.0037	602.3042	51.0358
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.


Figura 40 - Resultado encontrado para os dados do ANEXO K, com N = 70 e 81 epochs.

Fonte: MATLAB® 7.0.

Tabela 47 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 70 e 81 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	1.9938	1.9062	0.2994	5.5002	4.0000	6.9999	602.0000	51.0000
T1 (1020°C)	1.9875	1.8856	0.2838	4.8097	3.9479	6.5638	596.6497	39.0613
T2 (1040°C)	1.9872	1.8999	0.2849	5.5000	3.9549	6.6073	600.6902	45.8705
T3 (1060°C)	1.9931	1.9055	0.2986	5.4944	3.9982	7.0027	602.0094	50.8983
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Figura 41 - Resultado encontrado para os dados do ANEXO K, com N = 71 e 60 epochs.

Fonte: MATLAB® 7.0.

Tabela 48 - As fórmulas (4.5), (4.6) e (4.7) aplicadas aos dados dos ANEXOS I, J e K, com N = 71 e 60 epochs.

Variáveis	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
Físicas	(g/cm ³)	(g/cm ³)	(%)	(%)	(%)	(%)	(N)	(MPa)
a	1.9971	1.8997	0.3018	5.4945	4.0016	6.9947	602.0001	50.9999
T1 (1020°C)	1.9751	1.8621	0.3109	3.6305	4.1029	5.4755	601.6643	35.2209
T2 (1040°C)	1.9810	1.8857	0.3811	4.7575	4.1775	6.5362	601.7453	44.0534
T3 (1060°C)	1.9960	1.8988	0.3015	5.4909	4.0006	6.9935	602.0735	50.9426
PADRÃO 8	2	1.9	0.3	5.5	4	7	602	51

Fonte: Elaborada pelo autor.

Resumindo, os resultados para as tabelas de dados dos ANEXOS I, J e K que melhor corresponderam, às aplicações da regra de aprendizado *backpropagation* resiliente, foram para a temperatura de queima de 1020° C, os dados constantes da Tabela 30 (Figura 27), para a temperatura de queima de 1040° C, os dados que constam da Tabela 36 (Figura 31) e para a temperatura de queima de 1060° C, os dados apresentados na Tabela 47 (Figura 40). Destas três soluções, o melhor resultado surgiu para os dados correspondentes à temperatura de queima de 1060° C do ANEXO K e, novamente, para a maior temperatura de sinterização e demonstra definitivamente a validação do processo.

4.5. Regra de Aprendizado *Backpropagation* de Levenberg-Marquadt (trainlm)

Na aplicação da regra de aprendizado *backpropagation* de Levenberg-Marquadt os parâmetros de controle do MATLAB são apenas três: show = 200, epochs = 5000 e goal = 1e-5, com no caso do método anterior. Foram realizados 10 testes para verificar a estabilidade e a convergência do método. Iniciou-se o processo com o número de neurônios na camada oculta, N = 2, 3, ..., 25, acrescidos dos valores N = 30 e 35, para os dados da tabela do ANEXO E, onde as variáveis físicas são cinco e a temperatura de queima de 1000° C.

Apesar da grande expectativa neste processo ele apresentou em todos os valores de N uma convergência extremamente lenta, exigindo, no mínimo 40000 epochs para se chegar a um valor satisfatório, além de demandar um tempo razoável de utilização em um computador pessoal. Para se mostrar uma estimativa da lentidão da convergência, quando N = 22 neurônios, a cada 200 epochs a queda no valor do mse (erro médio quadrático) era da ordem

de 2 em 44000 e quando $N = 23$ neurônios, com 200 epochs o valor do mse era de 51064.8, enquanto que com 5000 epochs, o valor do mse era ligeiramente menor e igual a 51059.1, mostrando que, neste caso, o número de epochs, para se alcançar um mínimo global na vizinhança de zero, deveria ser de ordem aproximada de 43000000 (quarenta e três milhões!).

Outra situação inesperada quando da aplicação deste processo foi o fato de que em algumas passagens as matrizes de pesos ou de limiares alcançaram valores muito próximos de atingirem determinante nulo, o que leva a resultados não confiáveis, ou ainda, valores ruins de escala.

Para as tabelas de dados dos ANEXOS F, G, H, I, J e K, os dez testes foram aplicados com $N = 5, 10, 15, 20, 25, 30$ e 35 neurônios na camada oculta e observou-se em todos os casos a persistência da convergência extremamente lenta, o que não permite uma aplicação rápida deste processo à indústria de pisos e revestimentos cerâmicos do PCSG. Dessa forma, este método foi abandonado. Para a sua aplicação os dados do padrão de entrada devem ser normalizados de maneira que eles fiquem contidos dentro do intervalo real $[0,1]$. Como, no entanto, o método resiliente atendeu ao objetivo geral deste trabalho e mostrou também que a hipótese, integrante deste trabalho enunciada no capítulo 1, é verdadeira, este trabalho foi encerrado, não obstante, sabendo que além destes métodos, o próprio *software* MATLAB apresenta vários outros métodos, variações do método *backpropagation*.

4.6. Conclusões

O objetivo geral deste trabalho foi alcançado na medida em que foi encontrada a rede neural artificial direta de três camadas chamada *perceptron* (rede MLP: Multilayer Perceptron, do original em inglês), sendo uma camada de entrada (padrão de entrada), uma camada intermediária ou oculta e uma camada de saída (ou padrão de saída). No caso, o padrão de entrada (π) foram todas as tabelas de dados dos ANEXOS E, F, G, H, I, J e K, o padrão de saída para as cinco variáveis físicas foi fixado pelo vetor linha

$$\text{PADRÃO (5)} = [5.5 \ 4 \ 7 \ 602 \ 51],$$

e o padrão de saída para as oito variáveis físicas foi estabelecido por outro vetor linha

$$\text{PADRÃO (8)} = [2 \ 1.9 \ 0.3 \ 5.5 \ 4 \ 7 \ 602 \ 51].$$

A diferenciação entre uma rede e outra foi condicionada ao número de neurônios da camada oculta que, na maioria dos casos, era de $N = 2, 3, 4, \dots, 35$ ou, somente, os múltiplos de 5. Em alguns casos, atingiu o valor $N = 100$ na busca pela estabilidade e pela convergência.

Dentre quatro variações da regra de aprendizado delta generalizada (ou simplesmente *backpropagation*), todas incluídas no MATLAB, aquela que atendeu ao objetivo geral foi a regra resiliente. Com a rede MLP e a regra de aprendizado *backpropagation* resiliente, o objetivo geral foi alcançado.

Com relação à hipótese deste trabalho, resta apresentar as matrizes de pesos e de limiares encontradas, as quais permitem a aplicação das redes neurais artificiais para um controle mais rigoroso da qualidade dos produtos industriais dos pisos e revestimentos cerâmicos das indústrias do PCSG. Esta é uma das grandes vantagens da aplicação das redes neurais, pois leva em consideração que o padrão de saída pode ser determinado com bastante precisão. Os melhores resultados foram alcançados tanto para as cinco variáveis físicas como para as oito variáveis sempre na maior temperatura de queima, isto é, 1060°C . A Tabela 23 e em correspondência a Figura 22 mostram os dados para cinco variáveis. Nesta Tabela, as variáveis RLQ, PF, CR e MRF são crescentes, com uma ligeira igualdade da variável CR, enquanto a variável Abs é decrescente com exceção daquele dado referente à temperatura de queima de 1060°C .

A matriz de peso IW é de ordem 40×16 , por isso ela foi dividida em blocos. Assim,

$$IW = \begin{bmatrix} B1 & B2 \\ B3 & B4 \end{bmatrix}, \quad (4.9)$$

onde cada bloco B_i , $i = 1, 2, 3$ e 4 , é de ordem 20×8 . As outras matrizes LW, b_1 e b_2 são de mais fácil manipulação e não necessitam da divisão em blocos. Os blocos B1, B2, B3 e B4 constam, respectivamente, das Tabelas 49, 50, 51 e 52.

Tabela 49 – Bloco B1 da matriz IW, fórmula (4.9).

2.4010	2.4007	2.3999	2.3982	2.4052	2.4007	0.4302	2.4034
5.0451	5.0454	5.0428	5.0438	5.0399	5.0452	0.8628	5.0402
0.3729	1.9929	1.9954	1.9946	0.3751	0.3710	0.3761	0.3778
-0.0153	-0.0145	-0.0180	-0.0163	-0.0139	-0.0143	-0.0152	-0.0135
-2.5245	-2.5292	-2.5264	-2.5276	-2.5261	-2.5280	-2.5291	-2.5279
-5.5401	-5.5385	-5.5382	-5.5433	-5.5424	-5.5426	-5.5385	-5.5425
1.9493	1.8100	1.8130	1.8107	1.9526	1.9553	1.8105	1.9526
-2.2676	-2.2696	-2.2669	-2.2695	-2.2675	-2.2719	-2.2729	-2.2719
1.7399	1.6031	1.6024	1.5999	1.7405	1.7464	1.6008	1.7460
-0.5408	-0.0603	-0.0220	-0.0278	-0.1075	-0.3273	-0.0228	-0.4687
-0.0074	-0.0021	-0.0025	-0.0045	-0.0043	-0.0015	-0.0054	-0.0213
-4.9680	-4.8266	-4.8222	-4.8291	-4.9740	-4.9699	04.8268	-4.9675
0.2961	1.5459	1.5437	1.5459	0.2943	1.5494	1.5416	0.2966
0.3636	0.3674	2.1730	2.1679	0.3634	0.3654	2.1749	0.3661
-0.4748	-0.0630	-0.0266	-0.0252	-0.1046	-0.3166	-0.0174	-0.4672
4.8215	1.0123	1.0118	1.0086	4.9629	4.8209	1.0135	4.8235
0.0048	-0.0009	0.0027	0.0038	-0.0003	-0.0037	0.0033	-0.0016
-3.2759	-0.3557	-0.3512	-0.3544	-3.1361	-3.1315	-0.3529	-3.2741
5.5207	5.5170	5.5141	5.5202	5.5166	5.5187	0.9450	5.5171
-0.5194	-2.8481	-2.8479	-2.8487	-0.5232	-0.5192	-2.8516	-0.5254

Fonte: Elaborada pelo autor.

Tabela 50 – Bloco B2 da matriz IW, fórmula (4.9).

