UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Ilha Solteira

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

Idealizações de um Programa Baseado em Redes Neurais para Dosagem de Concreto

ENIO JOSÉ BOLOGNINI

Orientadora: Profa. Dra. Maria da Consolação Fonseca de Albuquerque
Co-orientador: Prof. Dr. José Fernando Moretti

Ilha Solteira - SP
Setembro/2016

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Ilha Solteira

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

Idealizações de um Programa Baseado em Redes Neurais para Dosagem de Concreto

ENIO JOSÉ BOLOGNINI

Orientadora: Profa. Dra. Maria da Consolação Fonseca de Albuquerque
Co-orientador: Prof. Dr. José Fernando Moretti

Dissertação apresentada ao programa de Pós-Graduação de Engenharia Civil para obtenção do título de Mestre em Engenharia Civil.

Área de Conhecimento: Estruturas

Ilha Solteira - SP
Setembro/2016

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

B693i

Bolognini, Enio José.
Idealizações de um programa baseado em redes neurais para dosagem de concreto / Enio José Bolognini. -- Ilha Solteira: [s.n.], 2016
156 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Estruturas, 2016

Orientador: Maria da Consolação Fonseca de Albuquerque
Co-orientador: José Fernando Moretti
Inclui bibliografia

1. Concreto. 2. Dosagem. 3. Inteligência rtificial. 4. Redes neurais. 5. Otimização computacional. 6. *Software*.

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Idealização de um programa computacional baseado em redes neurais para dosagem de concreto

AUTOR: ENIO JOSÉ BOLOGNINI
ORIENTADORA: MARIA DA CONSOLAÇÃO FONSECA DE ALBUQUERQUE
COORIENTADOR: JOSE FERNANDO MORETTI

Aprovado como parte das exigências para obtenção do Título de Mestre em ENGENHARIA CIVIL, área: ESTRUTURAS pela Comissão Examinadora:

Prof. Dr. SERGIO AUGUSTO MELLO DA SILVA
Departamento de Engenharia Civil / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. RODRIGO CAPOBIANCO GUIDO
Departamento de Ciências de Computação e Estatística / Instituto de Biociências, Letras e Ciências Exatas

Profa. Dra. CARLA NEVES COSTA
Departamento de Estruturas / Universidade de Campinas

Ilha Solteira, 02 de setembro de 2016

“Dedico este trabalho a Deus. Pois, com muita fé, humildade, amor e paz, realizei esta pesquisa em prol a Ciência”.

AGRADECIMENTOS

Dedico esta dissertação a Deus, por todas orações e pedidos de ações de graças, que foram realizados durante a jornada deste trabalho.

Agradeço a minha mãe Maria Aparecida Nemits Bolognini, pela coragem e educação, que a mim foram dadas a esta pessoa vencedora.

Aos meus amigos e parentes que fazem parte desta história. Deus ilumine vossas vidas.

Agradeço a Profa. Dra. Maria da Consolação Fonseca de Albuquerque, por se colocar a orientar-me nesta caminha a este título de mestrado.

Ao Prof. Dr. José Fernando Moretti pelas vossas orientações, e ao coord. Prof. Dr. Jefferson Nascimento de Oliveira, pelas vossas orientações do programa de mestrado. Também, a todos os professores do programa, em especial aos discentes: Karoline Aparecida de Souza Guimarães e Ruan Larisson Toninatto Vilela.

Aos professores: Dr. José Antonio Armani Paschoal, Dr. José Luiz Falótico Correa, Dr. Rodrigo Capobianco Guido, Ms. Antonio Ferreira Fabriga e Esp. Ademir Pradella, por todas orientações de estudo neste trabalho de pesquisa.

Ao Centro Universitário do Norte Paulista – UNORP, meus agradecimentos a esta casa em que recebi minha graduação. Atualmente leciono nesta família como docente. Também, em especial ao Dr. Augusto Cezar Casseb e a todos professores: Ms. Almir Giovani Figueredo, Ms. Ana Paula Fuji, Ms. Fabiana Zanquetta de Azevedo, Ms. José Renato Bianchi e Ms. Marian Faccin Jammal. Também, agradeço aos demais docentes desta instituição e ofereço pedidos de bênçãos a Deus, que os ilumine na caminhada em busca de seus objetivos.

Agradeço a Universidade Paulista – UNIP, campus São José do Rio Preto/SP, onde atualmente leciono como docente do curso de engenharia civil e ao PRONATEC, curso técnico profissionalizante, onde comecei a lecionar nesta instituição.

Aos professores da União das Escolas do Grupo FAIMI de Educação, em especial aos professores: Ms. Leandro de Oliveira Tancredo, Ms. Marilena Estrella Facuri, Ms. Marco Antônio Ferreira Matheus e Esp. Alexandre Cavalcante de Almeida e Nascimento.

Agradeço aos assistentes de suporte acadêmico: Flávio Rogério Porato, Gilson Campos Correa e Mário Roberto Correa Ferreira, pela amizade, orientações e trabalhos realizados durante esta pesquisa.

Agradeço ao Departamento de Engenharia Civil (DEC) da Faculdade de Engenharia de Ilha Solteira – FEIS, campus UNESP, por realizar este sonho, e, também, pela conquista de novos objetivos e projetos.

RESUMO

A produção de concreto está cada vez mais exigente. Medidas de prevenção e correção são empregadas na dosagem do concreto, gerando lucros e economia no preparo. A fim de obter economia e praticidade na dosagem de concretos, neste estudo foi desenvolvido, após a coleta de dados experimentais, a criação de rede neural artificial *feedforward*, utilizando algoritmo genético de retropropagação (*backpropagation*). A rede neural artificial (RNA) é composta de quatro camadas, entre entradas, pesos, bias, função de ativação sigmóide e saída desejada. O modelo conta com funções sigmoides, a fim de calcular e otimizar o erro através das camadas anteriores, até a entrada. Este modelo, por ser mais preciso, conta com certo momento e taxa de aprendizagem. A proposta da rede neural artificial (RNA) em *feedforward*, com o algoritmo genético de retropropagação (*backpropagation*), foi implementada em forma estrutural, e com uma interface gráfica, na qual o usuário final possa escolher a resistência desejada, tipo de cimento, tipo e dimensão de agregados graúdos, dimensão de agregados miúdos, tipo de concreto e aditivo, se for o caso de concretos de alta resistência (CAR). Nesta pesquisa, a coleta de dados, para armazenar no programa, foi realizada por meio de ensaios de caracterização dos materiais e de dosagem e resistência do concreto. A linguagem de programação *Java* foi utilizada para programar o algoritmo genético e a interface usuário. Foram realizados os testes e manutenção da ferramenta computacional, seguindo regras importantes no desenvolvimento de *softwares*. O resultado final, deste desenvolvimento, foi um *software* capaz de calcular a dosagem do concreto para o usuário, quando este insere valores de resistência à compressão axial desejada e o material que será usado na confecção do concreto.

Palavras chave: Concreto; Dosagem de Concreto; Resistência; *Software*.

ABSTRACT

The concrete production is increasingly demanding. preventive and corrective measures are used in concrete dosage, generating profits and savings in preparation. In order to achieve economy and practicality in the dosage of concrete in this study was developed after the collection of experimental data, the creation of artificial neural network feedforward using genetic algorithm backpropagation. The artificial neural network (ANN) is composed of four layers, between inputs, weights, biases, sigmoid activation functions and output desired. The model has sigmoid functions in order to calculate and optimize the error by the preceding layers, until the entrance. This model, to be more precise, has the right time and learning rate. The proposed artificial neural network (ANN) in feedforward, with the genetic algorithm backpropagation, was implemented in structural form, and with a graphical interface, in which the end user can choose the desired strength, cement type, and size of coarse aggregates, fine aggregates dimension, type of concrete and additives, if any of high strength concrete (CAR). In this research, data collection, to store the program, was carried out by means of characterization tests of materials and dosage and strength of concrete. The Java programming language was used to program the genetic algorithm and the user interface. testing and maintaining software tool were conducted following important rules in the software development. The end result of this development was an able to calculate the dosage of specific software for the user, when it enters resistance values to the desired axial compression and the material that will be used in the manufacture of concrete.

Keywords: Concrete; Concrete dosage; Resistance; Software.

LISTA DE ILUSTRAÇÕES

Figura 1 – Neurônio do sistema nervoso humano..... 35
Figura 2 – Neurônio artificial de *McCalluch-Pits*..... 36
Figura 3 – Função de ativação relé..... 38
Figura 4 – Função de ativação lógica *Threshold* 39
Figura 5 – Função de ativação sigmóide (1) 39
Figura 6 – Função de ativação sigmóide (2) 40
Figura 7 – Modelos de treinamento para redes neurais artificiais..... 42
Figura 8 – Algoritmo descendente 45
Figura 9 – Modelo aplicado para três estágios de treinamento..... 50
Figura 10 – Modelo de redes neurais artificiais..... 53
Figura 11 – Fases de desenvolvimento proposto..... 57
Figura 12 – Britas de basalto B0 e B1 60
Figura 13 – Refugos, usina de reciclagem e britas de granito B0 e B1..... 61
Figura 14 – Britas de seixo-rolado 61
Figura 15 – Areia grossa espalhada e seca por 48h sob os raios solares para obter umidade 0%..... 62
Figura 16 – Estufa para secagem das amostras dos ensaios com temperatura de (105±5)°C.. 63
Figura 17 – Agitador mecânico para agregados graúdos e agregados miúdos 64
Figura 18 – Curvas das amostras M1 e M2 de granulometria da areia grossa 67
Figura 19 – Modelo e leitura do frasco de Chapman 68
Figura 20 – Tronco de cone utilizado para teste de absorção da água no agregado miúdo.... 69
Figura 21 – Curvas das amostras M1 e M2 de granulometria do basalto B0 71
Figura 22 – Curvas das amostras M1 e M2 de granulometria do basalto B1 72
Figura 23 – Curvas das amostras M1 e M2 de granulometria do granito B0 73
Figura 24 – Curvas das amostras M1 e M2 de granulometria do granito B1 74
Figura 25 – Curvas das amostras M1 e M2 de granulometria do seixo rolado B1 75
Figura 26 – Recipiente cilíndrico e soquete metálico para compactação 79
Figura 27 – Exemplo do diagrama de dosagem 80
Figura 28 – Molde de tronco-cônico 83
Figura 29 – Verificação da coesão do concreto fresco 84

Figura 30 – Ensaio do capeamento por enxofre dos corpos de prova 85
Figura 31 – Rede neural artificial com quatro camadas entre quatro entrada, duas camadas intermediárias e uma saída 87
Figura 32 – Rede neural artificial com três camadas 87
Figura 33 – Diagrama de atividades do *software* DECCONCRETO 90
Figura 34 – Diagrama de casos do *software* DECCONCRETO 91
Figura 35 – Diagrama de classes do software DECCONCRETO 92
Figura 36 – *Software* DECCONCRETO 93
Figura 37 – Cadastramento de Resistências no DECCONCRETO 94
Figura 38 – Painel de consultas de resistências (MPa) 94
Figura 39 – Traço de concreto inteligente por redes neurais artificiais *feedfoward* 95
Figura 40 – Direitos Autorais 96
Figura 41 – Proposta do MER de software DECCONCRETO..... 97
Figura 42 – Curvas do diagrama de dosagem dos CCs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de basalto com diâmetro (B1) 105
Figura 43 – Curvas do diagrama de dosagem dos CCs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de basalto com diâmetros (B1/B0) 107
Figura 44 – Curvas do diagrama de dosagem dos CCs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetro (B0) 109
Figura 45 – Curvas do diagrama de dosagem dos CCs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetro (B1) 111
Figura 46 – Curvas do diagrama de dosagem dos CCs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetros (B1/B0) 113
Figura 47 – Curvas do diagrama de dosagem dos CCs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de seixo rolado com diâmetro (B1) 115
Figura 48 – Curvas do diagrama de dosagem dos CARs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de basalto com diâmetro (B0) 117
Figura 49 – Curvas do diagrama de dosagem dos CARs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de basalto com diâmetro (B1) 119
Figura 50 – Curvas do diagrama de dosagem dos CARs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 entre 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetro (B0) 121
Figura 51 – Curvas do diagrama de dosagem dos CARs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 entre 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetro (B1) 123

Figura 52 – Curvas do diagrama de dosagem dos CARs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 entre 7, 28 e 91 dias, referente a relação dos agregados graúdos de granito com diâmetro (B1/B0) 125
Figura 53 – Curvas do diagrama de dosagem dos CARs para as dosagens: 1:3,5; 1:5,0 e 1:6,5 entre 7, 28 e 91 dias, referente aos agregados graúdos de seixo rolado com diâmetro (B1) ... 127
Figura 54 – Resultados dos erros (e) de três camadas 128
Figura 55 – Resultados dos erros (e) de quatro camadas 128
Figura 56 – Resultados dos erros (e) de três camadas 129
Figura 57 – Resultados dos erros (e) de quatro camadas 130

LISTA DE TABELAS

Tabela 1 – Classificação e composição dos cimentos..... 31
Tabela 2 – Cimentos utilizados no presente trabalho..... 59
Tabela 3 – Série normal e intermediária de peneiras conforme a NM-ISO 3310-1 ou 2, para ensaio de granulometria..... 63
Tabela 4 – Peneiras (mm) e série, para ensaio de granulometria dos agregados miúdos..... 64
Tabela 5 – Módulo de finura e classificação do agregado miúdo..... 65
Tabela 6 – Distribuição granulométrica por limites dos agregados miúdos..... 66
Tabela 7 – Resultados dos ensaios de granulometria das amostras M1 e M2 de granulometria do agregado miúdo..... 66
Tabela 8 – Resultados de Leituras do frasco de Chapman e valores das massas específicas... 69
Tabela 9 – Resultados do ensaio de absorção do agregado miúdo..... 70
Tabela 10 – Resultados dos ensaios de granulometria das amostras M1 e M2 para as britas de basalto B0..... 71
Tabela 11 – Resultados dos ensaios de granulometria das amostras M1 e M2 para as britas de basalto B1..... 72
Tabela 12 – Resultados dos ensaios de granulometria das amostras M1 e M2 para as britas de granito B0.....73
Tabela 13 – Resultados dos ensaios de granulometria das amostras M1 e M2 para as britas de granito B1..... 74
Tabela 14 – Resultados dos ensaios de granulometria das amostras M1 e M2 das britas de seixo-rolado B1..... 75
Tabela 15 – Resultados dos ensaios para obtenção de massas específicas dos agregados graúdos…..... 76
Tabela 16 – Resultados dos ensaios para obtenção de massas específicas dos agregados graúdos..... 78
Tabela 17 – Valores encontrados da relação brita B1 e B0..... 79
Tabela 18 – Parâmetros de taxas da rede neural *feedforward*..... 90
Tabela 19 – Resultados das dosagens "ideais" dos concretos convencionais (CC), para agregados graúdos de basalto com diâmetro (B1) 98

Tabela 20 – Resultados das dosagens “ideais” dos concretos convencionais (CC), para agregados graúdos de basalto com diâmetros (B1/B0) 98
Tabela 21 – Resultados das dosagens “ideais” dos concretos convencionais (CC), para agregados graúdos de granito com diâmetro (B0) 99
Tabela 22 – Resultados das dosagens “ideais” dos concretos convencionais (CC), para agregados graúdos de granito com diâmetro (B1) 99
Tabela 23 – Resultados das dosagens “ideais” dos concretos convencionais (CC), para agregados graúdos de granito com diâmetros (B1/B0) 100
Tabela 24 – Resultados das dosagens “ideais” dos concretos convencionais (CC), para agregados graúdos de seixo rolado com diâmetro (B1) 100
Tabela 25 – Resultados das dosagens “ideais” dos concretos de alta resistência (CAR), para agregados graúdos de basalto com diâmetro (B0) 101
Tabela 26 – Resultados das dosagens “ideais” dos concretos de alta resistência (CAR), para agregados graúdos de basalto com diâmetro (B1) 101
Tabela 27 – Resultados das dosagens “ideais” dos concretos de alta resistência (CAR), para agregados graúdos de granito com diâmetro (B0) 102
Tabela 28 – Resultados das dosagens “ideais” dos concretos de alta resistência (CAR), para agregados graúdos de granito com diâmetro (B1) 102
Tabela 29 – Resultados das dosagens “ideais” dos concretos de alta resistência (CAR), para agregados graúdos de granito com diâmetros (B1/B0) 102
Tabela 30 – Resultados das dosagens “ideais” dos concretos de alta resistência (CAR), para agregados graúdos de seixo rolado com diâmetros (B1) 103
Tabela 31 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de basalto com diâmetro (B1) 104
Tabela 31 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de basalto com diâmetro (B1) 104
Tabela 32 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de basalto e diâmetros (B1/B0) 106
Tabela 32 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de basalto com diâmetro (B1/B0) 106
Tabela 33 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de granito com diâmetro (B0) 108
Tabela 33 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de granito com diâmetro (B0) 108

Tabela 34 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de granito com diâmetro (B1) 110
Tabela 34 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de granito com diâmetro (B1) 110
Tabela 35 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de granito com diâmetros (B1/B0) 112
Tabela 35 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de granito com diâmetro (B1/B0) 112
Tabela 36 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de seixo rolado com diâmetro (B1) 114
Tabela 36 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de seixo rolado com diâmetro (B1) 114
Tabela 37 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de basalto com diâmetro (B0) 116
Tabela 37 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de basalto com diâmetro (B0) 116
Tabela 38 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de basalto com diâmetro (B1) 118
Tabela 38 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de basalto com diâmetro (B1) 118
Tabela 39 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de granito com diâmetro (B0) 120
Tabela 39 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de granito com diâmetro (B0) 120
Tabela 40 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de granito com diâmetro (B1) 122
Tabela 40 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de granito com diâmetro (B1) 122
Tabela 41 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de granito com diâmetros (B1/B0) 124
Tabela 41 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de granito com diâmetro (B1/B0) 124
Tabela 42 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de seixo rolado com diâmetro (B1) 126

Tabela 42 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de seixo rolado com diâmetro (B1) 126

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ADALINE	Adaptive linear element
AI	Inteligência Artificial
ANN	Artificial Neural Networks
ART	Adaptive Resonance Theory
B0	Brita Zero
B1	Brita Um
CAA	Concreto Auto Adensável
CAD	Concreto de Alto Desempenho
CAF	Concreto com Adição de Fibras
CAR	Concreto de Alta Resistência
CC	Concreto Convencional
CORBA	Common Request Broker Architeture
CP	Corpo de Prova
CTE	Coeficiente de Expansão Térmica
IDE	Integrado de Desenvolvimento
ISO	Organização Internacional para Padronização
GUI	Interface Gráfica com Usuário
JDK	Java Developement Kit
JVM	Máquina virtual Java
MDOO	Modelo de Dados Orientados a Objetos
MER	Modelo Entidade Relacionamento
MF	Módulo de Finura
MPa	Megapascal
MySQL	My Structured Query Language
NBR	Normas Brasileiras de Regulamentação
NM	Normas Mercosur
OO	Orientação a Objetos
OOP	Programação Orientada a Objetos
RMI	Remote Method Invocation

RNA	Rede Neural Artificial
SGBD	Sistema de Gerenciamento de Banco de Dados
SO	Sistema Operacional
UML	Linguagem de Modelagem Unificada
WWW	World Wide Web

LISTA DE SÍMBOLOS

z_i	São valores da distribuição normal
x_i	São valores de entrada
$\bar{x}$	É a média dos valores de entrada
σ	Desvio padrão
a_i	Somatória dos pesos sinápticos com os vetores de sinais da entrada
x_n	Vetor de sinais da entrada n-dimensional
w_{kn}	Pesos sinápticos
$f(s)$	Função de ativação
λ	Função de inclinação
ΔW	Variação do vetor de pesos W
k	Índice que indica o número de camadas
α	Taxa de treinamento
∇_ε	Vetor gradiente de erro quadrático
ε^{2k}	Erro quadrático da rede neural
ε_i	É o i-ésimo erro da última camada da rede
d_i	Saída desejada do i-ésimo elemento da última camada de rede
y_i	Saída i-ésimo elemento da última camada de rede
ns	Número de neurônios da última camada de rede
ΔU_i	Comprimento do vetor
$\nabla_i(k)$	Gradiente do erro quadrático com relação aos pesos do neurônio i avaliado em h
U_i	É o vetor contendo os pesos do neurônio i
u_i	Pesos correspondente à interligação entre o i-ésimo e j-ésimo neurônio
η	Constante de momento
θ	Derivada da função sigmóide
$R(j)$	Conjunto de índices dos elementos que se encontram na fileira seguinte à fileira do elemento j, e que estão interligados ao elemento j.
D_{max}	Diâmetro máximo característico
γ_a	Massa específica do agregado miúdo expressa em g/cm³
L	Leitura do frasco de *Chapman*
A	Porcentagem de absorção de água

$M1$	Amostra 1
$M2$	Amostra 2
M_h	Peso em gramas da massa do agregado na condição saturada seca
M_s	Peso em gramas da massa do agregado seco em estufa após resfriamento em temperatura ambiente
γ_b	Massa específica do agregado graúdo expressa em g/cm³
$L(g)$	Leitura da balança dos agregado imersos em água
α	Teor de argamassa ideal
C	Consumo de cimento por metro cúbico de concreto adensado em kg/m³
Ar	Teor de ar incorporado e/ou aprisionado por metro cúbico, em dm³/dm³
a	Relação do agregado miúdo seco/cimento em massa, em kg/kg;
b	Relação do agregado graúdo seco/cimento em massa, em kg/kg;
γ_c	Massa específica do cimento em kg/m³;
a/c	Relação água/cimento em massa, em kg/kg.
Ca	Consumo em massa de agregado miúdo (kg/m³)
Cb	Consumo em massa de agregado graúdo (kg/m³)
$C_{água}$	Consumo em massa de água (kg/m³)

SUMÁRIO

1 INTRODUÇÃO..... 25
1.1 OBJETIVOS..... 26
1.2 JUSTIFICATIVA DA PESQUISA..... 27
1.3 CONTEÚDO E ESTRUTURA DA DISSERTAÇÃO..... 28
2 REVISÃO BIBLIOGRÁFICA..... 29
2.1 A PRODUÇÃO DE CONCRETO..... 29
2.2 CARACTERÍSTICAS DOS MATERIAIS PARA PRODUÇÃO DE CONCRETO.... 30
2.3 CIMENTOS..... 31
2.4 DOSAGEM DE CONCRETOS E OS RESULTADOS DE RESISTÊNCIA PELA IDADE..... 32
2.5 REDES NEURAIS ARTIFICIAIS..... 35
2.5.1 Funções de não linearidade para redes neurais..... 38
2.5.2 Modelo do algoritmo de retropropagação (*MADALINE*) 43
2.5.3 Treinamento do algoritmo de aprendizagem para retropropagação..... 45
2.5.4 Aplicações de redes neurais para cálculos de concretos..... 48
2.6 Softwares aplicados com inteligência artificial para dosar concretos..... 53
3 DESENVOLVIMENTO DE SOFTWARES..... 55
3.1 ENGENHARIA DE SOFTWARE..... 55
3.2 LINGUAGEM DE PROGRAMAÇÃO *JAVA*..... 56
4 **MATERIAIS E MÉTODOS**..... 59
4.1 INTRODUÇÃO..... 59
4.2 CIMENTOS..... 59
4.3 AGREGADOS GRAÚDOS..... 59
4.4 AGREGADO MIÚDO..... 62
4.5 MÉTODO DE ENSAIO PARA DISTRIBUIÇÃO GRANULOMÉTRICA..... 62
4.6 MÉTODO DE ENSAIO DE GRANULOMETRIA DOS AGREGADOS MIÚDOS... 64
4.6.1 Determinação da curva granulométrica dos agregados miúdos..... 66
4.7 MÉTODO PARA DETERMINAÇÃO DE MASSA ESPECÍFICA E ABSORÇÃO DE ÁGUA DOS AGREGADOS MIÚDOS..... 67

4.8 MÉTODO DE ENSAIO DE GRANULOMETRIA DOS AGREGADOS GRAÚDOS..... 70
4.9 MÉTODO PARA DETERMINAÇÃO DE MASSA ESPECÍFICA DOS AGREGADOS GRAÚDOS..... 76
4.10 MÉTODO PARA DETERMINAÇÃO DA ABSORÇÃO DOS AGREGADOS GRAÚDOS..... 77
4.11 MÉTODO PARA DETERMINAÇÃO DAS RELAÇÕES DOS AGREGADOS GRAÚDOS (B1/B0) 78
4.12 MÉTODO DE ENSAIO PARA DOSAGEM DE CONCRETO..... 79
4.13 MÉTODO DA CONSISTÊNCIA PELO ABATIMENTO DO TRONCO DE CONE..... 83
4.14 MÉTODO DE ENSAIO PARA MOLDAGEM, CURA E CAPEAMENTO..... 84
4.15 PESQUISA EXPERIMENTAL..... 85
4.16 METODOLOGIA DE TREINAMENTO PARA REDES NEURAIS ARTIFICIAIS..... 86
4.17 ELABORAÇÃO DA REDE NEURAL E REALIZAÇÃO DE TESTES..... 88
4.18 MÉTODO PARA DESENVOLVIMENTO COMPUTACIONAL..... 88
4.19 ELABORAÇÃO DO SOFTWARE DECCONCRETO COM A REDE NEURAL…. 90
4.20 ELABORAÇÃO DE INTERFACES..... 92
4.21 MÉTODO DE DESENVOLVIMENTO DE BANCO DE DADOS 96
5 RESULTADOS E DISCUSSÕES..... 98
5.1 DOSAGENS DOS CONCRETOS..... 98
5.1.1 Dosagens de concreto convencional com agregados graúdos de basalto..... 98
5.1.2 Dosagens de concreto convencional com agregados graúdos de granito..... 99
5.1.3 Traço de concreto convencional com agregados graúdos de seixo rolado..... 100
5.1.4 Dosagens de CAR com agregados graúdos de basalto..... 101
5.1.5 Dosagens de CAR com agregados graúdos de granito..... 102
5.1.6 Dosagens de CAR com agregados graúdos de seixo rolado..... 103
5.2 RESULTADOS DOS ENSAIOS MECÂNICOS..... 104
5.2.1 Resultados de resistência à compressão do concreto convencional com agregado graúdo de basalto B1..... 104
5.2.2 Resultados de resistência à compressão do concretos convencionais com agregado graúdos de basalto B1/B0..... 105

5.2.3 Resultados de resistência à compressão dos concretos convencionais com agregados graúdos de granito B0..... 107
5.2.4 Resultados de resistência à compressão do concreto convencional com agregado graúdos de granito B1..... 109
5.2.5 Resultados de resistência à compressão do concreto convencional com agregado graúdos de granito (B1/B0) 111
5.2.6 Resultados de resistência à compressão do concreto convencional com agregado graúdos de seixo-rolado B1..... 113
5.2.7 Resultados de resistência à compressão do concreto de alta resistência com agregados graúdos de basalto B0..... 115
5.2.8 Resultados de resistência à compressão do concreto de alta resistência com britas de basalto B1..... 117
5.2.9 Resultados de resistência à compressão do concreto de alta resistência com agregados graúdos de granito B0..... 119
5.2.10 Resultados de resistência à compressão do concreto de alta resistência com agregado graúdos de granito B1..... 121
5.2.11 Resultados de resistência à compressão dos concretos de alta resistência com agregados graúdos de granito (B1/B0) 123
5.2.12 Resultados de resistência à compressão do concreto de alta resistência com agregados graúdos de seixo rolado B1..... 125
5.3 REALIZAÇÃO DE TESTES DOS ERROS COM A REDE NEURAL..... 127
5.4 CONSIDERAÇÕES FINAIS..... 130
6 CONCLUSÃO..... 133
REFERÊNCIAS 135
ANEXOS 139

1. INTRODUÇÃO

Esta pesquisa apresenta dosagens de concretos com diversos tipos de agregados graúdos, cimentos e aditivos e, também o desenvolvimento de *software*, para dosagem do concreto com algoritmo genético de redes neurais.