2.3994	2.4019	0.4275	2.3991	2.4006	0.4339	2.3997	0.4319
5.0425	5.0411	0.8651	5.0450	5.0453	0.8585	5.0405	0.8646
0.3710	0.3729	1.9963	0.3766	0.3711	1.9979	0.3723	1.9981
-0.0174	-0.0189	-0.0194	-0.0175	-0.0128	-0.0139	-0.0186	-0.0179
-2.5305	-2.5266	-2.5232	-2.5308	-2.5292	-2.5246	-2.5283	-2.5293
-5.5441	-5.5438	-0.8338	-5.5426	-5.5453	-0.8364	-5.5384	-0.8306
1.9536	1.9516	1.8124	1.9544	1.8055	0.1719	1.8057	1.8093
-2.2715	-2.2716	-2.2673	-2.2719	-2.2721	-2.2732	-2.2708	-2.2723
1.7458	1.7428	1.6038	1.7455	1.7433	1.5977	1.7415	1.5974
-0.4738	-0.1026	-0.0191	-0.0114	0.0790	0.1872	0.0327	-0.0179
-0.0144	-0.0495	-0.0064	-0.0039	-0.0039	-0.0170	-0.0078	-0.0081
-4.9719	-4.9741	-0.6902	-4.8265	-4.8285	-0.6905	-4.8299	-0.6903
0.2980	0.2978	1.5482	0.2940	0.2920	1.5411	1.5462	1.5444
0.3675	0.3635	2.1704	0.3686	0.3689	2.1708	0.3650	2.1725
-0.4733	-0.1108	-0.0193	-0.0090	-0.0661	0.1890	0.0782	-0.0166
4.8229	4.9648	1.0531	4.9613	4.9671	1.0487	4.9619	1.0491
-0.0030	-0.0038	-0.0030	-0.0044	0.0014	-0.0027	-0.0006	0.0039
-3.2755	-3.1301	-0.3513	-0.4003	-0.3512	-0.3566	-0.3575	-0.3513
5.5197	5.5204	0.9435	5.5198	5.5177	0.9433	5.5183	0.9477
-0.5254	-0.5255	-2.8488	-0.5191	-0.5184	-2.8466	-2.8487	-2.8474

Fonte: Elaborada pelo autor.

Tabela 51 - Bloco B3 da matriz IW, fórmula (4.9).

1.5436	1.5428	1.5451	1.5490	1.5429	1.5434	1.5481	1.5449
-2.6653	-0.5142	-0.5189	-0.5149	-2.6640	-2.6638	-0.5133	-2.6700
0.3491	0.3559	0.3504	0.3522	0.3556	0.3507	0.3552	0.3561
-1.7977	-0.3644	-0.3675	-0.3635	-1.7999	-1.7943	-0.3695	-1.7984
1.4411	1.5799	1.5831	1.5843	1.4409	1.4376	1.5846	1.4404
-2.6065	-2.6068	-2.6012	-2.6008	-2.5992	-2.6039	-2.6021	-2.6032
-2.8453	-2.8458	-2.8507	-2.8473	-2.8500	-2.8507	-2.8465	-2.8492
2.1115	2.1092	2.1106	2.1091	2.1133	2.1136	2.1091	2.1122
2.1129	2.1095	2.1149	2.1078	2.1115	2.1131	2.1084	2.1135
5.9267	0.8535	0.8523	0.8535	5.7781	5.9222	0.8590	5.9261
-3.5899	-3.5904	-3.4528	-3.4495	-3.5894	-3.5879	-3.4460	-3.5876
2.9366	2.9402	2.9357	2.9375	2.9405	2.9425	2.8013	2.9372
0.3628	0.0203	-0.0470	-0.0160	0.3748	0.2588	-0.0523	0.2883
0.2292	-0.1327	-0.1281	-0.1324	0.0889	0.2265	-0.1772	0.2292
-0.0088	-0.0082	-0.0075	-0.0098	0.0159	-0.0095	-0.0075	-0.0030
6.4154	0.9455	0.9440	0.9410	6.2712	6.4123	0.9378	6.4186
0.0009	-0.0011	-0.0028	0.0001	0.0042	-0.0011	-0.0017	-0.0025
-0.6008	0.0825	0.1032	0.1059	-0.3547	-0.3710	0.2448	-0.3691
-0.9250	-0.9287	-0.9236	-0.9263	-0.9287	-0.9255	-0.9302	-0.9235
0.1192	-0.0668	-0.0962	-0.0678	-0.0212	0.0645	-0.0967	1.8221

Fonte: Elaborada pelo autor.

Tabela 52 – Bloco B4 da matriz IW, fórmula (4.9).

1.5443	1.5490	1.5492	1.5483	1.5454	1.5460	1.5440	1.5475
-2.6657	-2.6667	-0.4795	-2.6667	-0.5174	-0.4821	-2.6682	-0.4848
0.3541	0.3536	0.3532	0.3527	0.3525	0.0599	0.3516	0.0576
-1.7985	-1.8008	-0.3313	-1.7941	-0.3655	-0.3299	-1.7969	-0.3345
1.4354	1.4384	1.5809	1.4359	1.4409	1.5781	1.4397	1.5788
-2.6046	-2.6040	-2.5982	-2.6034	-2.6024	-2.6003	-2.6039	-2.6052
-0.5249	-2.8464	-2.8472	-2.8478	-2.8450	-2.8455	-2.8517	-2.8502
2.1139	2.1100	2.1148	2.1072	2.1147	2.1115	2.1129	2.1093
2.1096	2.1094	2.1094	2.1136	2.1104	2.1143	2.1082	2.1142
5.9231	5.7805	0.8171	5.7807	5.7805	0.8181	5.7816	0.8138
-3.5928	-3.5909	-3.4493	-3.5927	-3.5881	-3.4459	-3.5908	-3.4444
2.9413	2.9398	0.3829	2.9394	2.9386	0.3787	2.9405	0.3790
0.2875	0.2428	-0.2852	0.3118	0.1188	-0.0872	0.0907	-0.2876
0.2368	0.0831	-0.1715	0.0871	-0.1317	-0.1790	-0.1325	-0.1717
-0.0018	0.0170	-0.0066	0.0196	-0.0071	0.1382	-0.0028	-0.0041
6.4135	6.2756	0.9012	6.2740	6.2715	0.8998	6.2720	0.8970
0.0064	-0.0023	-0.0008	0.0027	0.0030	0.0071	-0.0008	0.0024
-0.3735	-0.3588	0.1458	-0.2037	-0.1372	0.1530	-0.1427	0.1444
-0.9246	-0.9250	-0.9273	-0.9288	-0.9295	-0.9312	-0.9240	-0.9252
1.8224	0.2247	-0.1825	-0.0024	-0.0262	-0.2320	-0.0280	-0.1754

Fonte: Elaborada pelo autor.

A seguir, são fornecidas as matrizes LW (vetor linha), b1 (vetor coluna) e b2 (vetor linha),

LW =[10.6507 -1.6113 -8.0526 -12.1897 1.0834 4.6068 1.5350 0.7478 -8.2536 1.5361
-9.6545 5.2655 -8.0779 1.6610 1.4393 2.5157 -1.3052 3.5816 -2.5204 1.0854 -8.4389 1.0781
0.5190 0.5594 6.4596 1.0913 1.0803 -7.5189 -7.5213 -0.1267 2.2879 -9.5623 -5.9951 -2.4220
575.5548 1.6027 4.5744 2.8892 1.2824 -1.0867],

$b1^T$ = [11.1182 -6.7321 3.3964 10.0635 -11.8536 -4.5271 4.4333 2.6438 4.4016 -0.0967
1.8429 -3.1783 3.5161 5.1964 -0.1652 -0.8158 -3.9578 -1.4680 -7.6699 -4.6255 -2.6878
-3.9224 -4.0715 -1.5730 -1.3933 -2.4638 -4.5618 0.9091 2.2839 2.6582 -6.5349 3.7130
5.6143 4.4312 -8.6249 2.7774 1.7058 -3.0905 -3.5703 1.6306],

e $b2 = [65.7042 \ 65.7042 \ 65.7042 \ 65.7042 \ 65.7042]$,

onde o símbolo T indica matriz transposta.

Para a aplicação são usadas as fórmulas (4.5), (4.6) e (4.7), repetidas abaixo:

$$\begin{aligned} & IW * pi + b1 * ones(1,5), \\ Ai &= \text{logsig}(IW * pi + b1 * ones(1,5)), \\ Ti &= LW * Ai + b2, \end{aligned}$$

onde $i = 1, 2, 3$ e 4 , pi é o padrão de entrada, $ones(1,5) = [1 \ 1 \ 1 \ 1 \ 1]$, Ti é o padrão de saída e $b2$ é a matriz de limiar, de ordem 1×5 , com o valor encontrado 65.7042 repetido 5 vezes.

Com relação à mesma temperatura de queima de 1060°C , agora com oito variáveis, a solução foi decidida entre dois resultados, aqueles fornecidos pelas Tabelas 46 e 47. Para isso, foi calculado o desvio entre o valor mostrado pela Tabela, designado por vt e o valor do padrão de resposta esperado, PADRÃO (8), ou de forma simplificada $P(8)$. Em valor absoluto, o desvio é obtido da expressão.

$$d = | vt - P(8) |, \quad (4.10)$$

e, transformado em porcentagem, pela fórmula

$$D = \frac{d}{P(8)} * 100. \quad (4.11)$$

Os resultados foram incluídos nas Tabelas 53 e 54.

Tabela 53 – Cálculo dos desvios, $D(\%)$, para os valores da Tabela 46.

$D(\%)$	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
1020	0.47	0.06	7.73	11.32	2.36	2.86	4.55	8.27
1040	0.29	0.46	16.57	13.47	0.81	8.58	0.83	17.41
1060	0.27	0.33	0.03	0.04	0.04	0.05	0.05	0.07

Fonte: Elaborada pelo autor.

Tabela 54 – Cálculo dos desvios, D(%), para os valores da Tabela 47.

D(%)	DP	DAS	RLS	RLQ	PF	Abs	CR	MRF
1020	0.63	0.76	5.40	12.55	1.30	6.23	0.89	23.41
1040	0.64	0.01	5.03	0	1.13	5.61	0.22	10.06
1060	0.35	0.29	0.47	0.10	0.05	0.04	0	0.20

Fonte: Elaborada pelo autor.

Como a norma NBR 13818 (ABNT, 1997) especifica as variáveis físicas Abs, CR e MRF, a escolha recaiu sobre os dados da Tabela 47 combinado com os dados da Tabela 54, porque esta Tabela suplantou em seis dos nove resultados os dados da Tabela 53, com desvios menores. Convém observar que a Tabela 54 apresentou somente um valor, $D = 23.41\%$, relativamente alto com relação aos outros valores encontrados.

Com isto colocado, a matriz de peso IW ficou sendo de ordem 70×20 e, também, foi dividida em blocos, conforme a matriz abaixo:

$$IW = \begin{bmatrix} B1 & B2 \\ B3 & B4 \\ B5 & B6 \end{bmatrix}, \quad (4.12)$$

onde B1 e B2 são de ordem 20×10 , enquanto B3, B4, B5 e B6 são de ordem 25×10 . As outras matrizes não necessitam da divisão em blocos. Os blocos B1, B2, B3, B4, B5 e B6 constam, respectivamente, das Tabelas 55, 56, 57, 58, 59 e 60.

Tabela 55 – Bloco B1 da matriz IW, fórmula (4.12).

0.0404	0.0204	0.0106	0.0021	0.0220	0.0141	-0.0058	0.0436	0.0108	0.0429
-0.0594	-0.0569	-0.0556	-0.0629	-0.0551	-0.0792	-0.0771	-0.0640	-0.0750	-0.0743
0.3525	0.3484	0.3494	0.2949	0.3544	0.3163	0.3063	0.3538	0.3063	0.3067
-0.0578	-0.0565	-0.0566	-0.0560	-0.0564	-0.0812	-0.0771	-0.0622	-0.0747	-0.0749
0.0317	0.0322	0.0312	0.0258	0.0272	0.0246	0.0250	0.0293	0.0263	0.0268
-0.2090	-0.3408	-0.3393	-0.1198	-0.3426	-0.4490	-0.1168	-0.2099	-0.6812	-0.2055
-0.5425	0.0348	0.0324	-0.0047	0.0353	-1.0021	-0.0036	-0.4455	-0.0087	-0.7400
0.0009	-0.0018	-0.0037	-0.0097	-0.0030	-0.0041	-0.0036	0.0008	-0.0012	-0.0037
-0.0570	-0.623	-0.0542	-0.0561	-0.0545	-0.0768	-0.0783	-0.0628	-0.0794	-0.0786
0.0015	-0.0006	0.0041	0.0040	0.0001	0.0006	-0.0017	0.0009	0.0025	0.0029
-0.0581	-0.0591	-0.0550	-0.0156	-0.0557	-0.0952	-0.1083	-0.0605	-0.1129	-0.0794
0.0483	0.0714	0.0704	0.0289	0.0690	0.0467	0.0407	0.0422	0.0713	0.0495
0.0022	0.0021	0.0030	-0.0087	0.0005	-0.0010	0.0031	-0.0015	0.0023	0.0006
0.4360	-0.0434	-0.0414	-0.0343	-0.0397	0.0546	-0.1238	0.3675	-0.0923	0.3569
-0.0573	-0.0572	-0.0590	-0.0572	-0.0543	-0.0786	-0.0775	-0.0589	-0.0730	-0.0769
0.0505	0.0239	0.0198	-0.1151	0.0222	0.0269	0.0189	0.0331	0.0232	0.0512
0.1041	0.1493	0.1481	0.0937	0.0791	0.0987	0.0527	0.0971	0.1184	0.0941
0.5310	0.1815	-0.0512	-0.0391	-0.0513	0.1170	-0.0284	0.3094	0.0005	0.3092
-2.7032	-0.2043	-0.2061	-0.0889	-0.2059	-0.3154	-0.0955	-2.7081	-0.5518	-2.7056
0.0031	0.0008	-0.0001	0.0048	0.0019	-0.0015	0.0021	-0.0023	0.0004	0.0023

Fonte: Elaborada pelo autor.

Tabela 56 – Bloco B2 da matriz IW, fórmula (4.12).

0.0440	0.0196	-0.0081	0.0407	0.0182	-0.0081	0.0167	0.0025	0.0040	-0.0106
-0.0770	-0.0772	-0.0629	-0.0584	-0.0643	-0.1217	-0.0584	-0.0724	-0.1127	-0.1029
0.2809	0.3078	0.3539	0.3486	0.3540	0.1847	0.3478	0.3481	0.2586	0.1555
-0.0756	-0.0785	-0.0601	-0.0628	-0.0644	-0.1224	-0.0595	-0.0736	-0.1091	-0.1093
0.0230	0.0235	0.0230	0.0279	0.0291	0.0103	0.0279	0.0234	0.0127	0.0904
-0.2049	-0.3415	-0.1136	-0.3411	-0.3386	-0.1198	-0.3378	-0.1148	-0.1183	-0.8532
-0.4486	-1.0019	-0.0039	0.0297	0.0325	-0.0018	0.0306	-0.0022	-0.0062	-0.1491
0	-0.0037	-0.0034	-0.0027	-0.0020	0.0036	0.0008	0.0072	0.0039	-0.0013
-0.0775	-0.0755	-0.0727	-0.0611	-0.0614	-0.1232	-0.0572	-0.0754	-0.1093	-0.1207
0.0017	-0.0007	0.0045	-0.0011	-0.0016	-0.0016	0.0041	0.0033	0.0003	-0.0009
-0.0754	-0.0780	-0.0945	-0.0578	0.0568	-0.1478	-0.0605	-0.1094	-0.1323	-0.0182
0.0478	0.0469	0.0426	0.0435	0.0451	0.0452	0.0747	0.0414	0.0362	0.0167
-0.0008	0.0007	0.0025	0.0023	-0.0024	-0.0002	-0.0037	0.0032	-0.0115	-0.0139
0.3824	0.2023	-0.0322	0.2530	-0.0442	-0.0158	-0.1059	-0.0311	-0.0197	-0.0075
-0.0757	-0.0783	-0.0597	-0.0603	-0.0650	-0.1252	-0.0588	-0.0781	-0.1093	-0.1081
0.2251	0.0192	-0.1166	-0.0124	0.0226	-0.1207	0.0207	-0.1152	-0.1109	-0.0779
0.0995	0.0940	0.1032	0.1181	0.1211	0.0971	0.1213	0.0990	0.1047	0.0919
0.3121	0.1681	-0.0346	0.1664	0.1705	-0.0391	0.1677	-0.0404	-0.0355	-0.0270
-2.7048	-0.2034	-0.0922	-0.2034	-0.2036	-0.0923	-0.2026	-0.0972	-0.0944	-0.7171
0.0029	0.0025	0.0037	-0.0016	-0.0019	-0.0030	0.0007	0.0003	0.0050	-0.0004

Fonte: Elaborada pelo autor

Tabela 57 – Bloco B3 da matriz IW, fórmula (4.12).

0.0677	0.0286	0.0297	-0.0374	0.0253	-0.0654	-0.0574	0.0725	-0.0602	0.0718
0.0028	0.0003	0.0029	-0.0036	0.0007	0.0051	-0.0157	-0.0090	0.0025	0.0022
-0.1352	-0.1920	-0.1937	-0.0416	-0.1928	-0.1350	-0.1579	-0.1355	-0.1951	-0.1320
-0.1710	-0.1838	-0.1863	-0.0498	-0.1831	-0.1663	-0.1934	-0.1714	-0.1945	-0.1698
-0.0270	-0.0277	-0.0328	0.0088	-0.0309	-0.0288	0.0163	-0.0267	-0.0289	-0.0253
0.0333	0.0166	0.0149	0.0071	0.0162	0.0156	0.0004	0.0273	0.0122	0.0275
0.0874	0.0694	0.0689	0.0120	0.0660	-0.1259	0.0274	0.0875	0.0316	0.0917
-0.2085	-0.3440	-0.3390	-0.1147	-0.3408	-0.4480	-0.1144	-0.2087	-0.1072	-0.2092
0.0044	0.0018	0.0018	-0.0068	0.0026	0.0013	-0.0002	-0.0003	0.0024	0.0021
0.0008	0.0019	0.0037	0.0030	0.0022	-0.0022	-0.0003	0.0036	-0.0016	-0.0017
0.3863	-0.0416	-0.0387	-0.0260	-0.0405	0.0597	-0.0303	0.3818	-0.1332	0.3588
0.2928	0.2937	0.2963	0.2106	0.2439	0.2944	0.2457	0.2971	0.2937	0.2933
-0.0288	-0.0254	-0.0196	-0.0200	-0.0228	-0.0273	-0.0285	-0.0262	-0.0244	-0.0289
-0.0765	-0.0276	-0.0243	-0.0550	-0.0290	0.0384	-0.0442	-0.0754	-0.0479	0.0280
-0.0619	-0.6360	-0.0538	-0.0590	-0.0595	-0.0772	-0.0749	-0.0611	-0.0756	-0.0774
0.1078	0.1478	0.1439	0.0997	0.0788	0.0983	0.0508	0.0984	0.1238	0.0978
-0.0371	-0.0247	-0.0283	-0.0175	-0.0239	-0.0416	-0.0222	-0.0351	-0.0252	-0.0359
-0.0562	-0.0541	-0.0532	-0.1135	-0.0584	-0.0666	-0.1189	-0.0550	-0.0620	-0.0605
0.3238	0.1774	0.1781	0.0256	0.1827	0.1857	0.1016	0.3189	0.0246	0.3644
0.0125	0.0014	-0.0285	-0.0202	-0.0228	0.0120	-0.0242	0.0072	-0.0273	0.0126
0.0752	0.0718	0.0697	0.0281	0.0763	0.0544	0.0174	0.0716	0.0432	0.0642
-0.0598	-0.0576	-0.0610	-0.0553	-0.0564	-0.0780	-0.0750	-0.0621	-0.0752	-0.0762
-0.0001	0.0022	0.0038	-0.0022	0.0013	-0.0026	-0.0019	0.0011	0.0026	-0.0018
-0.0454	-0.0119	-0.0145	-0.0063	-0.0122	-0.0161	0.0111	-0.0408	-0.0133	-0.0414
0.3129	0.2564	0.2590	0.0766	0.2625	2.7096	0.0739	0.3121	0.4481	0.3139

Fonte: Elaborada pelo autor.

Tabela 58 – Bloco B4 da matriz IW, fórmula (4.12).

0.0702	-0.0615	-0.0567	-0.0655	-0.0622	-0.0580	-0.0674	-0.0585	-0.0714	-0.0260
0.0010	0.0023	-0.0131	0.0061	0.0065	-0.0017	0.0050	-0.0020	-0.0034	0.0022
-0.1347	-0.1316	-0.1567	-0.1350	-0.1358	-0.1578	-0.1337	-0.1621	-0.1476	-0.0392
-0.1676	-0.1678	-0.1807	-0.1703	-0.1699	-0.1908	-0.1650	-0.0587	-0.0486	-0.0325
-0.0256	-0.0265	0.0159	-0.0253	-0.0259	0.0181	-0.0282	0.0070	0.0107	0.0029
0.0228	0.0263	0.0058	0.0232	0.0116	0.0055	0.0125	0.0048	0.0065	-0.0009
0.0003	0.0031	0.0278	0.0368	-0.1229	-0.0650	-0.1266	0.0270	-0.0697	-0.0915
-0.2083	-0.3385	-0.1195	-0.3437	-0.3387	-0.1128	-0.3400	-0.1151	-0.1185	-0.8537
0.0014	0	0.0026	0.0005	0.0039	0.0045	-0.0013	0.0014	0.0008	0.0050
-0.0009	-0.0023	0.0004	0.0008	-0.0038	0.0030	0.0021	0.0014	0.0044	0.0034
0.0767	0.3591	-0.0288	0.3602	-0.0779	-0.0247	-0.0770	-0.0333	-0.0166	-0.0074
0.2964	0.2954	0.2115	0.2988	0.2939	0.2133	0.2957	0.2079	0.2096	1.1022
-0.0307	-0.0300	-0.0226	-0.0250	-0.0290	-0.0633	-0.0229	-0.0228	-0.0595	-0.4179
0.0264	0.0249	-0.0611	-0.0744	-0.1337	-0.0200	-0.0826	-0.0609	-0.0287	-0.0489
-0.0777	-0.0752	-0.0766	-0.0573	-0.0596	-0.1206	-0.0584	-0.0728	-0.1082	-0.1223
0.1017	0.1018	0.1024	0.1251	0.1193	0.0997	0.1236	0.1037	0.1046	0.0987
-0.0024	-0.0049	-0.0246	-0.0369	-0.0365	-0.0257	-0.0379	-0.0236	-0.0205	-0.0190
-0.0608	-0.0651	-0.1019	-0.0550	-0.0566	-0.1805	-0.0558	-0.1028	-0.1458	-0.1586
0.3455	0.1749	0.0314	0.3618	0.1864	-0.0747	0.1826	0.0271	-0.0759	-0.0864
0.0123	0.0082	-0.0236	0.0085	0.0095	-0.0276	0.0123	-0.0272	-0.0194	-0.0061
0.0594	0.0560	0.0155	0.0752	0.0644	0.0210	0.0771	0.0266	0.0280	0.0160
-0.0753	-0.0761	-0.0749	-0.0606	-0.0591	-0.1188	-0.0579	-0.0732	-0.1134	-0.1222
0.0023	0.0004	0.0021	-0.0014	-0.0024	0.0036	0.0021	-0.0002	0.0044	0.0051
-0.0454	-0.0193	0.0100	-0.0099	-0.0142	0.0121	-0.0155	0.0061	-0.0001	0.0052
0.3146	0.3119	0.0746	0.3164	0.2570	0.0799	0.3145	0.0766	0.0769	0.6128

Fonte: Elaborada pelo autor.