Estas são aplicadas diretamente no treinamento artificial da coleta de dados dos materiais, e as respectivas resistências axiais.

Na dosagem do concreto, os materiais utilizados na mistura, devem proporcionar qualidade e resultados significativos de resistência à compressão. A dosagem do concreto necessita de ensaios laboratoriais como: caracterização, densidade, absorção, confecção, abatimento e resistência à compressão. Entretanto, os ensaios em laboratório consomem tempo e material. Uma solução é o desenvolvimento de *software* para dosagem de concreto, realizando ensaios em laboratório somente para ajustes. Este *software* pode ser elaborado por redes neurais artificiais, onde se deseja dosar o concreto por meio de neurônios artificiais. Também, oferecendo uma interface gráfica de acesso agradável e eficaz ao usuário.

Neste trabalho foram elaboradas as seguintes dosagens de concretos: convencionais (CC) e de alta resistência (CAR). Foram elaboradas dosagens 1:5,0 (médio), onde foi obtido, experimentalmente, o teor de argamassa ideal (α). Este foi mantido constante para as seguintes dosagens 1:3,5 (rico) e 1:6,5 (pobre). A fim de obter diferentes tipos de concretos, usaram-se diversos tipos de cimentos Portland como: CP II 32 – Z, CP III 40 – RS e CP V – ARI. Também, utilizaram-se nas misturas diferentes tipos de agregados graúdos como: basalto, granito e seixo rolado, sendo que as dimensões foram de B0, B1 e B1/B0 (mistura dos dois tamanhos).

Durante o trabalho foram obtidas diversas resistências à compressão, para montagem de um banco de dados de resistências e também de materiais. Estes dados armazenados foram utilizados pela rede neural artificial, para “treinar” o concreto, a fim de torná-lo automatizado e apresentar resultados precisos menos perdas de materiais.

Os materiais que dão origem ao concreto, contém aglomerantes contínuos, misturados com partículas de agregados e água. O aglomerante, conhecido como cimento Portland, quando misturado com água, tem a função de aglutinar os agregados miúdos e graúdos.

Existem vários tipos de cimento e diferentes agregados e aditivos, os agregados podem também possuir diferentes dimensões. O material que compõe o concreto pode imprimir maior ou menor resistência ao mesmo.

O concreto é conhecido pela mistura de argamassa com agregado graúdo, pois alguns concretos no estado fresco, exigem modificações em suas propriedades reológicas com adição de aditivos, o que melhora a trabalhabilidade.

É preciso que a dosagem esteja de acordo com a seleção dos materiais caracterizados, pela massa específica e massa unitária. Também é necessário que o concreto apresente fluidez (sem segregação e exsudação). Esta maneira adequada de mistura pode resultar em uma melhor resistência à compressão (VILLA, 2012).

Para elaboração de um *software,* capaz de armazenar e treinar, por redes neurais, os dados coletados durante a pesquisa, foi escolhida a linguagem de programação *Java Netbeans*. O método de programação adotado foi o modelo de dados orientados a objetos (MDOO). Neste modelo, pode-se elaborar uma base de dados utilizando o *My Structured Query Language (MySQL)* que relacione as tabelas do banco de dados, juntamente com o método aplicado de programação. Assim, esta aplicação vai promover um *software* voltado para o desenvolvimento cientifico.

1.1. OBJETIVOS

Gerais:

- Pesquisar bases bibliográficas: sobre diversos tipos de concretos, com um melhor aprofundamento do assunto;
- Encontrar o teor de argamassa ideal para diferentes tipos de concretos convencionais (CC) e de alta resistência (CAR);

Específicos:

- Relacionar dados experimentais dos ensaios de caracterização: massa específica e granulometria dos materiais utilizados nos concretos convencionais (CC) e de alta resistência (CAR) para o cálculo das dosagens

experimentais, a fim de avaliar diversas dosagens com variados agregados graúdos e cimentos;

- Analisar as resistências que os diferentes materiais imprimem no concreto, proporcionando a diferença nas dosagens dos mesmos e aproveitando os dados experimentais para armazenar diretamente na base de dados a fim de facilitar a aprendizagem da rede neural.
- Desenvolver algoritmo genético *feedforward* no modelo *backpropagation* para verificar os dados experimentais coletados, a fim de treinar entre as camadas de aplicação da rede neural os dados experimentais coletados nos ensaios de resistência (tensão - MPa);
- Adotar a linguagem de programação de computadores, a fim de programar *software*, com a utilização de redes neurais para dosagem de concreto, com objetivo de qualidade, desempenho e economia dos materiais.

1.2. JUSTIFICATIVA DA PESQUISA

Esta pesquisa busca otimizar a obtenção de dosagens de concreto por meio da Inteligência Artificial (IA), que é a base de *softwares* e equipamentos automatizados para construção civil conforme afirma Neshat et al (2012, p. 373). Segundo o autor, o desenvolvimento de aplicativos, que possam armazenar e produzir dados precisos, são constantemente mais ativos e presentes na sociedade. Estas tecnologias estão sendo aplicadas na construção civil para melhorar o desempenho de materiais e equipamentos.

A dificuldade em dosar o concreto está no preparo, no tempo de cura para ruptura e na perda de materiais em laboratório. Este sistema de informação permitirá armazenar dados e desenvolver cálculos de dosagens com inteligência artificial (AI), apresentando novos resultados de dosagens para concretos com menor perda de material e tempo em laboratório.

A possibilidade de realizar rapidamente a dosagem de concreto, com um controle do consumo de cimento, pode reduzir o custo de produção. Os resultados foram obtidos por meio das caracterizações dos materiais e ensaios dos corpos de prova. Este *software* pode produzir dosagens de concretos convencionais (CC) e de alta resistência (CAR) promovendo ainda maior rapidez na produção.

Para o desenvolvimento do software faz-se necessário a utilização de dados experimentais. Por esta razão a pesquisa vai depender de um desenvolvimento de *software* que

possa contar com a coleta destes dados e armazená-los em banco de dados. A otimização deste processo verificará os resultados armazenados, como quantidade de cada material e resistência.

Por meio de algoritmos genéticos, entre camadas de uma rede neural, pode-se treinar e obter dados através do momento e da taxa de treinamento, desde a entrada até a saída para: agregados graúdos, agregados miúdos, água, cimento e resistência a compressão.

A vantagem de aplicar uma formulação de algoritmos genéticos como *feedforward* é alcançar melhores resultados com menor tempo.

1.3. CONTEÚDO E ESTRUTURA DA DISSERTAÇÃO

Nos próximos capítulos deste trabalho tem-se o estado da arte, bem como os materiais, métodos, resultados e conclusões. Suas contribuições são pesquisadas de maneira clara e objetiva, e com respeito mútuo ao acesso dos acervos bibliográficos de outros pesquisadores. A proposta está dividida em 7 capítulos, sendo que o capítulo 1 é a introdução.

No capítulo 2 é abordada a revisão bibliográfica com relação à produção de concreto. Neste capítulo são abordados temas referentes aos diferentes tipos e métodos de concretos, cimentos, estrutura de partículas, rede neural entre outros.

No capítulo 3 são abordados os tipos de agregados e cimentos uma vez que podem influenciar na qualidade dos materiais para dosagem de concretos. O cimento Portland é muito utilizado na produção de concreto, assim como os agregados. Neste capítulo é apresentada a caracterização do agregado miúdo como origem; tipo; e módulo de finura. Também são abordados tipos de aditivos como microssílica e superplastificante.

Ainda no capítulo 3, em relação ao desenvolvimento da pesquisa, é apresentada a programação da ferramenta computacional, utilizando algoritmos genéticos de redes neurais artificiais.

O capítulo 4 é composto pelos resultados e discussões de dosagem, abatimento, ensaio mecânico e do desenvolvimento da rede neural e do *software* com interface gráfica.

O capítulo 5 consiste nas conclusões dos resultados obtidos nos ensaios e no *software* desenvolvido no presente trabalho e denominado DECCONCRETO.

Nos capítulos 6 e 7 temos as referências bibliográficas e bibliografias complementares, onde a importância de cada obra literária utilizada foi fundamental na pesquisa realizada da construção desta dissertação de mestrado.

2. REVISÃO BIBLIOGRÁFICA

2.1. A PRODUÇÃO DE CONCRETO

A formação do concreto é composta de agregados, cimento Portland e água. Os agregados são os materiais inertes (HASAN, 2012).

A produção de concreto é complexa, pois envolve os efeitos dentre parâmetros do processamento, controle de qualidade, trabalhabilidade, resistência entre outros. A dosagem baseia-se nos princípios da reologia do concreto fresco, e em questões como a força desejada, pelo tempo de endurecimento, durabilidade, que são controlados pela relação a/c (GUPTA, 2013).

O concreto pode envolver uma série de complexidades com relação ao processamento, controle de qualidade, trabalhabilidade, resistência entre outros. A dosagem baseia-se nos princípios da reologia do concreto fresco, e em questões como a resistência desejada para um determinado tempo de cura, durabilidade, que são controlados pela relação (a/c) (GUPTA, 2013).

Essa mistura é conhecida como dosagem, entretanto, alguns fatores como resistência, módulo de elasticidade e durabilidade exigem a dosagem adequada entre os materiais que formam o concreto. Para se obter a dosagem são necessários ensaios de caracterização dos materiais.

A dosagem do concreto é em função da resistência à compressão e do ambiente onde este será colocado. Portanto, algumas dosagens são definidas de acordo com o tipo de obra, conforme afirma Reis (2008).

Existem tipos de concretos produzidos com materiais selecionados para alta resistência e desempenho A vantagem em variar os tipos de concreto, em relação ao concreto comum, são as obtenções de maiores resistências axiais, ao fogo e às condições climáticas. (HELENE; TERZIAN, 1993).

De acordo com Yurdakul et. al. (2013), o concreto é controlado através da seleção de materiais, dosagem das misturas, e da mão de obra.

As partículas finas e grossas, o cimento e a água têm muita influência sobre o estudo dos concretos, pois a dosagem deste depende das quantidades exatas dos materiais (FLATT, 2004).

Segundo Cazacliu et. al. (2008), a produção industrial do concreto depende da mistura dos materiais e do preparo por equipamentos mecanizados, como: betoneira ou caminhões betoneira. Os autores citam problemas encontrados na medição das quantidades, para evitar perdas dos materiais no preparo, visto que deve ser acrescida uma quantidade que ficará grudada na parede da betoneira. Este processo de fabricação depende de medidas exatas para controlar os materiais.

Conforme Colombo et. al. (2013), a durabilidade do concreto é um dos fatores fundamentais, pois depende da mistura dos materiais, da consistência e abatimento e do tempo de cura. Nessa mistura a pasta deve ter boa hidratação, para obter um aumento da durabilidade.

2.2. CARACTERÍSTICAS DOS MATERIAIS PARA PRODUÇÃO DE CONCRETO

O concreto é formado pelos materiais como: água, cimento, areia e britas, sendo que estes devem ser coletados para realização dos ensaios de granulometria e caracterização, a fim de obter as curvas granulométricas, densidade e absorção dos agregado graúdos e miúdos para confecção do concreto.

Uma das caracterizações dos agregados graúdos e miúdos é a distribuição granulométrica. Esta terá influência na confecção do concreto e resistência à compressão. Os agregados estão diretamente relacionados à sua superfície, ou seja, com relação à porosidade e área superficial. Os agregados graúdos têm maior porosidade e são consideradas partículas grossas. Os agregados miúdos têm menor porosidade e maior área superficial e são conhecidas como partículas finas. Estas tendem a alojar-se nos poros de partículas grossas. A distribuição granulométrica também influencia na quantidade de água, pois o grão com maior superfície apresenta grande absorção de água. Assim, as partículas mais finas consomem mais água, pois a área superficial é maior em relação às partículas mais grossas (DRAGAN et al, 2012).

Para verificar a distribuição granulométrica, o material deve ser peneirado, em peneiras de diferentes diâmetros e a massa contida em cada peneira deve ser registrada. Estes materiais seguem padrões rigorosos, para verificação do tipo da brita, diâmetro e da quantidade de água absorvida (Matias et al., 2013).

Kim et al (2014), estudaram pavimentações para aeroportos, onde os mesmos utilizaram areia fina com a intenção de diminuir as fissuras no concreto, com relação ao efeito térmico de expansão e retração. Os autores estudaram oito tipos de misturas (dosagens), que

foram ajustados de acordo com a quantidade de água. Foram obtidos resultados satisfatórios com a utilização de granito, como agregado graúdo e, areia fina como agregado miúdo.

É importante que os concretos contenham agregados graúdos porosos para alojar partículas finas, assim melhorando o empacotamento das mesmas no preenchimento dos espaços vazios. A chave está na microestrutura do material, sendo que os agregados miúdos abrigam maior absorção de água em relação aos agregados graúdos. Este, ao entrar em contato com as partículas de cimento da argamassa, resulta em estrutura mais densa e beneficia a difusão dos grãos finos do cimento com as camadas mais externas dos agregados graúdos. (YOUNIS; PILAKOUTAS, 2013).

2.3. CIMENTOS

O cimento Portland é um dos aglomerantes hidráulicos utilizados na dosagem de concreto, sendo que o cimento pode ser comum, composto, de alto-forno, de alta resistência e pozolânico.

Cada cimento Portland é classificado conforme a composição química (Tabela 1):

Tabela 1 – Classificação **e c**omposição dos cimentos **(**ABNT NBR NM: 5732 (1991), 5733(1991), 5735 (1991), 5736 (1991), 5737 (1992) e 11578 (1997)).

Sigla	Classe de Resistência	Componentes (% em massa)			
		Clínquer + sulfatos de cálcio	Escória granulada de alto-forno	Material pozolânico	Material carbonático
CP I	25;32;40	100	0		
CP I-S	25;32;40	99-95	1-5		
CP II-E	25;32;40	94-56	6-34	-	0-10
CP II-Z	25;32;40	94-76	-	6-14	0-10
CP II-F	25;32;40	94-90	-	-	6-10
CP III	25;32;40	65-25	35-70	-	0-5
CP IV	25;32	65-25	35-70	-	0-5
CP V- ARI	-	95-100	-	-	0-5

A composição do cimento deverá estar de acordo com a Tabela 1, sendo que as embalagens devem estar em sacos de 50 kg, e com as impressões visíveis das siglas, classes correspondentes, altura, e ao centro a normalização do nome e da marca do fornecedor.