Tabela 59 – Bloco B5 da matriz IW, fórmula (4.12).

-0.0007	0.0013	-0.0008	-0.0014	0.0016	0.0012	-0.0008	-0.0035	-0.0027	0.0002
0.0275	0.0320	0.0345	0.0211	0.0316	0.0307	0.0404	0.0304	0.0317	0.0302
0.0283	0.0136	0.0153	0.0043	0.0132	0.0111	0.0003	0.0232	0.0143	0.0245
-0.0311	0.0060	0.0094	0.0059	0.0085	-0.0203	0.0084	-0.0325	0.0107	-0.0279
-0.0377	-0.0276	-0.0267	-0.0183	-0.0217	-0.0247	-0.0195	-0.0361	-0.0215	-0.0388
-0.0157	0.0148	0.0199	0.0245	0.0243	-0.0104	0.0241	-0.0104	0.0131	-0.0138
0.4300	-0.0276	-0.0282	-0.0049	-0.0315	0.0989	-0.0164	0.3900	-0.0260	0.3657
0.0024	0.0026	0.0023	0.0031	0.0026	0.0016	-0.0022	-0.0009	-0.0007	-0.0029
-0.0375	-0.0254	-0.0268	-0.0237	-0.0218	-0.0250	-0.0187	-0.0374	-0.0262	-0.0376
0.0195	0.0212	0.0208	0.0194	0.0195	0.0153	0.0213	0.0180	0.0168	-0.0499
-0.0381	-0.0222	-0.0209	-0.0211	-0.0219	-0.0225	-0.0255	-0.0403	-0.0225	-0.0401
0.0401	-0.0207	-0.0184	-0.0403	-0.0188	0.0441	-0.0222	0.0446	-0.0180	0.0969
-0.0366	-0.0216	-0.0238	-0.0183	-0.0266	-0.0233	-0.0206	-0.0370	-0.0239	-0.0349
-0.0599	-0.0596	-0.0563	-0.0561	-0.0576	-0.0799	-0.0797	-0.0588	-0.0732	-0.0767
0.0221	0.0272	0.0690	-0.0237	-0.0335	0.0226	-0.0194	0.0250	0.0733	0.0262
-0.0440	-0.0748	-0.0993	-0.0787	-0.0994	-0.0493	-0.1000	-0.0483	-0.0983	-0.0393
-0.0011	-0.0026	-0.0023	0.0055	0.0003	-0.0002	0.0026	-0.0031	0.0040	0.0009
0.0033	0.0019	-0.0030	0.0072	-0.0030	-0.0002	-0.0011	-0.0022	-0.0025	0.0011
0.0009	-0.0048	-0.0017	0.0042	-0.0028	-0.0051	-0.0005	-0.0007	0.0008	-0.0049
0.0080	0.0097	0.0057	0.0013	0.0071	0.0121	0.0129	0.0121	0.0077	0.0102
0.3624	0.2319	0.2293	-0.1034	0.2351	-0.2296	-0.1022	0.0106	-0.0712	0.0120
0.0304	0.0304	0.0385	0.2377	0.0386	0.0230	0.0262	0.0290	0.0220	0.0214
0.1020	-0.0267	-0.0645	-0.0621	-0.0682	-0.0185	-0.3610	0.1100	0.0529	0.1142
0.0022	-0.0017	0.0016	-0.0064	0.0008	-0.0039	-0.0030	0.0016	0.0015	-0.0022
-0.0344	-0.0035	-0.0060	0.0067	-0.0046	0.0003	0.0161	-0.0257	-0.0035	-0.0307

Fonte: Elaborada pelo autor.

Tabela 60 – Bloco B6 da matriz IW, fórmula (4.12).

-0.0026	-0.0018	-0.0005	-0.0021	-0.0031	-0.0047	0.0018	0.0060	0.0118	-0.0118
0.0266	0.0258	0.0399	0.0310	0.0330	0.0395	0.0266	0.0274	0.0255	0.0001
0.0240	0.0250	0.0038	0.0257	0.0165	0.0112	0.0265	0.0092	0.0060	0.0041
-0.0285	-0.0271	0.0345	-0.0167	0.0093	0.0315	0.0053	0.0348	0.0322	0.0164
-0.0374	-0.0395	-0.0220	-0.0354	-0.0230	-0.0213	-0.0252	-0.0214	-0.0247	-0.0191
0.0106	-0.0124	0.0195	0.0099	-0.0137	0.0228	-0.0116	0.0241	0.0232	0.0208
0.3676	0.3660	-0.0151	-0.0861	-0.1285	-0.0143	0.0041	-0.0196	-0.0033	-0.0049
-0.0007	0.0005	0.0003	-0.0026	0.0028	0.0026	0.0028	-0.0018	-0.0017	-0.0462
-0.0355	-0.0385	-0.0232	-0.0370	-0.0255	-0.0217	-0.0219	-0.0260	-0.0173	-0.0164
0.0142	-0.0522	0.0191	0.0155	0.0182	0.0153	0.0189	0.0094	0.0106	0.0060
-0.0412	-0.0372	-0.0258	-0.0228	-0.0268	-0.0263	-0.0250	-0.0219	-0.0225	0.0080
0.0968	0.1019	-0.0397	0.0093	-0.0220	-0.0457	-0.0189	-0.0412	-0.0406	-0.2023
-0.0359	-0.0369	-0.0218	-0.0361	-0.0263	-0.0243	-0.0282	-0.0212	-0.0203	-0.0225
-0.0755	-0.0757	-0.0732	-0.0596	-0.0643	-0.1195	-0.0569	-0.0776	-0.1097	-0.1062
0.0221	0.0236	-0.0386	0.0243	0.0265	-0.0373	0.0210	-0.0211	-0.0230	-0.1906
-0.0534	-0.0378	-0.0922	-0.0496	-0.0462	-0.1021	-0.0460	-0.0921	-0.0840	-0.0283
0.0036	0.0015	0.0011	0.0024	0.0009	0.0011	0.0011	0.0036	-0.0006	0.0056
0.0007	0.0008	-0.0007	-0.0010	-0.0029	-0.0038	0.0002	-0.0014	0.0062	0.0120
-0.0039	-0.0035	-0.0051	-0.0022	-0.0021	0.0018	-0.0053	-0.0025	0.0088	0.0331
0.0063	0.0101	0.0082	0.0073	0.0080	0.0115	0.0121	0.0102	0.0006	0.0310
0.0104	-0.1215	-0.0804	0.2307	-0.1201	-0.0785	0.2287	-0.1002	-0.1028	-0.7607
0.0221	0.0221	0.0326	0.0330	0.0269	0.0241	0.0273	0.0281	0.0203	0.1192
0.1150	-0.0286	-0.0573	0.1116	-0.0314	-0.0621	-0.0272	-0.0620	-0.0587	-0.5267
-0.0023	-0.0029	0.0011	-0.0009	-0.0027	-0.0022	0.0020	0.0016	-0.0023	-0.0015
-0.0360	-0.0360	0.0148	-0.0046	-0.0050	0.0181	-0.0056	-0.0118	0.0045	0.0208

Fonte: Elaborada pelo autor.

A seguir, as outras matrizes,

LW = [-1.2516 -27.0481 -0.0985 -27.1744 -0.5460 0.8034 -3.7941 -6.5422 -27.6216 95.9035
-26.8871 1.8888 -0.4168 -2.5810 -26.8337 2.3459 -0.7838 -0.3164 0.5908 96.6923 0.5864
-9.0630 -0.9755 -0.8091 0.9583 -0.7615 -0.0532 0.7978 95.9943 96.7776 -1.6576 -0.8905
-15.0051 0.6144 -27.0444 -0.1060 1.1710 -0.4133 0.1325 -0.6060 -3.7948 -27.3438 96.1249
0.8995 -3.3421 0.8964 1.9142 -0.5593 2.1019 1.5406 2.1179 -3.3831 -5.0903 1.3298 2.4226
-1.1270 2.4355 1.4058 -27.3181 2.4678 -0.4543 96.5362 5.0686 -7.0072 2.2331 -0.8964
0.3360 0.2627 -0.4157 1.2539],

$$b1^T = [2.4410 \ -7.9358 \ -5.0742 \ -7.2658 \ 2.6508 \ 0.4874 \ 1.5836 \ 1.5013 \ -8.6979 \ -3.0517 \ -5.6962 \\ -2.7558 \ -7.1611 \ -0.6151 \ -6.5599 \ -0.5943 \ -5.7552 \ -0.5321 \ -2.0322 \ -3.5029 \ -0.0488 \ 0.7850 \\ 3.2023 \ 2.8671 \ -1.4401 \ 4.0182 \ 1.3002 \ -0.0167 \ -4.8233 \ -3.3370 \ -0.9908 \ 4.8597 \ -2.2629 \\ -0.2202 \ -6.6958 \ -5.9316 \ -4.0406 \ -5.0494 \ 1.4031 \ 2.4255 \ 1.7494 \ -7.9289 \ -4.0354 \ -2.3067 \\ -0.4935 \ 1.8228 \ -1.2622 \ 4.6173 \ -4.3329 \ -3.9924 \ -3.3867 \ 0.5023 \ 8.6083 \ -3.5537 \ -1.9742 \\ -2.7788 \ -2.9090 \ -4.6417 \ -8.9476 \ -3.6206 \ 3.5346 \ -4.6819 \ 10.6586 \ 2.2981 \ -4.3918 \ 1.0575 \\ 2.5938 \ 1.5923 \ 2.6691 \ -4.0129] e$$

$$b2 = [22.2270 \ 22.2270 \ 22.2270 \ 22.2270 \ 22.2270 \ 22.2270 \ 22.2270 \ 22.2270],$$

onde o símbolo T indica matriz transposta.

Para a aplicação da rede neural artificial aos dados das tabelas dos ANEXOS I, J e K são usadas as mesmas fórmulas (4.5), (4.6) e (4.7), agora com $i = 1, 2$ e 3 , $b2$ é a matriz de limiar, de ordem 1×8 , com o valor encontrado 22.2270 repetido 8 vezes e, por fim, a matriz $\text{ones}(1,8) = [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1]$.

Com estes resultados fica provada a hipótese formulada no capítulo introdutório deste trabalho, isto é, "é possível aplicar as redes neurais artificiais na indústria de pisos e revestimentos cerâmicos".

É importante ressaltar que o processo de aplicação das RNAs foi também validado na medida em que as matrizes encontradas para a temperatura de sinterização de 1060°C , tanto para cinco como para oito variáveis, puderam ser aplicadas às outras temperaturas de queima (1000°C para 5 variáveis, 1020°C e 1040°C para 5 e 8 variáveis).

Pode-se concluir, então, que a estabilidade e a convergência não ocorreram quando o número de neurônios na camada oculta é grande e nem mesmo quando o número de iterações (epochs) é muito elevado. Ocorreu quando houve uma relação ótima entre os dois números, na temperatura de sinterização de 1060°C . Ainda, levando em consideração que uma rede neural é um conceito desenvolvido para operar com grande volume de dados, observou-se que a melhor solução foi encontrada quando, além da temperatura mencionada, o número de variáveis atingiu o número de oito e quando o número de linhas de dados era de vinte, de acordo com as tabelas dos ANEXOS I, J e K.

Após ter contratado os fornecedores de argilas e de outros insumos e definido o produto com as especificações técnicas das variáveis de controle, o industrial interessado em

aplicar as RNAs, para se estabelecer em algum nicho de mercado, deve proceder de acordo com as seguintes etapas:

- 1 – Recolher amostras das minas e bancadas de argilas;
- 2 – Confeccionar os corpos-de-prova;
- 3 – Testar em laboratório os corpos-de-prova, para encontrar os dados amostrais das variáveis de controle;
- 4 – Elaborar a tabela (ou tabelas) com os dados amostrais, que será definida como o padrão de entrada das RNAs; e
- 5 – Aplicar as RNAs.

Para a aplicação das RNAs, seguem-se as seguintes etapas:

- 1 – Disponibilizar um *software* (MATLAB);
- 2 – Definir a rede (MLP de três camadas);
- 3 – Definir a regra de aprendizado da rede (regra delta generalizada ou *backpropagation* com quatro variações); e
- 4 – Estabelecer as funções de transferência da rede (logística e linear).

Entre parênteses foram colocados o *software* e os dados utilizados neste trabalho. O programa usado para o *backpropagation* resiliente (*trainrp*) consiste dos seguintes passos:

1. `p = [2.058 ... 61.3; 2.006 ... 59.7; ... ; 1.984 ... 22.9];`
2. `t = [2 1.9 0.3 5.5 4 7 602 51];`
3. `net = newff(minmax(p),[3,1],{'logsig','purelin'},'trainrp');`
4. `net.trainParam.show = 200;`
5. `net.trainParam.epochs = 5000;`
6. `net.trainParam.goal = 1e-5;`
7. `[net,tr] = train(net,p,t);`

Realizados os testes e encontrados os melhores valores de parada (epochs ou goal), indicando que houve convergência, o comando `a = sim(net,p)` fornece a simulação executada pelo programa.

Mais importante, os comandos `celldisp(net.IW)`, `celldisp(net.LW)` e `celldisp(net.b)` recuperam as matrizes de pesos IW e LW e as matrizes de limiares b (duas). Aplicando as fórmulas (4.5), (4.6) e (4.7), p. 60, podem ser encontrados os valores estimados para o produto industrial, os quais se apresentam aproximadamente iguais ao padrão de saída da rede, designado por t no programa. Convém observar que a matriz p corresponde aos dados amostrais do ANEXO I.

5. CONSIDERAÇÕES FINAIS

Ao concluir este trabalho é muito importante reforçar alguns aspectos quando da aplicação de uma rede neural artificial. A ideia da aplicação do conceito das redes neurais artificiais às indústrias de pisos e revestimentos cerâmicos do PCSG mostrou-se bastante promissora tendo em vista que, mesmo operando com uma pequena quantidade de dados, contrariando a sua proposta original de trabalhar com grande volume de dados em problemas complexos, as redes forneceram soluções com pequenos desvios com relação ao padrão de saída previamente estabelecido. Mais ainda, a escolha das minas para fornecer as amostras recaiu sobre aquelas que apresentaram as maiores diferenciações nas argilas e representavam toda a coluna estratigráfica da Formação Corumbataí. Por isso, mesmo diferentes e com dados amostrais que variavam em média de 0.3 a 602, todos os dados dos ANEXOS A, B, C e D foram usados desde que pertencessem às mesmas variáveis físicas e às mesmas temperaturas de queima. Estes dados também não interferiram nas soluções encontradas.

Provavelmente, uma indústria cerâmica não utiliza argilas tão diferentes para a sua linha de produção. Com valores mais homogêneos é possível estabelecer um padrão de qualidade bem mais rigoroso, que pode se constituir no padrão de saída pré-estabelecido para o funcionamento de uma rede neural.

Este trabalho pode ser ampliado, futuramente, incluindo também outras variáveis, além das variáveis físicas aqui usadas, que são as variáveis químicas e mineralógicas. Isto possibilita um melhor desempenho por parte das redes neurais.

É bom reforçar também que as redes neurais artificiais apresentam outras arquiteturas e também outras regras de aprendizado. Elas podem ser operadas isoladamente ou associadas a outro conceito ou método, em especial, daqueles que já fazem parte do que é concebido como Inteligência Artificial.

Por outro lado, é também igualmente importante ressaltar que com o inevitável aumento da população humana, ocorrerá uma pressão cada vez maior para a ocupação dos espaços ainda inexplorados na face deste planeta Terra. A humanidade em busca por água, por alimentos e por outros recursos naturais, forçosamente provocará um aumento dos nefastos impactos causados ao meio ambiente. Especificamente, no caso das mineradoras e da industrialização correspondente, Poletto (2007) e AMBIENTE BRASIL (2009), sugerem alternativas no sentido de se diminuir o consumo e de se aumentar a reciclagem e, no caso das minas, de se promover a revegetação e a reversão das áreas degradadas em terras produtivas.

No caso da revegetação, como um trabalho para o futuro, poder-se-ia sugerir a aplicação de uma rede Kohonen, as quais não exibem uma camada de saída, contudo os neurônios da camada de entrada competem entre si e o vencedor leva tudo (ou vencedores). Com esta rede poderiam ser resolvidos alguns problemas relativos à flora, promovendo uma competição controlada biologicamente entre as espécies vegetais para que aquelas que estiverem melhores adaptadas ao local possam se estabelecer.

REFERÊNCIA BIBLIOGRÁFICA

ABDI, H.; VALENTIN, D.; EDELMAN, B. Neural networks. *Sage University Papers Series on Quantitative Applications in the Social Sciences*, 07 – 124. Thousand Oaks, CA, 1999.

AMBIENTE Brasil. Disponível em: <http://www.ambientebrasil.com.br>. Acesso em: 11 nov. 2009.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR 13818: placas cerâmicas para revestimentos: especificação e métodos de ensaio*. Rio de Janeiro, 1997. 78 p.

ASSOCIAÇÃO PAULISTA DAS CERÂMICAS DE REVESTIMENTOS – ASPACER. Disponível em: <http://www.aspacer.com.br>. Acesso em: 10 fev. 2012.

AZEVEDO, F. M.; BRASIL, L.; OLIVEIRA, R. C. L. *Redes neurais com aplicações em controle e em sistemas especialistas*. Florianópolis: Bookstore, 2000.

BRAGA, R. L.; CARVALHO, A. P. L.; LURDEMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. 2. ed. Rio de Janeiro: Livros Técnicos, 2007.

CAMPANHA, J. R. *Determinação dos parâmetros de ordem de redes neurais pelo método dos cumulantes*. 1994. 129p. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1994.

CHRISTOFOLETTI, S. R. *Estudo mineralógico, químico e textural das rochas sedimentares da Formação Corumbataí “Jazida Cruzeiro”, e suas implicações nos produtos e processos cerâmicos*. 1999. 120p. Tese (Doutorado em Geociências) – Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 1999.

CHRISTOFOLETTI, S. R.; MORENO, M. M. T. Características das rochas da Formação Corumbataí utilizadas na indústria de revestimento cerâmico. *Geociências*, São Paulo, v. 23, n. 1/2, p.79-88, 2004.

CHRISTOFOLETTI, S. R.; THOMAZELLA, H. R.; MORENO, M. M. T.; MASSON, M. R. Utilização da análise estatística multivariada no tratamento de dados aplicados às matérias-primas cerâmicas. *Revista do Instituto Geológico*, São Paulo, v. 26, n. 1/2, p. 19-29, 2005.

CINTRA, E. C. *Aplicação de redes neurais no controle de teores de cobre e ouro no depósito de Chapada (GO)*. 2003. 170f. Tese (Doutorado em Geologia) – Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2003.

CORREIA, S. L.; TOMAZI, F. C.; FOLGUERAS, M. V. Influência da composição mineralógica e temperatura de queima nas propriedades tecnológicas de massas cerâmicas. In: CONGRESSO BRASILEIRO DE CERÂMICA, 51., 2007, Salvador. *Anais ...*, Salvador, 2007, p. 12.

DAMÁSIO, A. R. *O erro de Descarte: emoção, razão e o cérebro humano*. Traduzido por Dora Vicente e Georgina Segurado. Revisão Técnica de Carmem S. da Costa e Ana Maria Barbosa. São Paulo: Companhia das Letras, 1996.

FERRO, L. *Modelo do bulbo olfativo baseado em redes neurais recorrentes*. 2007. 97f. Dissertação (Mestrado em Física Aplicada) – Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2007.

ECCLES, J. C. *The physiology of nerve cells*. John Hopkins University Press, [S.l.], 1957

GAIDZINSKI, R. *Fatores envolvidos no sazonalidade e suas implicações nas propriedades de argilas para a Indústria Cerâmica*. 2006. 179p. Tese (Doutorado em Ciências, em Engenharia Metalúrgica e de Materiais) – Engenharia Metalúrgica e de Materiais, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

GROSSBERG, S. Adaptive pattern classification and universal recording. *Biological Cybernetics*, [S.l.], v. 23, n. 1, p. 121-134, 1976.

GROSSBERG, S. How does the brain build a cognitive code? *Psychological Review*, [S.l.], v.89, n. 1, p. 529-572, 1980.

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

HEBB, D. *The organization of behavior: a neurophysiological theory*. New York: John Wiley & Sons, 1949.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, [S.l.], v. 79, p. 2554-2558, 1982.

KOHONEN, T. *Clustering, taxonomy and topological maps of pattern: pattern recognition*. [S.l.], [s.n.], 1982.

KOVÁCS, Z. L. *Redes neurais artificiais: fundamentos e aplicações: um texto básico*. 3. ed. São Paulo: Livraria da Física, 2002.

LE CUN, Y. A learning procedure for asymmetric threshold network. *Proceedings of Cognitiva*, [S.l.], n. 85, p. 599-604, 1985.

MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, [S.l.], v. 5, n.1, p. 115-133, 1943.

MINSKY, M.; PAPERT, S. *Perceptrons: an introduction to computational geometry*. Cambridge: The MIT Press, 1969.

MORENO, M. M. T.; BARTOLOMEU, D.; LIMA, R. H. C. Análise do comportamento de queima de argilas e formulações para revestimento cerâmico. *Cerâmica*, [S.l.], n.55, p.286-295, 2009.

NUSSENZVEIG, H. M. (Org.). *Complexidade e caos*. Rio de Janeiro: UFRJ/COPEA, 1999.

PARKER, D. *Learning logic*. Invention report, Stanford University, File 1, Office Technology Licensing, 1982.

POLETTTO, E. R. A inovação tecnológica e a utilização de tecnologias ambientais como fator de diminuição de impactos ambientais na indústria cerâmica: o caso do APL de pisos e revestimentos cerâmicos de Santa Gertrudes (SP). *Geografia*, Londrina, v. 16, n. 2, p. 25-47, 2007.

POLETTTO, E. R. O desenvolvimento territorial e a utilização dos recursos naturais: a mineração de argila no APL de pisos e revestimentos cerâmicos de Santa Gertrudes (SP). In: FÓRUM AMBIENTAL DA ALTA PAULISTA, 2007, [S.l.]. *Anais...*, v. III, 2007b, p. 19.