Também, devem atender as exigências físicas e químicas, de acordo com às normas técnicas ABNT NBR NM 11578 (1997).

De acordo com a Tabela 1, estes cimentos são utilizados para verificar a resistência à compressão, em que se deseja variar nos períodos de 3, 7, 28, 63 e 91 dias, obtendo a resistência à compressão (MPa), trabalhabilidade, exsudação, impermeabilidade e coesão (HELENE; TERZIAN, 1993).

2.4. DOSAGEM DE CONCRETOS E OS RESULTADOS DE RESISTÊNCIA PELA IDADE

A resistência do concreto pode ser obtida pela confecção do mesmo e do tempo de cura, sendo que existem diversos tipos de concretos como: concreto convencional (CC), concreto de alto desempenho (CAD), concreto com adição de fibras (CAF), concreto de alta resistência (CAR), concreto auto adensável (CAA) entre outros. Algumas das vantagens destas dosagens estão no concreto de alta resistência (CAR), que produz efeitos de baixa porosidade e permeabilidade e, de alta resistência contra cloretos e sulfatos, o que permite combater problemas relacionados aos ataques em armaduras (REIS, 2008).

Flatt (2004), realizou uma abordagem matemática para calcular a hidratação do concreto, cujo objetivo era reproduzir resultados de concreto de maior coesão no abatimento. Também, objetivou uma melhor dispersão das partículas finas na mistura, com o procedimento de introdução do aglomerante hidráulico. A fim de uma melhor hidratação do cimento, o autor realizou ensaios com aplicação de superplastificante. Esta hidratação depende da quantidade superplastificante e do cimento, para reproduzir resultados que possam trazer queda da coesão do concreto no abatimento, pois se espera melhorar a dispersão das partículas finas na mistura com um procedimento correto de introdução do aglomerante, conforme sugerido pelo autor. Este método foi aplicado e recomentado como prevenção para uma melhor dispersão de partículas finas, onde se obteve uma coesão significativa baseada em normas técnicas de procedimento e elaboração no preparo e abatimento.

NESHAT, 2012, obteve uma formulação matemática para obter dosagens de concreto. O autor observou que na preparação da mistura todos os materiais devem ser pesados secos, ou seja, devem apresentar umidade zero na pesagem. Desse modo são possíveis bons resultados de resistência com o uso de sua formulação matemática. Assim, o essencial é

formular o procedimento da mistura em massa e as devidas absorções de água. A água deve seguir de acordo com o peso do cimento e a relação água cimento.

Para obter a relação água/cimento (a/c), deve-se conhecer a resistência e o tempo de ruptura dos corpos de prova. Ao calcular o consumo de cimento, se obtém por cálculo da quantidade de britas, areia e água. (HELENE; TERZIAN, 1993).

Dragan et. al. (2012), realizaram um estudo para otimização da dosagem de concreto. Neste estudo os materiais considerados foram: tipo de aglomerante, agregados graúdos e miúdos, água e aditivos. Foram elaboradas fórmulas matemáticas, para obter uma dosagem que contribui no aumento de resistência do concreto com economia de material. Foram confeccionadas várias dosagens com o total de 288 corpos de prova, e o tempo de ruptura de 28 dias. Neste trabalho foi observado que a resistência axial depende da argamassa de cimento e agregados. Entretanto, os agregados atingiram uma reação mais elevada de resistência do que a argamassa. Nesta experiência, foi comprovado que o consumo de água está relacionado ao tamanho do grão.

Conforme afirma Gupta (2013), na engenharia civil o projeto de mistura de concreto é difícil e sensível. A maneira clássica para a determinação do projeto da mistura de concreto é baseada na incerteza e depende das ideias de especialistas. No projeto de mistura de concreto e controle de qualidade, a resistência à compressão axial do concreto é considerada a propriedade mais valiosa, que por sua vez depende de certo número de fatores.

Diamond e Sahu (2006), ao estudar a dosagem do concreto convencional com microssílica, perceberam que os materiais quando misturados na betoneira, apresentaram aglutinação. O processo de aglutinação das partículas finas, em contato com o aglomerante hidráulico (cimento Portland), pode ser resolvido com aplicação e tratamento ultrassônico moderado. Entretanto, nem sempre isso é garantido. O autor notou que tais efeitos foram observados em partículas maiores que as partículas do cimento Portland. Os grãos maiores, não dispersos, aparentemente sofrem reações químicas durante a confecção do concreto, mas tais reações podem induzir danos somente sob circunstâncias particularmente desfavoráveis.

Para resolver estes efeitos da mistura, foi aplicado ensaios para verificar o comportamento da microssílica quando misturados ao aglomerante hidráulico.

Chegou-se à conclusão que os efeitos causados da aglutinação, são atribuídos a maneira em que microssílica é fabricada.

As partículas de cimento e sílica ativa, quando dispersas apresentam ótima reologia em dosagens para concretos de alta resistência (CAR), pois no contato com os superplastificantes, se encontraram resultados significativos na confecção do concreto.

Jo et al., (2007), ao realizar ensaios de ruptura, aos 7 e 28 dias, em concreto com nano partícula, constataram que houve um aumento expressivo de resistência à compressão. Este aumento foi observado ao ensaiar dois tipos de mistura um com sílica ativa e as nano partículas (nano-SiO_2) e outro sem, sendo que ambas continham os mesmos valores proporcionais de cimento e água.

Younis e Pilakoutas (2013), analisaram o efeito do desempenho de agregados reciclados no concreto. A fim de se obter a condição de absorção dos agregados e cimento, os autores recomendaram a adição de água em pequenas doses e afirmaram que o período de tempo tem influência na reologia do concreto fresco. Os autores propuseram um modelo preventivo de resistência utilizando técnicas multilineares e de regressão não linear. Foram confeccionados corpos de prova cuja dosagem foi obtida por esta técnica. Foi observado o aumento na resistência do concreto com materiais reciclados. Também, foi utilizada fibra reciclada de pneus na mistura deste concreto, o que apresentou resultados significativos em 30% de aumento na resistência. Também observaram que ao colocar o concreto nos corpos de prova, a vibração deve ser precisa para que não haja segregação, sendo que a cura e endurecimento do concreto devem ficar por um período de 24hs, a fim de desenformar os corpos de prova.

Matias et al. (2013), para dosar o concreto convencional (CC) e o concreto de alta resistência (CAR), realizou cálculo do traço unitário com as massas (kg) do cimento, agregados graúdos, agregados miúdos, água, microssílica ativa e superplastificante. Utilizando estas medidas foram realizadas as confecções do concreto convencional (CC) e do concreto de alta resistência (CAR). Observando os dois tipos de concretos, constatou-se uma ótima reologia com uso de aditivos, pois a resistência à compressão apresentou maiores índices de resistência no concreto de alta resistência (CAR) comparados ao concreto convencional (CC).

Abdeen e Hodhod (2010), realizaram ensaios, com objetivo de treinar uma rede neural, a fim de obter a dosagem para uma determinada resistência. Os autores utilizaram dois tipos de cimentos para confecção dos concretos e o agregado miúdo foi retirado do deserto egípcio, este teve módulo de finura de 3,3. O agregado graúdo também foi retirado do deserto, este teve o diâmetro máximo de 25 (mm). À água foi retirada diretamente da torneira para compor a mistura da pasta na confecção do concreto. Destes ensaios, foram introduzidas as quantidades em massa (kg) e resistência à compressão em uma rede neural (ANN), para treinar e obter as resistências axiais (MPa). Os autores propuseram a mistura do concreto por redes neurais (ANN), e concluíram que esta pode reduzir os ensaios em laboratório, proporcionando economia de tempo e maior precisão dos resultados.

Kim et al (2014), ao estudarem a expansão do concreto verificaram que alguns efeitos devem ser considerados, como aumento e queda de temperatura, pois observando sua base tridimensional de elementos finitos, propuseram um coeficiente de expansão térmica (CTE), que estão relacionados ao tipo de concreto que é produzido para determinada obra. Foram realizadas medições com a utilização do coeficiente de expansão térmica. Estes dados, obtidos de uma obra de pavimentação de aeroportos, ajudaram a diminuir fissuração no concreto pavimentado, que é um dos problemas apontados nas falhas de pavimentação de pistas de pouso e decolagem. Os autores concluíram que a utilização do (CTE) pode melhorar o desempenho da pavimentação de concreto dos aeroportos.

2.5. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais são baseadas no modelo do sistema nervoso humano, conforme se observa na Figura 1.

Figura 1 – Neurônio do sistema nervoso humano (Minussi e Lotufo, 2007)

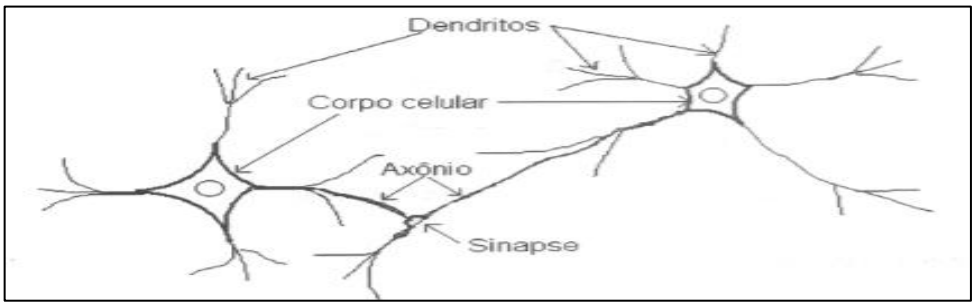

Fonte: Minussi e Lotufo, 2007.

Na Figura 1, é apresentado um sistema que tem elementos de processamento das informações conhecidos como neurônios, sendo que se podem comparar à rede neural humana com a rede neural artificial, onde está aplicação de treinamento por um algoritmo genético apresenta resultados através da aprendizagem dos neurônios, pois executa tarefas como um sistema especialista que aprende e devolve o resultado em termo real (HASAN; KABIR, 2013).

A importância de compreender o estudo das redes neurais se faz necessário para desenvolver modelos genéticos com capacidade e processamento em tempo real (MINUSSI; LOTUFO, 2007).

Conforme se observa na Figura 1, a rede neural do cérebro humano é formada pelo seguinte modelo biológico: corpo celular, sinapse, dendrito e axônio, sendo que para cada um destes pode ser aplicado o modelo das redes neurais artificiais de *McCulloch-Pitts*, que foi desenvolvido em 1943 (HAYKIN, 2001).

Um dos modelos de neurônios mais conhecidos é chamado de *McCulloch-Pitts*, sendo que este modelo é idêntico ao neurônio humano e possui várias funções, a fim de ajudar a compreender o estudo do cérebro humano (MINUSSI; LOTUFO, 2007).

Conforme o modelo de neurônio de *McCulloch-Pitts*, as estruturas de redes neurais artificiais formam conexões de elementos (neurônios) que são classificadas em camadas. Nestas camadas devem processar os dados das entradas e dos pesos que, passam pelas camadas de entrada, intermediária e de saída. As camadas estão ilustradas Figura 2, na qual é possível observar o neurônio artificial.

Figura 2 – Neurônio artificial de *McCalluch-Pits* (McCalluch-Pits *apud* Minussi e Lotufo, 2007)

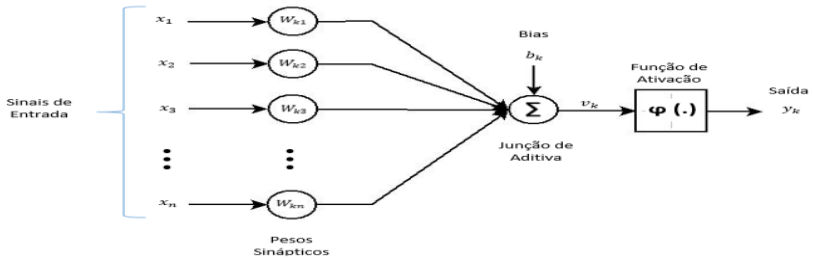

Fonte: Minussi e Lotufo, 2007.

No neurônio artificial ilustrado na Figura 2, x são valores de entrada, que podem ser, por exemplo, dados de resistência obtidos na prática. W são os pesos sinápticos, os quais são valores normalizados da distribuição normal, ou seja, distribuição do qui-quadrado. Sendo que, a normalização da distribuição normal, em números entre -1 a +1 ou 0 a +1, é feita usando matrizes aleatórias. A distribuição normal é dada conforme a equação Eq. 2.1.

$$z_i = \frac{x_i - \bar{x}}{\sigma} \qquad \text{Eq. [2.1]}$$

Onde:

z_i – São valores da distribuição normal;

x_i – São valores de entrada;

$\bar{x}$ – É a média dos valores de entrada;

σ – Desvio padrão.

Portanto, o peso é inversamente proporcional ao desvio padrão.

Na Figura 2, também é possível observar no neurônio artificial a junção aditiva, que é a somatória dos pesos multiplicados pelas suas respectivas entradas. Esta soma deve ser feita conforme a equação Eq. 2.2.

$$a_i = \sum_{j=1}^{n} w_{ij} x_i \qquad \text{Eq. [2.2]}$$

Onde,

- a_i – Somatória dos pesos sinápticos com os vetores de sinais da entrada;
- x_n – Vetor de Sinais da Entrada n-dimensional;
- w_{kn} – Pesos Sinápticos.

Este modelo é considerado como uma regressão linear capaz de produzir sinais de atividade, que são os neurônios em si, capazes de fazer cálculos não lineares. Na Figura 2, a função de ativação está representada por φ (.) e os dados de saída por y. Os pesos das camadas têm pesos bias ($x_0 = 1$) que são constantes iniciadas com o valor de um, para controlar as saídas dos neurônios. (MCCALLUCH-PITS *apud* MINUSSI; LOTUFO, 2007; MORETTI, 2010).

2.5.1 Funções de Não Linearidade para Redes Neurais

O modelo de *McCulloch-Pitts* é articulado pelas somas das entradas e dos pesos. Essa soma alimenta uma função não linear. As funções mais comuns são relé, lógica Threshold ou sigmóide, ou seja, deve-se escolher uma destas funções para fazer a regressão dos dados. Estas funções possuem pesos bias que são carregadas por uma constante que controle as saídas do neurônio (*McCulloch-Pitts apud* MINUSSI; LOTUFO, 2007).

As Figuras 3, 4, 5 e 6 ilustram, graficamente e suas respectivas equações, as funções de não linearidade, conhecidas como funções de ativação. Para calcular estas funções, é necessário obter a multiplicação e soma dos pesos com as entradas, conforme as equações Eq. 2.3, 2.4 e 2.5. Deve-se obter a soma destas funções, até que apresente os sinais de regressão linear (MCCULLOCH-PITTS *apud* MINUSSI; LOTUFO, 2007; MORETTI, 2010).

a) Função Ativação Relé

Figura 3 – Função de ativação relé

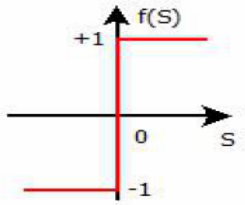

Fonte: Minussi e Lotufo, 2007.

$$f(s) = \begin{cases} +1, se\ s \geq 0 \\ -1, se\ s\ \leq 0 \end{cases} \qquad \text{[Eq. 2.3]}$$

b) Função de Ativação Lógica *Threshold*

Figura 4 – Função de ativação lógica *Threshold*

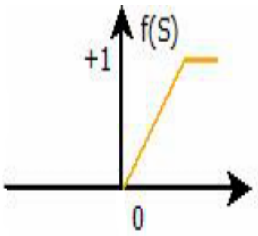

Fonte: Minussi e Lotufo, 2007.

c) Função de Ativação Sigmoide

- **Função Sigmoide (1)**

Figura 5 – Função de ativação sigmóide (1)

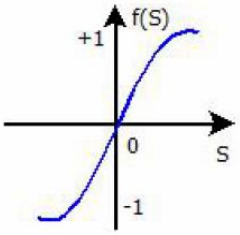

Fonte: Minussi e Lotufo, 2007.

$$f(s) = \frac{1-e^{-\lambda s}}{1+e^{-\lambda s}} \qquad \text{[Eq. 2.4]}$$

Sendo que:

λ = Inclinação da curva.

- **Função Sigmoide (2)**

Figura 6 – Função de ativação sigmóide (2)

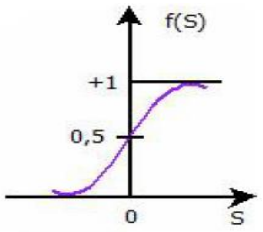

Fonte: Minussi e Lotufo, 2007.

$$f(s) = \frac{1}{1+e^{-\lambda s}} \qquad \text{[Eq. 2.5]}$$

As redes neurais podem ser divididas em três categorias: *feedforward, feed-back e self-organizing.* Embora cada uma destas categorias, sejam baseadas em diferentes filosofias e obedeçam diferentes princípios, a caracterização de um sistema pelo termo geral "rede neural" implica em uma habilidade para aprender. Aprendizagem é o processo pelo o qual o sistema neural adquiri habilidade para processar certas tarefas ajustando seus parâmetros internos de acordo com alguns esquemas de aprendizagem (KARAYIANNIS; VENETSANOPOULOS, 1993).

A rede neural *feedforward* é normalmente a mais usada. Esta consiste de uma ou mais camadas de unidades ou elementos de processamento linear. As unidades pertencentes as camadas vizinhas são conectadas por conjunto de pesos sinápticos. Tal rede neural é chamada de *feedforward* (KARAYIANNIS; VENETSANOPOULOS, 1993).

As redes neurais *feedforward* podem ser recorrentes ou não-recorrentes Simpson Apud Minussi e Lotufo (2007), definem dois tipos de redes neurais classificadas como:

- Redes Neurais Recorrentes: possuem laços de realimentação conectados desde as entradas até as saídas, sendo que uma delas se encontra no meio chamado de camada intermediária;

- Redes Neurais Não recorrentes: é aplicada em camadas de neurônios que só recebem sinais das camadas anteriores, pois estas não contêm a realimentação entre as camadas.

Haykin (2001) e Minussi e Lotufo (2007), aplicaram mesmos modelos de redes neurais tipo *feedforward*, sendo estas redes recorrentes e a não recorrente, onde se obteve sucesso nas redes não recorrentes, pois não necessita de memória, enquanto que, as entradas e pesos são exclusivos para saídas dos dados.

As redes neurais são estudos aplicados em inteligência artificial (AI) para desenvolvimento de algoritmos genéticos, que contam com grandes aplicações tecnológicas na engenharia. Este campo tecnológico tem crescido muito nos últimos anos, sendo aplicados em engenharia genética e automação, a fim de obter novos produtos automatizados a disposição da sociedade (GUPTA, 2013).

As redes neurais artificiais são concepções entre *hardware* e *software*, pois contem capacidade de aprendizagem eficaz em relação ao cérebro humano, sendo aplicados padrões de reconhecimento formados por neurônios interligados, a fim de ajustar os pesos e conduzir os conjuntos de padrões e treinamentos se obtendo os resultados diretamente na saída, onde este treinamento neural depende do custo computacional (*hardware e software*) para respostas em tempo real (CAMPOS, 2010).

De acordo com Badde et al (2013), as redes neurais artificiais (RNAs) são uma família de arquiteturas massivamente paralelas que são capazes de aprender e generalizar a partir de exemplos e experiência para produzir soluções significativas para os problemas, mesmo quando os dados de entrada contêm erros e estão incompletas. Isso faz com que estas RNAs se tornem uma poderosa ferramenta, para a solução de alguns dos complicados problemas de engenharia.

Na Figura 7, pode ser observado os modelos ADALINE (a), MADALINE (b), HOPFIELD (c), ART (d) e ARTMAP (e).

Figura 7 – Modelos de treinamento para redes neurais artificiais (Minussi e Lotufo, 2007)

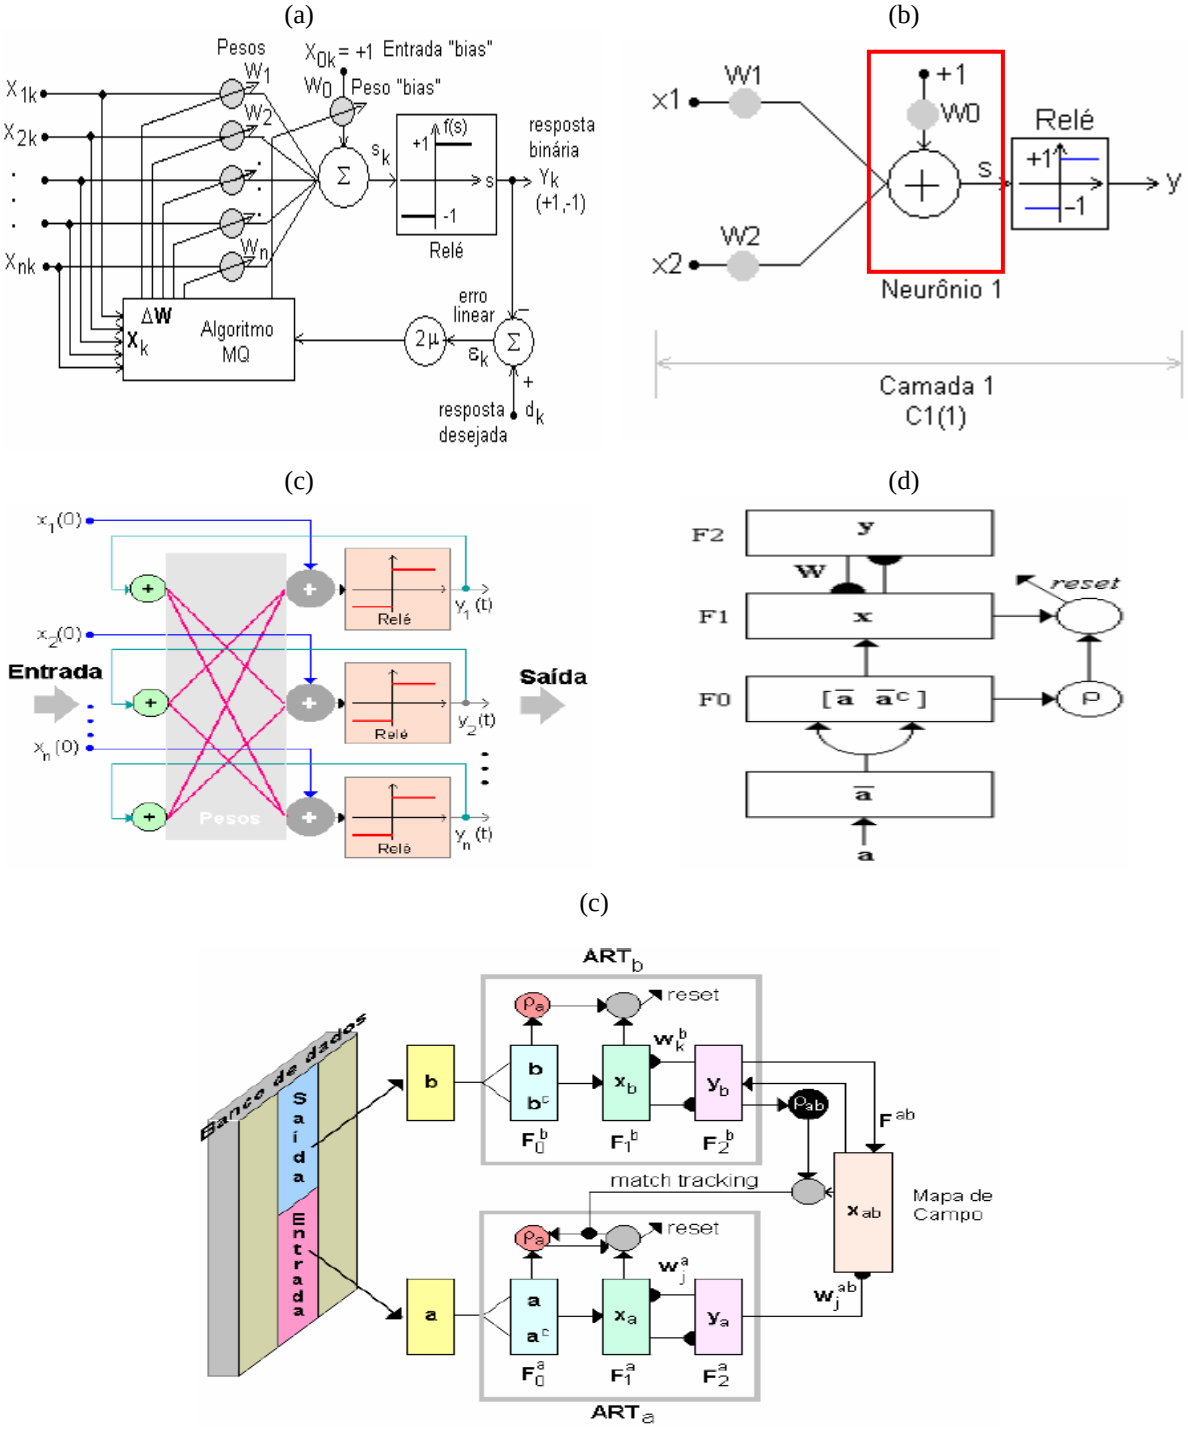

Fonte: Minussi e Lotufo, 2007

Também, na Figura 7, os modelos de treinamento para redes neurais artificiais, podem ser conhecidos como:

- *ADALINE* – é o modelo que se adapta linearmente em série pela função relé, sendo que a função não linear é muito utilizada para saídas de padrões binários. Este algoritmo de *McCulloch-Pits* contém não linearidade na função relé, pois tem duas entradas e saídas que utilizam funções lógicas *and*, *or* e *nor* exclusivo. Assim sendo, o modelo também tem um algoritmo chamado *Windrow-Hoff*, que realiza adaptação dos pesos;
- *MADALINE* – é conhecido como *backpropagation* (retropropagação), trata-se de um algoritmo aprendizagem para treinar a rede neural. Este algoritmo tem capacidade de inverter a matriz, ou seja, os dados de entrada passam a ser os dados de saída e vice-versa. Normalmente utilizado para automação e robótica. Este modelo matemático faz o ajuste dos pesos que apresentam erro, durante a retropropagação, associada a uma derivada parcial, onde pode ser repetida até a convergência dos valores aplicados a um número máximo de ciclos das camadas.
- *HOPFIELD* – é uma rede neural de *Kohonen* bem diferente do modelo *feedforward.* Esta rede define os pesos de forma direta, ou seja, a função do neurônio soma se distribui os sinais a partir de saída;
- ART (*Adaptive Resonance Theory*) – é um treinamento rápido e não supervisionado com estabilidade e plasticidade. Contém três camadas de entradas com vetor de atividade, pesos, categoria, ressonância e atualização;
- ARTMAP Nebulosa – a característica deste algoritmo é o treinamento rápido, ou seja, é supervisionado e auto organizável. Possui parâmetros de entrada e treinamento sequencialmente ou aleatório (KARAYIANNIS; VENETSANOPOULOS, 1993; MINUSSI; LOTUFO, 2007).

2.5.2 Modelo do Algoritmo de Retropropagação (*MADALINE*)

O desenvolvimento de algoritmos de aprendizagem rápidos e eficientes para redes neurais tem sido um assunto de interesse. Como resultado foram propostos diversos novos algoritmos para treinar a rede neural. A popularidade da rede neural de diversas camadas

motivou pesquisadores para acelerar a queda do erro do algoritmo de retropropagação. Versões aceleradas da queda do erro do algoritmo de retropropagação foram tentadas pela adaptação da taxa de aprendizagem durante o treino ou por várias outras análises heurísticas para melhorar a convergência do algoritmo. Os desenvolvimentos de algoritmos de aprendizagem alternativos, para redes neurais de multicamadas, foram testados modificando a estratégia de otimização e/ou empregando outras regras de adaptação como o gradiente descendente (KARAYIANNIS; VENETSANOPOULOS, 1993).