PRADO, A. C. A. *Placas cerâmicas para revestimento de baixa absorção de água e estabilidade dimensional confeccionadas por moagem a seco usando o material da Formação Corumbataí*. 2007. 203f. Tese (Doutorado em Geologia Regional) – Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2007.

PRADO, A. C. A.; ZANARDO, A.; MORENO, M. M. T.; MENEGAZZO, A. P. M. Redução da susceptibilidade à deformação pirolástica das argilas do Pólo Cerâmico de Santa Gertrudes através da adição de matérias-primas. *Cerâmica*, [S.l.], n. 54, p. 7-20, 2008.

ROCHA, R. R. *Propriedades químico-mineralógicas de rochas da Formação Corumbataí: aplicação na classificação de produtos*. 2012. 203p. Tese (Doutorado em Geologia Regional) – Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2012.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, [S.l.], v. 65, n. 1, p. 386-408, 1958.

RUMELHART, D. E.; HINTON, G. E.; McCLELAND, J. L. *A general framework for parallel distributed processing*. Cambridge: The MIT Press, 1986.

VON DER MARLSBURG, C. Self-organizing of orientation sensitive cells in the striated cortex. *Kibernetik*, [S.l.], v. 14, n. 1, p. 66-82, 1973.

WASSERMAN, P. D. *Neural computing: theory and practice*. New York: Van Nostrand Reinhold, 1989.

WERBOS, P. *Beyond regression: new tools for prediction and analysis in the behavioral sciences*. 1974. Ph. D. Thesis. Harvard University, Cambridge, 1974.

WIDROW, B.; HOFF, M. *Adaptive switching circuits*. In: IRE WESCON CONVENTION RECORD, 1960, New York, Neurocomputing, p. 96-107.

BIBLIOGRAFIA COMPLEMENTAR

AIHARA, K.; TAKABE, T.; TOYODA, M. Chaotic neural networks. *Phys. Lett. A*, n. 144, p. 333-340, [S.l.], 1990.

BAIRD, B.; HIRSH, M. W.; ECKMAN, F. A neural network associative memory for handwritten character recognition using multiple Chua attractors. *IEEE Transactions on Circuits and Systems II: analog & digital signal processing*, 40, p. 667-674, 1993.

BARROS DE ANDRADE, L. *Mapeamento do potencial mineral para níquel e ouro no Cinturão Metassedimentar Nova Brasilândia – Rondônia por meio de lógica nebulosa (fuzzy) e redes neurais artificiais*. 2008. Dissertação (Mestrado em geociências) – Instituto de Geociências, Universidade Estadual de Campinas, Campinas, 2008.

BIONDI NETO, L.; SIEIRA, A. C. C.; DANZIGER, B. R.; DA SILVA, J. G. S. Neuro - CPT: classificação de solos usando redes neurais artificiais. *Engevista*, Rio de Janeiro, v. 8, n. 1, p.37-48, 2006.

BISHOP, C. M. *Neural networks for pattern recognition*. New York: Oxford University Press Inc., 1995.

BRASIL. Ministério das Minas e Energia. Secretaria de Geologia, Mineração e Transformação Mineral. *Anuário estatístico 2009*. Disponível em: <http://www.mme.gov.br>. Acesso em: 17 jan. 2010.

BURDEN, R. L.; FAIRES, J. D. *Análise numérica*. Tradução de All Taskes. Revisão Técnica de Helena Castro. São Paulo: Cengage Learning, 2008.

CABRAL JÚNIOR, M.; DEL MONTE, E.; MOTTA, J. F. M.; SINTONI, A.; SUSLICK, S.

Arranjos produtivos minero-cerâmicos e o desenvolvimento econômico: caso do APL de Socorro – SP. *Cerâmica Industrial*, [S.l.], n.11(2), p.1-6, 2006.

CAMPANHA, J. R.; TANCREDO, A. Um modelo físico para redes neurais. *Cad. Cat. Ens. Fis.*, Rio Claro, v. 8, n.1. p.56-63, 1991.

CESSAC, B. Increase in complexity in random neural networks. *J. Phys. I France* 5, [S.l.], p. 409-432, 1995.

CHAPMAN, S. J. *Programação em MATLAB® para engenheiros*. Tradução de Flávio Soares Correa da Silva. São Paulo: Pioneira Thomson Learning, 2003.

CHUTCHFIELD, J. et al. Power spectral analysis of a dynamical system. *Physics Letters*, [S.l.], v. 76A, n. 1, p. 1-4, 1980.

CORREIA, S. L.; HOTZA, D.; SEGADÃES, A. M. Otimização da resistência mecânica de corpos cerâmicos em função das matérias-primas e restrições de propriedades tecnológicas. *Cerâmica*, [S.l.], n. 51, p.230-238, 2005.

CRISANTI, A.; SOMPOLINSKY, H. Dynamics of spins systems with randomly asymmetric bonds ising spins and Glauber dynamics. *Physical Review A*, [S.l.], v. 37, n. 12, p. 4865-4874, 1988.

EKELAND, I. *O cálculo e o imprevisto*. Tradução de Maria Clara Constantino. Revisão Técnica de Hugo Vicente Capelato. São Paulo: Martins Fontes, 1987.

GORINI, A. P. F.; CORREA, A. R. Cerâmica para revestimento. *Cerâmica*, Rio de Janeiro, n. 10, p. 201-252, 1999.

GROSSBERG, S. *A theory of visual coding, memory and development: formal theories of visual perception*. New York: John Wiley & Sons, 1978.

GUTFREUND, H.; REGER, J. D.; YOUNG, A. P. The nature of attractors in an asymmetric spin glass with deterministic dynamics. *J. Phys. A. Math. Gen.*, [S.l.], n. 1, p. 2775-2797, 1988.

HANSELMAN, D.; LITTLEFIELD, B. *Matlab® 6: curso completo*. Tradução de Cláudia Sant'Ana Martins. Revisão Técnica de Alberto Saa, Francisco A. M. Gomes e M. Aparecida Diniz Ehrhardt. São Paulo: Prentice Hall, 2003.

HIRSCH, M. W.; BAIRD, B. Computing with dynamic attractors in neural networks. *Biosystems*, [S.l.], n. 34, p. 173-195, 1995.

IFEACHOR, E. C.; JERVIS, B. W. *Digital signal processing: a practical approach*. New York: Wesley Publishing Company, 1993.

KLOTZ, A.; BRÄUER, K. A small-size neural networks and fuzzy logic: basic concepts and applications. *The Institute of Electrical and Eletronics Engineers (IEEE) Press, Inc.*, New York, 1996.

KOHONEN, T. *Self organization and associative memory*. 1st. ed. Berlin: Springer-Verlag, 1984.

LANDIM, P. M. B. O grupo Passa Dois na Bacia do Rio Corumbataí. São Paulo: DNPM – DGM, 1970. Boletim 252.

LAU, C. (Ed.). *Neural networks: theoretical foundations and analysis*. New York: The Institute of Electrical and Eletronics Engineers (IEEE) Press, Inc., 1992.

LI, Z.; DAYAN, P. Computational differences between asymmetrical and symmetrical networks. *Network: Comput. Neural Syst.*, [S.l.], n.10, p. 59-77, 1999.

MASSON, M. R. *Caracterização de jazidas usando a garantia de qualidade de matérias-primas para indústria cerâmica de revestimento*. 2002. 267f. Tese (Doutorado em Geologia) – Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2002.

MIRZAI, A. R. (Org.). *Artificial intelligence: concepts and applications in engineering*. Cambridge: The MIT Press, [19-].

MORETTIN, P. A. Análise harmônica de processos estocásticos. In: COLÓQUIO BRASILEIRO DE MATEMÁTICA, 12., 1979, Poços de Caldas. *Anais...*, Poços de Caldas, 1979.

MOTTA, J. F. M. *As matérias-primas e o estudo de três casos de rochas fundentes*. 2000. 208f. Tese (Doutorado em Geologia) – Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro, 2000.

MOTTA, J. F. M. et al. Características do pólo de revestimentos cerâmicos de Santa Gertrudes – SP: com ênfase na produção de argilas. *Cerâmica Industrial*, São Paulo, v. 9, n.1, p. 7-13, 2004.

NOSE FILHO, K.; LOTUFO, A. D. P.; LOPES, M. L. M. Utilização de redes neurais artificiais e redes neuro fuzzy para previsão de cargas elétricas. In: BRAZILIAN CONFERENCE ON DYNAMICS, CONTROL AND APPLICATIONS, 7., 2008, Presidente Prudente. *Anais...*, Presidente Prudente, 2008, p.6.

OLIVEIRA, M. C.; MAGANHA, M. F. B. *Guia técnico ambiental da indústria cerâmica branca e de revestimento*. São Paulo: CETESB, série P + L, 2006, p.90.

OSLER, T. J. A quick look at Liapunov space. *New Jersey Mathematics and Computer Education*, New Jersey, v. 28, n. 2, p. 183-197, [19-].

PANDORFI, H.; SILVA, I. J. O.; SARNIGHAUSEN, V. C. R.; VIEIRA, F. M. C.; NASCIMENTO, S. T.; GUISELINI, C. Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura. *Revista Brasileira de Zootecnia*, [S.l.], v. 40, n. 3, p. 676-681, 2011.

PARK, J.; SANDBERG, W. Universal approximation using radial basis functions. *Neural Computation*, [S.l.], [s.n.], n. 3, 1991.

POGGIO, T.; GIROSI, F. Networks for approximation and learning. *Proceedings of the Electrical and Eletronics Engineers*, Detroit, v. 78, p. 1481-1497, 1990.

POGGIO, T.; GIROSI, F. Regularization algorithms for learning that are equivalent to multilayer networks. *Science*, [S.l.], v. 247, n. 1, p. 978-982, [19-].

PORWAL, A.; CARRANZA, E. J. M.; HALE, M. Artificial neural networks for mineral-potential mapping: a case study from Aravalli Province, Western India. *Natural Resources Research*, [S.l.], 12(3), p. 155-171, 2003.

RENALS, S.; ROHWER, R. A study of network dynamics. *Journal of Statistical Physics*, [S.l.], v. 58, n. 5/6, 1990.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. *Parallel Distributed Processing*, Cambridge, MIT Press, v. 1, p. 319-362, 1986b.

SHAFFER, W. M. Can nonlinear dynamics elucidate mechanisms in ecology and epidemiology? *IMA Journal of Mathematics Applied in Medicine and Biology*, [S.l.], n. 2, p. 221-252, 1985.

SHERRINGTON, D. *Magnets, microchips and memories: from spin glasses to the brain*, [S.l.], p.319-330, [19-].

VIEIRA, V. M. *Redes neurais artificiais: uma aplicação em petrofísica e estudo dos efeitos de estímulos persistentes*. 2007. 73p. Dissertação (Mestrado em Física) – Instituto de Física, Universidade Federal de Alagoas, Maceió, 2007.

WANDRESEN, R.; MITISHITA, E. A.; DE ANDRADE, J. B. Identificação de pontos de apoio pré-sinalizados com o uso de redes neurais artificiais e correlação. *Bol. Ciênc. Geod., sec. Artigos*, Curitiba, v. 9, n. 2, p. 179-198, 2003.

WANG, X. Chaos-based learning. *Complex Systems*, [S.l.], n . 5, p. 359-370, 1991.

WIDROW, B. Generalization and information storage in networks of adaline neurons. *Self-organizing Systems*. Washington, Spartan Books, p. 435-461, 1962.