No modelo de gradiente descente, o ajuste dos pesos é determinando pelo algoritmo descente, onde este é treinado pelas camadas anteriores conforme a equação Eq. 2.6 (Apud N.2 MINUSSI; LOTUFO, 2007; MORETTI, 2010).

$$\Delta W^{(k)} = W^{(k+1)} - W^{(k)} = \alpha(-\nabla \varepsilon^{2(k)}) \qquad \text{[Eq. 2.6]}$$

ΔW = variação do vetor de pesos W;
k = índice que indica o número de camadas;
α = taxa de treinamento;
∇_{ε} = vetor gradiente de erro quadrático;
ε^{2k} = erro quadrático da rede neural.

O algoritmo descendente é ilustrado na Figura 8.

Figura 8 – Algoritmo descendente

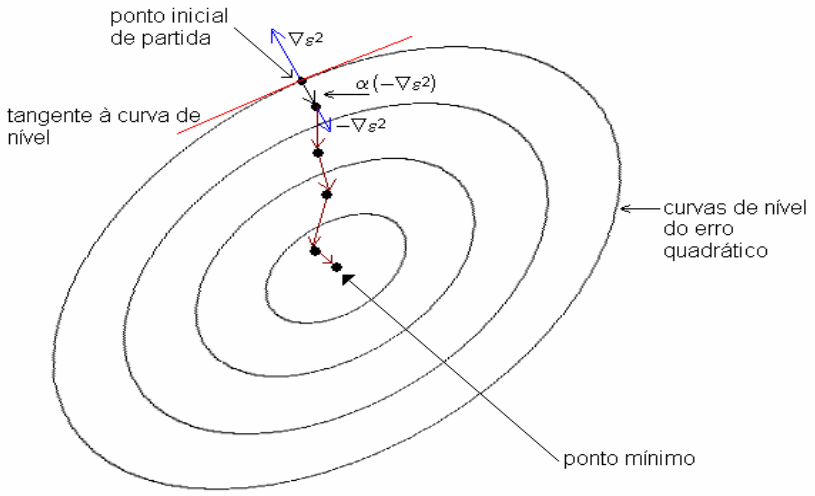

Fonte: Minussi e Lotufo, 2007.

Este ajuste de pesos, na direção contrária, pode determinar o erro quadrático ($\varepsilon^{(2k)}$) e, com uma taxa de treinamento (α), deve atuar no fator de escala e, diminuir ou aumentar o vetor de erro quadrático (-$\nabla\varepsilon^2$). Para o valor de α se tornar estável, é preciso controlar o ponto de equilíbrio da rede (HAYKIN, 2001; MINUSSI; LOTUFO, 2007; MORETTI, 2010).

2.5.3 Treinamento do Algoritmo de Aprendizagem para Retropropagação

Minussi e Lotufo (2007), discorrem sobre as entradas (x_n), que devem ser somadas na primeira camada, com os respectivos pesos e bias (w_{mn}). Estes pesos, utilizam uma forma aleatória entre [0, +1] ou [-1, +1] e podem definir os pesos bias com valores fixos, para que as somas dos valores passem pelas funções de ativação (sigmóide) e, sejam ajustadas por uma taxa de inclinação (λ). Este processo pode executar as somas das camadas intermediárias, até que a última camada apresente o resultado do valor de saída.

Com as equações Eq. 2.7 e 2.8, pode-se calcular com o valor do erro. É possível haver uma ou mais saídas gerando os erros quadráticos. Estas serão associadas a uma derivada parcial, para realizarem uma retropropagação (sentido inverso nas camadas). Podem ser iniciadas diretamente na camada de saída, para realizar a soma dos ajustes de pesos, a fim

de obter os novos pesos nas camadas anteriores, até a camada de entrada da rede (MINUSSI; LOTUFO, 2007; MORETTI, 2010).

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2 \qquad \text{[Eq. 2.7]}$$

Sendo que:

$$\varepsilon_i = d_i - y_i; \qquad \text{[Eq. 2.8]}$$

ε_i = é o í-ésimo erro da última camada da rede;
d_i = saída desejada do i-ésimo elemento da última camada de rede;
y_i = saída do i-ésimo elemento da última camada de rede;
ns = número de neurônios da última camada de rede.

Esta rede soma e ajusta os pesos e, pode verificar o neurônio no índice i do gradiente descendente conforme as equações Eq. 2.9 e 2.10 (MINUSSI; LOTUFO, 2007).

$$U_i(k+1) = U_i(k) + \Delta U_i(k) \qquad \text{[Eq. 2.9]}$$

Sendo que:

$$\Delta U_i(k) = -\alpha[\nabla_i(k)]; \qquad \text{[Eq. 2.10]}$$

$\Delta U_i(k)$ = comprimento do vetor;
$\nabla_i(k)$ = gradiente do erro quadrático com relação aos pesos do neurônio i avaliado em h;

$U_i = [w_{0i}\ w_{1i}\ w_{2i}\ \ ...\ \ w_{ni}]$ – é o vetor contendo os pesos do neurônio i.

Este processo de ajuste minimiza o erro quadrático, com uma taxa de treinamento (α), que adota o comprimento do vetor $[\nabla_i(k)]$ e devolve a soma de $\Delta U_i(k)$. É possível tornar mais rápida a resposta deste algoritmo de retropropagação. As equações Eq. 2.11 e 2.12 mostram como se calculam o peso correspondente à camada. Deve-se considerar na função sigmoide uma taxa de momento (η), a fim de obter mais rápido o valor do gradiente (CAMPOS, 2010).

$$u_{ij}(k+1) = u_{ij}(k) + \Delta u_{ij}(k) \qquad \text{[Eq. 2.11]}$$

Sendo que:

$$\Delta u_{ij}(k) = 2\alpha(1-\eta)\delta_j x_i + \eta \Delta u_{ij}(k-1); \qquad \text{[Eq. 2.12]}$$

u_{ij} = peso correspondente à interligação entre o i-ésimo e j-ésimo neurônio;

η = constante momento $(0 \leq \eta < 1)$.

Caso o elemento j estiver na última camada, este automaticamente deve efetuar a soma utilizando a equação Eq. 2.13.

$$\delta_j = \theta_j \varepsilon_j \qquad \text{[Eq. 2.13]}$$

Sendo que:

θ = derivada da função sigmóide dada pelas equações Eq. 2.15 e 2.16, que tem relação a s_j, que é igual a $= 0{,}5\lambda(1-y^2)$ ou $= \lambda y(1-y)$.

Caso o elemento j estiver nas demais camadas, esta rede deve efetuar a soma de acordo com a equação Eq. 2.14.

$$\delta_j = \theta_j \sum_{k \in R(j)} w_{jk} \delta_k \qquad \text{[Eq. 2.14]}$$

Sendo que:

$R(j)$ = conjunto dos índices dos elementos que se encontram na fileira seguinte à fileira do elemento j, e que estão interligados ao elemento j.

Minussi e Lotufo (2007), trata da derivação da função sigmóide (equação Eq. 2.4), com ajuste no ângulo (θ) da rede e obtém a equação E. 2.15, conforme as equações:

$$\frac{\delta y}{\delta s} = 0{,}5\ \lambda(1 - y^2) \qquad \text{[Eq. 2.15]}$$

A partir da soma da derivada parcial, esta função sigmóide (equação Eq. 2.5), pode ser reescrita pela equação Eq. 2.16.

$$\frac{\delta y}{\delta s} = \lambda y(1 - y) \qquad \text{[Eq. 2.16]}$$

2.5.4 Aplicações de Redes Neurais para Cálculos de Concretos

Dragan et al, (2012), propuseram as confecções de concretos por meio de redes neurais artificiais, o que permite realizar com precisão os valores em massa (kg) dos materiais e a correspondente resistência à compressão (MPa), pois utilizam um número de parâmetros de entrada do algoritmo genético *feedforward*, a fim de treinar os pesos e as funções

sigmóides entre as camadas. Esta retropropagação encontra erros e ajusta todos os pesos das camadas anteriores, pois é o processo realizado em ciclos para que atinjam o valor de saída desejada, que são respostas de resistências à compressão (MPa). Assim, esta abordagem principal do desenvolvimento do sistema é por multicamadas para apresentar um treinamento por retropropagação. Este modelo, por multicamadas, propõe entradas e saídas normalizadas, pois as funções sigmóides dependem de números aleatórios entre [0 e 1] ou [-1 e +1]. Estas normalizações podem ser calculadas por regras estatísticas como o cálculo dos mínimos quadrados diretamente nas entradas obtendo o valor máximo e mínimo. Quando atingir a resposta com o menor erro e o valor desejado, é aplicada a desnormalização com a mesma regra estatística. Assim, o resultado obtido do treinamento é apresentado na forma de resistência axial.

Segundo Gupta (2013), a quantificação dos materiais, para a confecção do concreto, como: cimento, areia, britas e água, pode substituir este método de tradicional pelo modelo de redes neurais artificiais, o que apresentam resistências à compressão em tempo real. Assim, foi necessário armazenar uma quantidade de 55 exemplares, para realizar os testes dos treinamentos da rede neural, sendo que estas comparações experimentais realizam em um par de entradas e saídas os sinais de formato vetorial. Estes resultados foram significativos, pois se mantiveram aproximados os mesmos índices de resistências. Conclui-se que a rede neural é eficaz no treinamento das massas (kg).

O modelo minimiza a função objetivo e supervisiona o método de aprendizagem, que calcula a soma das entradas e dos pesos com a função sigmoide. Assim, para cada saída da função sigmóide é calculado nas próximas camadas os valores das funções pesos. Este processo é realizado passando pela camada de entrada, intermediária e saída. Quando encontrado o valor de resposta são calculados os erros e a função de derivação, sendo que possa realizar a retropropagação nas camadas anteriores. Aplicando as misturas de 64 testes com diferentes tipos de cimento, se pode concluir que os dados resultantes da rede neural, são técnicas aplicadas em simulação do banco de dados entre resistências e massas (kg), a fim de se obter com sucesso os valores de resistência à compressão aplicando diferentes idade e misturas (ABDEEN; HODHOD, 2010).

Segundo Badde et al (2013), é proposto um estudo entre os modelos a serem desenvolvidos na utilização de uma rede neural tipo *feedforward* em multicamada chamada de *preceptor*. Este modelo consiste nas somas ponderadas das funções dos neurônios em um conjunto de entradas, pesos, funções sigmoides e as saídas. Assim, podem apresentar os erros e ajustar os pesos das camadas no modelo de retropropagação, sendo que são armazenados os

dados coletados dos ensaios de laboratório em um banco de dados. Destes ensaios, foram treinados os dados das entradas com os valores em massa (kg) dos materiais como: cimento, água, areia, britas e relação (a/c). Realizando o treinando estes dados do concreto convencional (CC), obtém-se a saída em resistência à compressão e a resposta para um período de 28 dias.

Os dados foram inseridos nas entradas e transformados em índices não dimensionais, onde obtidos os valores das entradas como a/c (água cimento), água/total (em que total é o peso da mistura), agregado graúdo/agregado miúdo, mistura/cimento e aditivo/cimento, foram realizadas as simulações na rede *feedforward*, com objetivo de treinar e devolver os resultados de resistência à compressão através das camadas em ciclos. Então, se conclui que o modelo cascata (*backpropagation*) é o que tem melhor desempenho, pois tem respostas mais eficazes e reduz o tempo de resposta.

Dragan et al (2012), defende a utilização de um coeficiente empírico na rede neural para aumentar a resistência, sendo que os treinamentos nas camadas da rede e os ajustes dos pesos da retropropagação, foi suficiente para encontrar o valor da resistência diretamente na saída, conforme se observa na Figura 9.

Figura 9 – Modelo aplicado para três estágios de treinamento (Dragan et al., 2012)

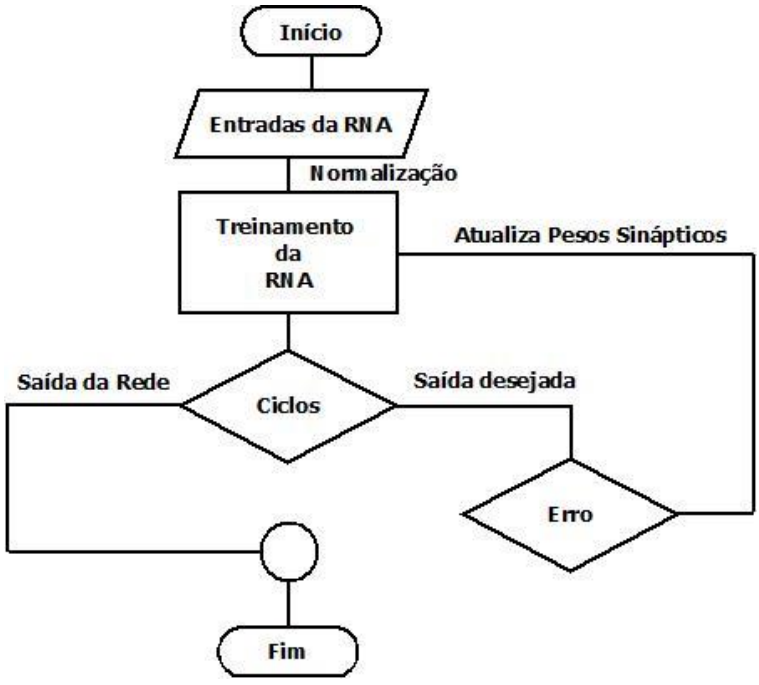

Fonte: Bolognini Apud Dragan et al (2012)

Na Figura 9, as entradas e o coeficiente empírico da rede neural, foram aplicados por estágios:

- 1º Estágio – marca de cimento, tipo de cimento, quantidade de cimento, coeficiente de Los Angeles (Resistência a Fragmentação), conteúdo fracionário, total da quantidade de agregados do concreto fresco, quantidade de água, relação (a/c), média do abatimento, densidade do concreto e resistência à compressão pela idade. Todos estes parâmetros foram adicionados no primeiro estágio da rede neural, a fim de simular o treinamento e ajuste dos pesos para obter o valor de saída desejada. Foram constatados que a marca do cimento não seria um dos parâmetros de entrada, assim sendo, a rede neural identificou apenas o tipo de cimento, e não fabricante;
- 2º Estágio – foram utilizados cinco parâmetros de entrada como: tipo de cimento, quantidade de cimento, relação (a/c), média de abatimento e resistência à compressão. Esta realização foi um sucesso na passagem dos parâmetros, então se conclui que a rede foi eficaz neste estágio;
- 3º Estágio - diminuindo para quatro os parâmetros de entrada como: tipo de cimento, quantidade de cimento, relação a/c e resistência à compressão. Seguindo o exemplo do estágio anterior, foram retirados apenas o parâmetro de entrada média de abatimento, e se concluiu o sucesso neste terceiro estágio da rede neural artificial.