ANEXOS

Anexo A - Variáveis físicas obtidas na temperatura de queima de 1000°C

AMOSTRA	RLQ (%)	PF (%)	Abs (%)	CR(N)	MRF (MPa)
CF1 B1	5.501	3.505	5.724	662.3	55.5
CF1 B2	5.504	4.945	6.625	537.8	47.0
CF1 B3	5.517	5.229	6.449	226.5	20.1
CF2 B2	5.473	5.682	8.583	619.3	49.8
CR1 B3	2.720	2.575	11.032	464.7	36.5
CR2 B1	3.838	2.605	8.955	520.1	41.7
CR2 B2	4.085	2.666	8.810	596.7	48.2
CR2 B3	3.152	3.259	10.964	438.6	35.3
PG B1	3.545	2.093	10.179	575.3	42.8
PG B2	3.093	1.972	10.432	498.1	37.8
PG B3	2.232	1.988	13.460	478.4	34.3
PG B4	4.159	5.055	11.884	561.4	45.0
PT1 B1	2.613	2.768	11.295	336.3	25.5
PT1 B2	4.483	3.260	8.337	587.0	48.5
PT1 B3	3.909	2.970	8.932	548.8	43.6
PT1 B4	2.966	2.975	10.656	468.2	36.9
PT2 B1	2.170	2.449	12.417	288.5	20.7
PT2 B2	3.459	2.565	10.135	506.3	39.4
PT2 B3	3.976	2.933	9.804	278.3	21.4
PT3 B1	2.452	5.051	18.466	306.6	20.4
PI B1	2.012	1.997	14.113	343.7	24.0
PI B2	2.929	2.775	10.007	409.5	31.6
PI B3	5.335	4.001	6.934	499.0	42.7
PI B4	3.750	4.735	11.938	608.7	47.5
Amplitude	3.505	3.710	12.742	435.8	35.4
Média	3.7030	3.3355	10.2555	473.34	37.34
Desvio Padrão	1.13556	1.16162	2.77118	121.216	10.600

Anexo B – Variáveis físicas obtidas na temperatura de queima de 1020°C

AMOSTRA	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	2.058	1.985	0.381	7.121	3.506	3.202	677.4	61.3
CF1 B2	2.006	1.863	0.668	6.722	5.261	4.843	673.3	59.7
CF1 B3	1.973	1.848	0.794	6.630	5.577	5.567	589.1	52.5
CF2 B1	2.008	1.867	0.500	2.246	7.598	13.863	428.0	33.6
CF2 B2	2.013	1.846	0.851	6.854	5.650	5.423	766.8	69.8
CR1 B3	2.076	1.887	0.094	5.579	2.752	5.572	602.4	51.2
CR1 B4	2.119	1.935	0.136	1.398	3.993	12.527	445.9	34.8
CR2 B1	2.071	1.893	0.172	5.900	2.965	4.669	588.1	49.4
CR2 B2	2.088	1.897	0.279	6.316	3.153	4.269	643.7	57.6
CR2 B3	2.073	1.897	0.207	5.031	3.644	7.218	566.0	47.3
PG B1	2.022	1.845	0.173	6.298	2.393	4.905	695.6	58.3
PG B2	2.044	1.853	0.159	5.942	2.138	5.183	681.1	56.7
PG B3	1.928	1.751	0.118	5.451	2.346	9.251	642.1	46.1
PG B4	1.991	1.823	0.344	5.674	5.642	9.374	593.3	50.3
PT1 B2	2.017	1.864	0.381	6.913	3.060	3.757	684.3	60.2
PT1 B3	2.081	1.888	0.299	6.331	3.001	3.998	646.7	57.9
PT1 B4	2.052	1.893	0.359	5.257	3.124	6.283	612.2	52.0
PT2 B2	2.045	1.864	0.146	5.994	2.625	4.665	661.7	59.0
PT2 B3	2.005	1.850	0.275	6.192	2.952	4.972	606.8	50.9
PI B1	1.963	1.800	0.056	4.130	2.318	9.486	515.2	42.9
PI B2	2.050	1.873	0.239	4.332	3.265	7.044	384.6	29.9
PI B3	2.003	1.871	0.548	6.988	4.256	3.897	715.3	64.1
PI B4	1.999	1.850	0.317	5.027	5.407	9.154	768.9	65.3
TU B2	2.051	1.906	0.118	1.724	5.742	15.129	478.2	35.6
TU B3	1.984	1.816	0.082	0.806	6.041	18.718	328.1	22.9
Amplitude	0.191	0.234	0.795	6.315	5.460	15.516	440.8	46.9
Média	2.0288	1.8666	0.3078	5.2342	3.9364	7.3188	599.79	50.77
Desvio Padrão	0.04264	0.04504	0.21738	1.82845	1.48738	4.00806	113.806	11.872

Anexo C – Variáveis físicas obtidas na temperatura de queima de 1040°C

AMOSTRA	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	2.063	1.896	0.357	7.969	3.480	1.421	727.2	67.0
CF1 B2	2.018	1.873	0.674	7.497	5.227	3.147	766.4	69.3
CF1 B3	1.981	1.857	0.825	7.451	5.626	4.014	609.7	56.1
CF2 B1	1.985	1.849	0.501	3.511	7.558	12.135	478.6	37.4
CF2 B2	2.008	1.852	0.928	8.184	6.338	3.629	763.0	69.5
CR1 B3	2.075	1.885	0.098	7.104	2.735	2.437	738.9	64.2
CR1 B4	2.114	1.930	0.138	2.974	4.045	9.689	575.4	47.1
CR1 B5	2.064	1.853	0.288	0.225	3.253	16.795	134.3	9.8
CR2 B1	2.071	1.892	0.176	6.755	3.094	2.354	651.3	54.4
CR2 B2	2.083	1.892	0.341	7.491	3.052	1.798	743.2	67.4
CR2 B3	2.076	1.898	0.209	6.689	3.682	4.067	629.1	56.4
PG B1	2.019	1.839	0.114	8.195	2.454	1.758	751.0	66.3
PG B2	2.030	1.854	0.136	7.601	2.170	2.134	792.5	70.3
PG B3	1.951	1.781	0.094	7.974	2.247	4.057	771.5	63.3
PG B4	2.006	1.813	0.360	6.916	5.280	7.096	669.4	59.7
PT1 B3	2.073	1.892	0.297	7.743	3.166	1.435	739.4	66.4
PT1 B4	2.046	1.887	0.349	6.969	3.263	2.794	725.4	64.6
PT2 B3	2.006	1.848	0.267	7.743	2.980	2.252	635.1	57.3
PT3 B1	1.899	1.745	0.056	4.196	5.238	14.211	641.7	48.8
PI B1	1.967	1.800	0.062	5.934	2.386	6.039	576.3	45.5
PI B3	2.003	1.870	0.514	8.078	4.455	1.959	752.8	68.2
PI B4	1.998	1.843	0.317	6.109	5.091	6.761	765.8	67.4
TU B2	2.051	1.875	0.098	3.487	5.839	12.025	558.8	43.5
TU B3	1.992	1.818	0.126	1.901	6.194	16.765	380.2	27.3
Amplitude	0.215	0.185	0.872	7.970	5.388	15.374	658.2	60.5
Média	2.0241	1.8559	0.3052	6.1957	4.1189	5.8655	649.04	56.13
Desvio Padrão	0.04958	0.04189	0.23681	2.23705	1.51295	4.99129	150.641	15.067

Anexo D – Variáveis físicas obtidas na temperatura de queima de 1060°C.

AMOSTRA	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	2.065	1.910	0.419	8.167	3.733	0.202	760.9	70.6
CF1 B2	2.029	1.881	0.658	8.231	5.334	1.641	738.7	69.0
CF1 B3	2.018	1.879	0.753	8.047	5.366	2.001	643.7	60.8
CF2 B1	2.018	1.879	0.508	5.024	7.720	7.531	556.4	46.5
CF2 B2	2.013	1.861	0.886	8.885	6.179	2.195	775.8	65.8
CR1 B3	2.082	1.890	0.086	7.202	2.776	0.360	745.6	64.2
CR1 B4	2.126	1.944	0.170	6.131	4.093	2.689	764.3	69.3
CR1 B5	2.041	1.851	0.193	0.742	3.096	15.557	172.5	12.5
CR2 B2	2.086	1.896	0.287	7.115	3.115	0.210	744.1	54.8
CR2 B3	2.083	1.909	0.219	7.619	3.942	1.811	706.0	65.8
PG B1	2.022	1.848	0.148	8.675	2.582	0.154	786.3	69.3
PG B2	2.040	1.855	0.146	7.785	2.261	0.138	926.6	82.2
PG B3	1.960	1.786	0.122	9.527	2.162	0.229	929.3	79.6
PG B4	2.005	1.836	0.342	8.043	5.605	4.475	723.0	66.8
PT1 B4	2.047	1.895	0.359	7.556	3.287	0.581	818.3	73.0
PT2 B3	2.006	1.853	0.283	8.275	3.033	0.741	720.4	65.3
PT3 B1	1.940	1.747	0.038	5.172	5.289	12.070	677.7	53.1
PI B1	1.965	1.802	0.042	7.012	2.505	3.976	598.1	49.3
PI B3	2.009	1.865	0.482	8.585	4.213	0.927	739.4	68.7
PI B4	2.007	1.851	0.328	7.087	5.507	4.890	785.4	69.0
TU B1	2.032	1.860	0.068	0.106	10.146	21.738	247.6	17.0
TU B2	2.047	1.873	0.110	6.162	5.790	5.814	724.5	60.2
TU B3	1.984	1.819	0.082	2.941	6.161	14.410	456.5	33.6
Amplitude	0.186	0.197	0.848	9.421	7.984	21.600	756.8	69.7
Média	2.0272	1.8604	0.2926	6.6995	4.5172	4.5365	684.4	59.41
Desvio Padrão	0.04362	0.04316	0.23398	2.45970	1.94883	5.91185	181.683	17.703

Anexo E - Variáveis físicas obtidas na temperatura de queima de 1000°C. (Minas CF, CR, PG, PT e PI)

AMOSTRA	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	5.501	3.505	5.724	662.3	55.5
CF1 B2	5.504	4.945	6.625	537.8	47.0
CF1 B3	5.517	5.229	6.449	226.5	20.1
CF2 B2	5.473	5.682	8.583	619.3	49.8
CR1 B3	2.720	2.575	11.032	464.7	36.5
CR2 B2	4.085	2.666	8.810	596.7	48.2
CR2 B3	3.152	3.259	10.964	438.6	35.3
PG B1	3.545	2.093	10.179	575.3	42.8
PG B2	3.093	1.972	10.432	498.1	37.8
PG B3	2.232	1.988	13.460	478.4	34.3
PG B4	4.159	5.055	11.884	561.4	45.0
PT1 B4	2.966	2.975	10.656	468.2	36.9
PT2 B2	3.459	2.565	10.135	506.3	39.4
PI B1	2.012	1.997	14.113	343.7	24.0
PI B3	5.335	4.001	6.934	499.0	42.7
PI B4	3.750	4.735	11.938	608.7	47.5
Amplitude	3.505	3.710	8.389	435.8	35.4
Média	3.9064	3.4526	9.8699	505.31	40.18
Desvio	1.22611	0.49096	2.49924	108.912	9.245
Padrão					