O terceiro estágio demonstrou uma regressão linear do coeficiente de regressão, sendo que esta solução empírica também solucionou a influência dos minerais adicionados com diversos tipos cimento, pois se otimizou a produção do concreto com sucesso na rede neural *feedforward*.

Gupta (2013), treinou uma rede neural para os períodos de 7,14 e 28 dias de concreto. Foram obtidos no ciclo de treinamentos da rede e ajustes dos pesos os coeficientes de correlação. Assim sendo, esta apresentação dos coeficientes tornou-se eficaz na otimização do concreto.

Dragan et. al. (2012), realizaram ensaios de resistências de concreto em 288 corpos de prova. Com objetivo de aperfeiçoar a produção, os resultados foram divididos em dois os bancos de dados, a fim de armazenar 240 resultados de resistências para realizar a aprendizagem da rede neural, enquanto que, outras 48 resistências foram selecionadas para testes. Realizando as simulações de aprendizagem da rede neural, foram utilizados por etapas das 48 resistências de testes, sendo que em todos os estágios da rede neural estiveram normalizados nas entradas e desnormalizados nas saídas com apenas um neurônio com o valor de saída desejada de resistência à compressão para 28 dias.

Elgin e Senouci (1994), treinaram uma rede neural para obter resultados de dosagem de concreto com borracha. Os autores desenvolveram cinco tarefas de execução para programar a rede neural, sendo que a primeira identificava a entrada e saída, na segunda preparava os exemplos de treino e teste, na terceira determinava o tamanho das camadas e dos neurônios da rede neural, na quarta realizava o treinamento e a quinta realizava o teste em ciclos na rede. Esta rede foi identificada na entrada e saída com tipo de borracha, tamanho, porcentagem, idade do concreto, resistência à compressão e tração de borracha. Foram testados 60 exemplares, onde 48 deles foram consideradas e apenas 12 como testes iniciais. Concluíram que a rede neural foi eficaz nas respostas das resistências à compressão.

Ao realizar o treinamento por redes neurais artificiais, é preciso organizar todas entradas do algoritmo de retropropagação (*backpropagation*), com valores das quantidades de materiais em massa (kg). Estas estradas correspondem as variáveis chamadas de cimento Portland, agregados graúdos, agregados miúdos, reciclados da construção civil, aditivos e água. Estes valores de entrada, podem aumentar a velocidade do tempo de resposta na saída da rede. Entretanto, a complexidade da rede depende do tamanho destas camadas escondidas, pois redes *feedforward* com mais de uma camada interna, podem agilizar o treinamento e responder com mais facilidade na retropropagação. Então, pode se concluir que a rede pode diminuir o tempo de resposta, para apresentar com maior rapidez as resistências à compressão do concreto (CHANDWANI et al, 2014).

2.6 SOFTWARES APLICADOS COM INTELIGÊNCIA ARTIFICIAL PARA DOSAR CONCRETOS

De acordo com Neshat et al (2012, p. 373), "[...] a Inteligência Artificial (AI) está recebendo maior atenção na indústria da construção civil, para auxiliar no processo das tomadas de decisão em áreas de pesquisa, desenvolvimento e reparação".

Segundo Pileggi (2001), a maneira eficaz de uma melhor trabalhabilidade na distribuição granulométrica seria uma formulação algorítmica, para desenvolver um *software* capaz de garantir agilidade e precisão. O mesmo pôde verificar o comportamento reológico do concreto e as misturas dos materiais, ou seja, se pode com tal *software* simular diversas técnicas de aplicação.

Na Figura 10, a inteligência artificial e os neurônios são elementos de múltiplas entradas e saída para redes neurais artificiais. A ligação da rede neural pode ser representada por camadas. Esta rede pode determinar ações, gerando e recebendo sinais nas entradas e saídas, que passam pela ligação da camada interna dos neurônios da rede. Contudo, estes podem ser estáticos ou dinâmicos e dependem do tempo de processamento dos sinais. O treinamento da rede neural depende das modificações no comportamento dos neurônios. A sua arquitetura depende dos coeficientes, pesos, funções de entrada e da ativação, que podem ser divididos em dois grupos de aprendizagem: Supervisionada e Não Supervisionada. Estas funções são de forma linear e não linear, que podem ser combinações dos sinais de forma simples não linear ou polinomial, para aumentar o processamento do neurônio. A função mais adequada é de ativação linear, mas para resolver as funções não lineares a mais recomendada é a função sigmoide (DRAGAN et al., 2012).

Figura 10 – Modelo de redes neurais artificiais (Minussi e Lotufo, 2007)

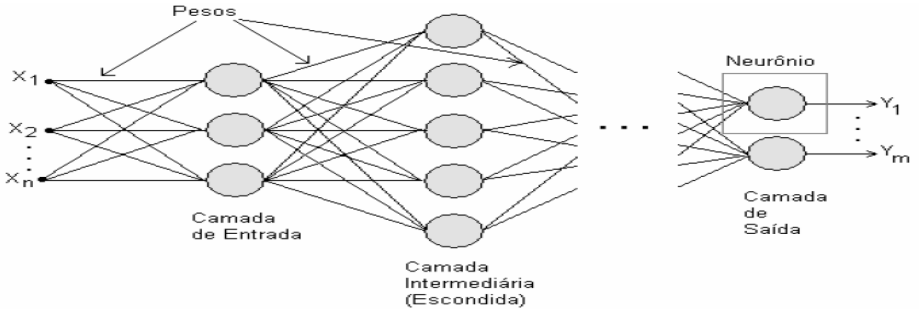

Fonte: Minussi e Lotufo, 2007

É importante ressaltar que algoritmos genéticos otimizam modelo computacionais de processos evolutivos. Por serem não lineares, estes processamentos têm capacidade para resolver numerosas soluções. Também, é uma mistura perfeita de pesquisa e treinamento, onde o algoritmo de retropropagação com um processo estocástico, pode definir através do gradiente descendente a busca de erros e aplicar ajuste nos pesos da rede neural. Este processo vai englobar a utilização dos operadores estocásticos no treinamento da rede, a fim de otimizar os resultados com maior rapidez (CHANDWANI et al, 2014).

3 ESENVOLVIMENTO DE SOFTWARES

3.1 ENGENHARIA DE SOFTWARE

É necessário um planejamento para o desenvolvimento de *softwares*, onde se aplica métodos de programação, com ferramentas e procedimentos para programar o *software*. Estas ferramentas são conhecidas como: linguagem de programação; enquanto que, estes procedimentos são as etapas de desenvolvimento do programa, também conhecidos como engenharia de *software*. Esta engenharia é a análise de todas as informações requisitadas pelo usuário, para desenvolvimento e entrega final do *software* (PRESSMAN, 2011).

Pressman (2011), tratou da utilização da adequada do *software*, por um *hardware* que tenha velocidade de processamento. Este hardware está relacionado ao custo computacional (*hardware e software*), para executar instruções com um compilador, ao mesmo tempo executando outros processos. Entretanto, existe a possibilidade de causar problemas de espera, com outros processos abertos no sistema operacional (SO). Contudo, não se deve tratar de projetos fabricados como é o caso do *hardware*. Então, se pode concluir que os s*oftwares* são processos executados por estruturas de manipulação de dados, com informações impressas ou virtuais.

Portanto é necessário uma interface gráfica para a execução do *software*.

Deitel (2005), programou interfaces gráficas que atendem sobre aparência e comportamento da estrutura de *software.* Estas interfaces, devem ser amigáveis aos usuários, pois os mesmos dependem da acessibilidade do aplicativo. O autor sugere a utilização da linguagem *Java* o GUI (*Graphical User Interface*), pois oferece um ambiente de desenvolvimento para *softwares.*

As interfaces gráficas, para *softwares*, têm aumentado o número expressivo de usuários que desejam utilizá-las em pesquisas científicas. Em plataformas (*WINDOWS*) e *(UNIX*), a aparência e comportamento, devem variar, pois, os ambientes de acesso mais agradáveis ao usuário são sistemas operacionais (SO) Windows (*Microsoft Corporation*). Estes podem permitir interação e armazenamento, para grandes quantidades de informações.

3.2 LINGUAGEM DE PROGRAMAÇÃO *JAVA*

Deitel (2005), expôs sobre o surgimento de dispositivos inteligentes de programação *Java*. A linguagem *Java*, pode editar, compilar, carregar, verificar e executar, por fases dentro do contexto *J2SE Development Kit* (JDK) da *Sun Microsystens*. Também, o mesmo ambiente de desenvolvimento oferece programação contendo recursos para redes integradas *(java.net*), pois é aplicado diretamente em métodos de chamada para outro objeto (comunicação entre computadores via internet). O autor conclui que estas comunicações são conhecidas pela utilização dos pacotes *Remote Method Invocation* (RMI), com pacotes *java.rmi* (cinco pacotes), sendo acionadas pelo *Java Virtual Machine* (JVM) para se comunicarem remotamente.

Existem pacotes *org.omg* (sete pacotes) para *Common Object Request Broker Architeture* (CORBA), onde pode ser utilizado entre dois aplicativos. Também, o oferecido no mesmo ambiente o *Java Server Pages* (JSP), pois é aplicado diretamente na programação de páginas da internet (WWW). Os pacotes *javax.servlet* e *javax.servlet.http*, são definidas entre classes e interfaces, enquanto que, *javax.servlet.jsp* e *javax.servlet.jsp.tagext*, contém classes e interfaces de alta capacidade. Estes métodos de programação permitem que se crie páginas (WWW) encapsuladas e, permitindo escritas dos códigos *scriptlets* diretamente nas mesmas. (DEITEL, 2005).

Deitel (2005), propôs a criação de *softwares* aplicativos, com a linguagem *Java*, deverá ser programada em ambientes para desenvolvimento integrados (IDE). Estes ambientes, incluem editores de escrita, e, também, depuradores para buscas de erros na lógica de programação.

Figura 11 – Fases de desenvolvimento proposto (DEITEL, 2005)

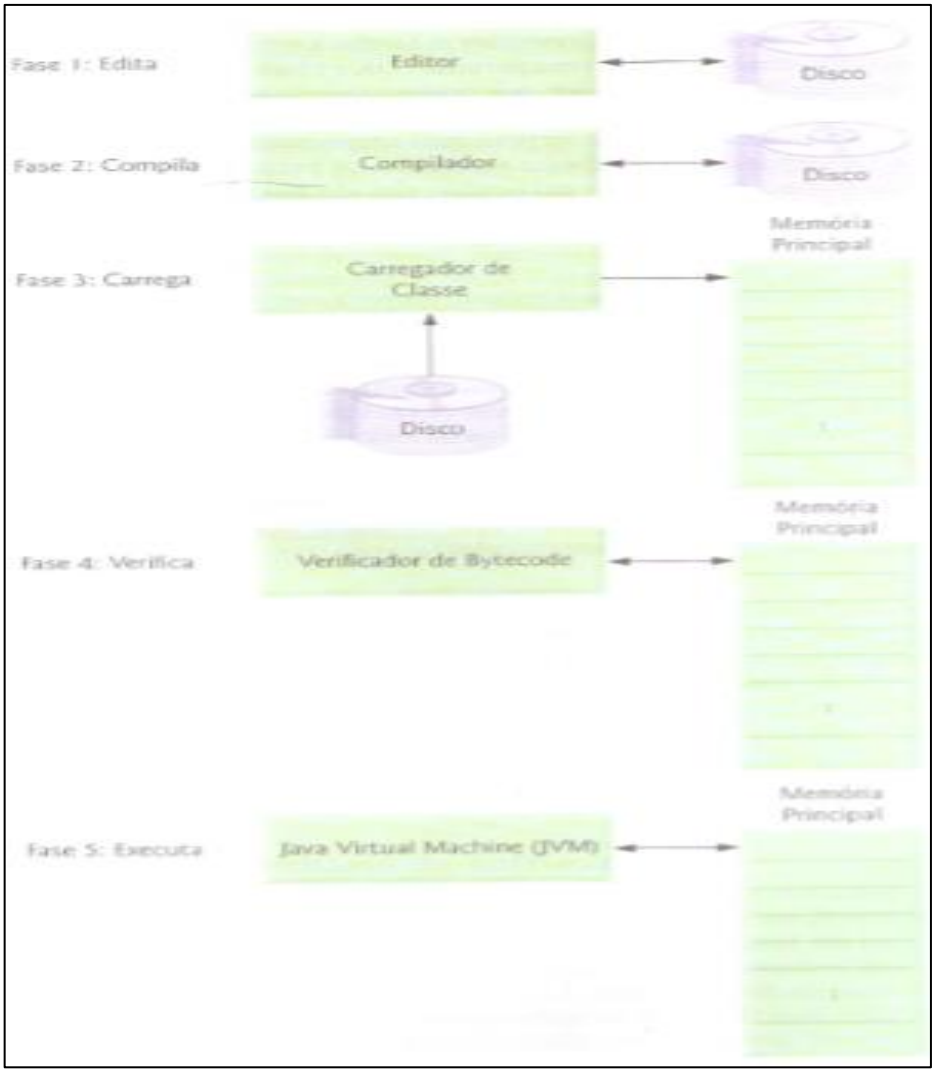

Fonte: Deitel, 2005.