Anexo F – Variáveis físicas obtidas na temperatura de queima de 1020°C. (Minas CF, CR, PG, PT e PI)

AMOSTRA	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	7.121	3.506	3.202	677.4	61.3
CF1 B2	6.722	5.261	4.843	673.3	59.7
CF1 B3	6.630	5.577	5.567	589.1	52.5
CF2 B2	6.854	5.650	5.423	766.8	69.8
CR1 B3	5.579	2.752	5.572	602.4	51.2
CR2 B2	6.316	3.153	4.269	643.7	57.6
CR2 B3	5.031	3.644	7.218	566.0	47.3
PG B1	6.298	2.393	4.905	695.6	58.3
PG B2	5.942	2.138	5.183	681.1	56.7
PG B3	5.451	2.346	9.251	642.1	46.1
PG B4	5.674	5.642	9.374	593.3	50.3
PT1 B4	5.257	3.124	6.283	612.2	52.0
PT2 B3	6.192	2.952	4.972	606.8	50.9
PI B1	4.130	2.318	9.486	515.2	42.9
PI B3	6.988	4.256	3.897	715.3	64.1
PI B4	5.027	5.407	9.154	768.9	65.3
Amplitude	2.991	3.512	6.284	253.7	26.9
Média	5.9508	3.7574	6.1624	646.83	55.38
Desvio	0.84024	1.33480	2.07216	70.255	7.490
Padrão					

Anexo G – Variáveis físicas obtidas na temperatura de queima de 1040°C. (Minas CF, CR, PG, PT e PI)

AMOSTRA	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	7.969	3.480	1.421	727.2	67.0
CF1 B2	7.497	5.227	3.147	766.4	69.3
CF1 B3	7.451	5.626	4.014	609.7	56.1
CF2 B2	8.184	6.338	3.629	763.0	69.5
CR1 B3	7.104	2.735	2.437	738.9	64.2
CR2 B2	7.491	3.052	1.798	743.2	67.4
CR2 B3	6.689	3.682	4.067	629.1	56.4
PG B1	8.195	2.454	1.758	751.0	66.3
PG B2	7.601	2.170	2.134	792.5	70.3
PG B3	7.974	2.247	4.057	771.5	63.3
PG B4	6.916	5.280	7.096	669.4	59.7
PT1 B4	6.969	3.263	2.794	725.4	64.6
PT2 B3	7.743	2.980	2.252	635.1	57.3
PI B1	5.934	2.386	6.039	576.3	45.5
PI B2	8.078	4.455	1.959	752.8	68.2
PI B4	6.109	5.091	6.761	765.8	67.4
Amplitude	2.261	4.168	5.675	216.2	24.0
Média	7.3690	3.7791	3.4602	713.58	63.28
Desvio	0.70007	1.35970	1.80192	66.937	6.691
Padrão					

Anexo H – Variáveis físicas obtidas na temperatura de queima de 1060°C. (Minas CF, CR, PG, PT e PI)

AMOSTRA	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	8.167	3.733	0.202	760.9	70.6
CF1 B2	8.231	5.334	1.641	738.7	69.0
CF1 B3	8.047	5.366	2.001	643.7	60.8
CF2 B2	8.885	6.179	2.195	775.8	65.8
CR1 B3	7.202	2.776	0.360	745.6	64.2
CR2 B2	7.115	3.115	0.210	744.1	54.8
CR2 B3	7.619	3.942	1.811	706.0	65.8
PG B1	8.675	2.582	0.154	786.3	69.3
PG B2	7.785	2.261	0.138	926.6	82.2
PG B3	9.527	2.162	0.229	929.3	79.6
PG B4	8.043	5.605	4.475	723.0	66.8
PT1 B4	7.556	3.287	0.581	818.3	73.0
PT2 B3	8.275	3.033	0.741	720.4	65.3
PI B1	7.012	2.505	3.976	598.1	49.3
PI B3	8.585	4.213	0.927	739.4	68.7
PI B4	7.087	5.507	4.890	785.4	69.0
Amplitude	2.515	4.017	4.752	331.2	32.9
Média	7.9882	3.8500	1.5332	758.85	67.14
Desvio	0.71600	1.35089	1.61216	84.975	8.037
Padrão					

Anexo I – Variáveis físicas obtidas na temperatura de queima de 1020°C. (Minas CF, CR, PG, PT, PI e TU)

AMOSTRA	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	ABS (%)	CR (N)	MRF (MPa)
CF1 B1	2.058	1.985	0.381	7.121	3.506	3.202	677.4	61.3
CF1 B2	2.006	1.863	0.668	6.722	5.261	4.843	673.3	59.7
CF1 B3	1.973	1.848	0.794	6.630	5.577	5.567	589.1	52.5
CF2 B1	2.008	1.867	0.500	2.246	7.598	13.863	428.0	33.6
CF2 B2	2.013	1.846	0.851	6.854	5.650	5.423	766.8	69.8
CR1 B3	2.076	1.887	0.094	5.579	2.752	5.572	602.4	51.2
CR1 B4	2.119	1.935	0.136	1.398	3.993	12.527	445.9	34.8
CR2 B2	2.088	1.897	0.279	6.316	3.153	4.269	643.7	57.6
CR2 B3	2.073	1.897	0.207	5.031	3.644	7.218	566.0	47.3
PG B1	2.022	1.845	0.173	6.298	2.393	4.905	695.6	58.3
PG B2	2.044	1.853	0.159	5.942	2.138	5.183	681.1	56.7
PG B3	1.928	1.751	0.118	5.451	2.346	9.251	642.1	46.1
PG B4	1.991	1.823	0.344	5.674	5.642	9.374	593.3	50.3
PT1 B4	2.052	1.893	0.359	5.257	3.124	6.283	612.2	52.0
PT2 B3	2.005	1.850	0.275	6.192	2.952	4.972	606.8	50.9
PI B1	1.963	1.800	0.056	4.130	2.318	9.486	515.2	42.9
PI B3	2.003	1.871	0.548	6.988	4.256	3.897	715.3	64.1
PI B4	1.999	1.850	0.317	5.027	5.407	9.154	768.9	65.3
TU B2	2.051	1.906	0.118	1.724	5.742	15.129	478.2	35.6
TU B3	1.984	1.816	0.082	0.806	6.041	18.718	328.1	22.9
Amplitude	0.191	0.234	0.795	6.315	5.460	15.516	440.8	46.9
Média	2.0228	1.8642	0.3230	5.0693	4.1747	7.9418	601.47	50.65
Desvio Padrão	0.04681	0.04992	0.23783	1.97134	1.57618	4.22980	114.976	12.003

Anexo J – Variáveis físicas obtidas na temperatura de queima de 1040°C. (Minas CF, CR, PG, PT, PI e TU)

AMOSTRA	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	2.063	1.896	0.357	7.969	3.480	1.421	727.2	67.0
CF1 B2	2.018	1.873	0.674	7.497	5.227	3.147	766.4	69.3
CF1 B3	1.981	1.857	0.825	7.451	5.626	4.014	609.7	56.1
CF2 B1	1.985	1.849	0.501	3.511	7.558	12.135	478.6	37.4
CF2 B2	2.008	1.852	0.928	8.184	6.338	3.629	763.0	69.5
CR1 B3	2.075	1.885	0.098	7.104	2.735	2.437	738.9	64.2
CR1 B4	2.114	1.930	0.138	2.974	4.045	9.689	575.4	47.1
CR2 B2	2.083	1.892	0.341	7.491	3.052	1.798	743.2	67.4
CR2 B3	2.076	1.898	0.209	6.689	3.682	4.067	629.1	56.4
PG B1	2.019	1.839	0.114	8.195	2.454	1.758	751.0	66.3
PG B2	2.030	1.854	0.136	7.601	2.170	2.134	798.5	70.3
PG B3	1.951	1.781	0.094	7.974	2.247	4.057	771.5	63.3
PG B4	2.006	1.813	0.360	6.916	5.280	7.096	669.4	59.7
PT1 B4	2.046	1.887	0.349	6.969	3.263	2.794	725.4	64.6
PT2 B3	2.006	1.848	0.267	7.743	2.980	2.252	635.1	57.3
PI B1	1.967	1.800	0.062	5.934	2.386	6.039	576.3	45.5
PI B3	2.003	1.870	0.514	8.078	4.455	1.959	752.8	68.2
PI B4	1.998	1.843	0.317	6.109	5.091	6.761	765.8	67.4
TU B2	2.051	1.875	0.098	3.487	5.839	12.025	558.8	43.5
TU B3	1.992	1.818	0.126	1.901	6.194	16.765	380.2	27.3
Amplitude	0.163	0.149	0.866	6.294	5.388	15.344	418.3	43.0
Média	2.0236	1.8580	0.3254	6.4889	4.2051	5.2989	670.82	58.39
Desvio Padrão	0.04274	0.03646	0.25157	1.93347	1.83622	4.26439	110.377	11.944

Anexo K – Variáveis físicas obtidas na temperatura de queima de 1060°C. (Minas CF, CR, PG, PT, PI e TU)

AMOSTRA	DP (g/cm ³)	DAS (g/cm ³)	RLS (%)	RLQ (%)	PF (%)	Abs (%)	CR (N)	MRF (MPa)
CF1 B1	2.065	1.910	0.419	8.167	3.733	0.202	760.9	70.6
CF1 B2	2.029	1.881	0.658	8.231	5.334	1.641	738.7	69.0
CF1 B3	2.018	1.879	0.753	8.047	5.366	2.001	643.7	60.8
CF2 B1	2.018	1.879	0.508	5.024	7.720	7.531	556.4	46.5
CF2 B2	2.013	1.861	0.886	8.885	6.179	2.195	775.8	65.8
CR1 B3	2.082	1.890	0.086	7.202	2.776	0.360	745.6	64.2
CR1 B4	2.126	1.944	0.170	6.131	4.093	2.689	764.3	69.3
CR2 B2	2.086	1.896	0.287	7.115	3.115	0.210	744.1	54.8
CR2 B3	2.083	1.909	0.219	7.619	3.942	1.811	706.0	65.8
PG B1	2.022	1.848	0.148	8.675	2.582	0.154	786.3	69.3
PG B2	2.040	1.855	0.146	7.785	2.261	0.138	926.6	82.2
PG B3	1.960	1.786	0.122	9.527	2.162	0.229	929.3	79.6
PG B4	2.005	1.836	0.342	8.043	5.605	4.475	723.0	66.8
PT1 B4	2.047	1.895	0.359	7.556	3.287	0.581	818.3	73.0
PT2 B3	2.006	1.853	0.283	8.275	3.033	0.741	720.4	65.3
PI B1	1.965	1.802	0.042	7.012	2.505	3.976	598.1	49.3
PI B3	2.009	1.865	0.482	8.585	4.213	0.927	739.4	68.7
PI B4	2.007	1.851	0.328	7.087	5.507	4.890	785.4	69.0
TU B2	2.047	1.873	0.110	6.162	5.790	5.814	724.5	60.2
TU B3	1.984	1.819	0.082	2.941	6.161	14.410	456.5	33.6
Amplitude	0.166	0.158	0.844	6.586	5.558	14.272	472.8	48.6
Média	2.0306	1.8666	0.3215	7.4035	4.2682	2.7488	732.17	64.19
Desvio Padrão	0.04219	0.03788	0.23648	1.48494	1.58971	3.48596	109.468	7.995