Conforme se observa na Figura 11, estas aplicações para programação de *softwares*, podem ser apresentas por fases:

- Primeira fase, a edição é composta por editor de disco, onde o programa é criado como arquivo de extensão (*.java*);
- Segunda fase, deve consistir na compilação do arquivo armazenado em disco, para criar um *bytecodes* extensão (*.classI*);
- Terceira fase, é carregada na classe o arquivo (*.class*) contido no *bytecodes*, deixando-a na memória;

- Quarta fase, realiza-se a verificação do *bytecodes*, para validação e não violação das restrições de segurança;
- Quinta fase, é executado o programa JVM (*Java Virtual Machine*), onde este traduz a linguagem, para executar e armazenar na memória principal.

A linguagem de programação *Java* possibilita o desenvolvimento de ambientes *Desktop* (computadores em redes locais) e, também, permite oferecer a mesma interface para computadores conectados na internet por *World Wide Web* (WWW). Utiliza-se das mesmas classes programadas e, pode ser atualizado constantemente no servidor *Java*. Este ambiente de programação é oferecido pela empresa *ORACLE*, onde disponibiliza o IDE Netbeans 8.0.2, com licença *freeware*.

4 MATERIAIS E MÉTODOS

4.1 INTRODUÇÃO

Os materiais utilizados para confecção do concreto foram o cimento Portland, água, agregados graúdos, agregados miúdos e aditivos. Para os agregados, foram obtidas as curvas da distribuição granulométrica e realizada as caracterizações para determinar as densidades e absorções.

Os materiais utilizados nesta dissertação foram selecionados para realizar comparações entre diferentes britas e cimentos a fim de obter a dosagem do concreto. Para isto foram realizados ensaios de resistência à compressão, cujos resultados foram aplicados à metodologia de redes neurais artificiais e técnicas para desenvolvimento de *softwares*.

4.2 CIMENTOS

Neste trabalho de dissertação os cimentos Portland utilizados estão apresentados na Tabela 2.

Tabela 2: Cimentos utilizados no presente trabalho (ABNT NBR NM 5733 (1991), ABNT NBR NM 5735 (1991), e ABNT NBR NM 11578 (1997)).

Sigla	Classe de Resistência	Componentes (% em massa)			
		Clínquer + sulfatos de cálcio	Escória granulada de alto-forno	Material pozolânico	Material carbonático
CP II-Z	25;32;40	94-76	-	6-14	0-10
CP III	25;32;40	65-25	35-70	-	0-5
CP V - ARI	-	95-100	-	-	0-5

4.3 AGREGADOS GRAÚDOS

Os agregados graúdos que foram utilizados na mistura da argamassa, tiveram diâmetros: 4,75 mm a 12,5 mm – britas B0 e 9,5 mm a 25 mm – britas B1, sendo que foram

selecionados três tipos de britas: basalto, granito e seixo rolado. Esta seleção tem como objetivo a confecção de concreto com diferentes materiais. Na Figura 12, se observa a ilustração da brita de basalto B0 (a) e B1 (b), respectivamente.

Figura 12: Britas de basalto B0 e B1

(a) (b)

Fonte: Enio José Bolognini

As britas de granito foram coletas de refugos abandonados às margens da Rodovia SP 595 (Rodovia dos Barrageiros – Figura 13 (a)). Essas foram reaproveitadas para confeccionar concreto convencional (CC) e de alta resistência (CAR). Estes refugos foram transportados até a Usina de Reciclagem da Prefeitura Municipal de São José do Rio Preto/SP, para serem triturados nos diâmetros de 4,75 mm a 12,5 mm de britas B0 e de 9,5 mm a 25 mm de britas B1. Esta britagem dos granitos, também forneceu agregados miúdos, pois a reciclagem da usina conta com a britagem e separador de agregados graúdos. Nesta ocasião, foram calibradas as esteiras para receberem os refugos de granito, a fim de serem triturados e transformados em britas. Estes reaproveitamentos dos refugos de granito acabaram fornecendo os diâmetros de britas B0 e B1, que foram necessários para o trabalho desta dissertação. Abaixo, na Figura 13, pode observar o separador do britador da usina de reciclagem (b) e as britas de granito B0 (c) e B1 (d).

Figura 13 – Refugos, usina de reciclagem e britas de granito B0 e B1

(a) (b)

(c) (d)

Fonte: Enio José Bolognini

Nesta dissertação, também foi utilizado como agregado graúdo o seixo-rolado. Na Figura 14 está apresentada a ilustração do seixo.

Figura 14 – Britas de seixo-rolado

Fonte: Enio José Bolognini

4.4 AGREGADO MIÚDO

Os agregados miúdos, utilizados neste trabalho de dissertação, tiveram módulo de finura (MF) em 3,3, sendo considerado areia grossa. O mesmo está ilustrado na Figura 15.

Figura 15 – Areia grossa espalhada e seca por 48h sob os raios solares para obter umidade 0%

Fonte: Enio José Bolognini

Este agregado miúdo foi misturado ao cimento Portland e à água, a fim de formar à argamassa e misturar com agregados graúdos para confeccionar o concreto. Todos os materiais foram ensaiados a fim de serem caracterizados.

4.5 MÉTODO DE ENSAIO PARA DISTRIBUIÇÃO GRANULOMÉTRICA

A distribuição granulométrica dos agregados utilizados neste trabalho foi realizada conforme a ABNT NBR NM 248 (2003). Esta trata dos ensaios de granulometria, determinação da massa específica, módulo de finura e tipo de agregado miúdo. Este módulo deve ser determinado de acordo com o conjunto de peneiras numeradas (ABNT NBR NM-ISO 3310-1 ou 2), onde à abertura das malhas estejam de acordo com as séries normais e intermediárias descritas na Tabela 3.

Tabela 3 - Série normal e intermediária de peneiras conforme a NM-ISO 3310-1 ou 2, para ensaio de granulometria (ABNT NBR NM 7211, 2009)

Série Normal	Série Intermediária
75 mm	-
-	63 mm
-	50 mm
37,5 mm	-
--	31,5 mm
--	25 mm
19 mm	-
4,75 mm	12,5 mm
2,36 mm	-
1,18 mm	6,3 mm
600 µm	-
300 µm	-
150 µm	-

Nos ensaios de laboratório os agregados graúdos e miúdos foram colocados em recipientes metálicos e levados até a estufa com temperatura de (105 ± 5)°C, para secarem até consistência de massa, conforme ABNT NBR MN 52 (2009). Na Figura 16, pode-se observar a estufa usada na secagem das amostras.

Figura 16 – Estufa para secagem das amostras dos ensaios com temperatura de (105 ± 5)°C ABNT NBR MN 52 (2009)

Fonte: Enio José Bolognini

O agitador mecânico separou as amostras conforme a abertura nas malhas de cada peneira. Este procedimento foi realizado para cada tipo e diâmetro de agregado graúdo e

miúdo. Na Figura 17 estão ilustrados os agitadores e as peneiras utilizadas para os agregados miúdos e graúdos.

Figura 17 – Agitadores mecânicos (a) e (b) para agregados graúdos e agregados miúdos

(a) (b)

Fonte: Enio José Bolognini

4.6 MÉTODO DE ENSAIO DE GRANULOMETRIA DOS AGREGADOS MIÚDOS

Os agregados miúdos foram submetidos ao ensaio de granulometria, conforme ABNT NBR NM 7211 (2009). Estes foram colocados sobre conjunto de peneiras e ordem decrescente de diâmetro conforme apresentada na Tabela 4 e todo conjunto foi agitado mecanicamente.

Tabela 4 – Peneiras (mm) e série, para ensaio de granulometria dos agregados miúdos conforme ABNT NBR NM 7211 (2009)

Peneiras (mm)	Série
4,80	Normal
2,40	Normal
1,20	Normal
0,60	Normal
0,30	Normal
0,15	Normal

O módulo de finura foi obtido conforme ABNT NBR MN 52 (2009). Esta trata da realização do cálculo do módulo de finura (MF) do agregado miúdo e da determinação das porcentagens média e acumulada de cada peneira, e com aproximação de 0,01. Para isso foi obtida a soma das porcentagens retidas acumuladas das peneiras de série normal e dividido por 100, conforme a equação Eq. 4.1. Esta representa a diâmetro máximo característico ($D_{máx}$) do agregado miúdo em relação à abertura da malha de peneiras de série normal ou intermediária. Neste ensaio, a porcentagem retida acumulada apresentou resultado em massa menor ou igual a 5%.

$$MF = \frac{\sum \%Retida\ Acumulada}{100} \qquad \text{[Eq. 4.1]}$$

Realizado o cálculo do módulo de finura (MF), então se classifica o agregado miúdo conforme a Tabela 5:

Tabela 5 – Módulo de finura e classificação do agregado miúdo

Intervalo de Dimensões Características	**Classificação do Agregado Miúdo**
2,90 < MF < 3,50	Grossa
2,20 < MF < 2,90	Média
1,55 < MF < 2,20	Fina

ABNT NBR NM 7211 (2009), expressa o ensaio de granulométrica dos agregados miúdos que devem atender os limites superiores e inferiores estabelecidos. Já o estabelecimento da distribuição granulométrica deve apresentar os limites das curvas de granulometria do agregado miúdo representados na Tabela 6.

Tabela 6 – Distribuição granulométrica por limites dos agregados miúdos (ABNT NBR NM 7211, 2009)

Peneira com Abertura de Malha (ABNT NBR NM ISSO 331O-1) mm	Percentual, em massa, retida acumulada			
	Limites Inferiores		Limites Superiores	
	Zona Utilizável	Zona Ótima	Zona Utilizável	Zona Ótima
9,5	0	0	0	0
6,3	0	0	0	7
4,75	0	0	5	10
2,36	0	10	20	25
1,18	5	20	30	50
0,6	15	35	55	70
0,3	50	65	85	95
0,15	85	90	95	100

4.6.1 Determinação da Curva Granulométrica dos Agregados Miúdos

O ensaio de granulometria dos agregados miúdos apresentou os resultados de massa retida, quantidade em gramas, porcentagem e massa acumulada das amostras (M1 e M2), conforme apresentado na Tabela 7.

Tabela 7 – Resultados dos ensaios de granulometria das amostras M1 e M2 de granulometria do agregado miúdo

Abertura das Peneiras	M1			M2		
	Massa retida (g)	Massa retida (%)	Massa Retida Acumulada (%)	Massa retida (g)	Massa retida (%)	Massa Retida Acumulada (%)
4,80	2,11	0,21	0,21	1,13	0,113	0,113
2,40	**22,87**	**2,29**	**2,50**	**26,25**	**2,625**	**2,738**
1,20	43,55	4,36	6,86	52,29	5,229	7,967
0,60	146,45	14,65	21,51	161,72	16,172	24,139
0,30	531,50	53,15	74,66	525,50	52,55	76,689
0,15	230,90	23,09	97,75	214,20	21,42	98,109
Fundo	22,60	2,26	100,00	18,90	1,89	100,00
Total	999,98		303,49	999,97		309,76

Neste trabalho foi calculada a dimensão máxima característico do agregado miúdo, conforme equação Eq. 4.1. O resultado foi de 2,40 mm e o módulo de finura da amostra M1 apresentou 3,04 mm, enquanto que, para à amostra M2 foi de 3,1 mm classificadas como areia grossa de acordo com a Tabela 6. A Figura 18 ilustra as curvas granulométricas das amostras M1 e M2:

Figura 18 – Curvas das amostras M1 e M2 de granulometria da areia grossa ABNT NBR NM 7211 (2009)

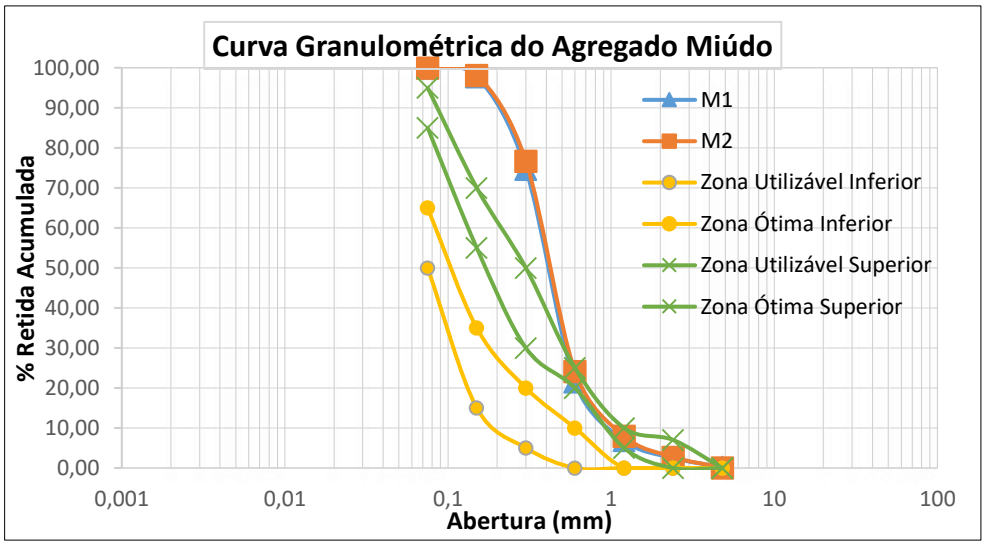

4.7 MÉTODO PARA DETERMINAÇÃO DE MASSA ESPECÍFICA E ABSORÇÃO DE ÁGUA DOS AGREGADOS MIÚDOS

Segundo a ABNT NBR NM 52 (2009), o ensaio para determinação massa especifica (g/cm³) do agregado miúdo é a realizada com a coleta de três amostras, com o peso de 500,00 gramas cada. Essas devem ser levadas até a estufa com temperatura média de (105 +-5)°C, e deixando no mínimo por 24 horas. É necessário que as amostras estejam totalmente secas. Estes agregados miúdos devem ser pesados na balança de precisão (erro = ± 0,1), e levados até o frasco de *Chapman* que deverá conter 200 cm³ de água. Os mesmos devem ser despejados com auxílio de um funil, e o frasco deve ser agitado com cuidado, para que possam ser retiradas as bolhas de ar da água e do agregado miúdo. Ao terminar o agitamento deixar o frasco em repouso por alguns minutos, até que possa realizar a leitura do frasco, conforme ilustrado na Figuras 19 (a) e (b).

Figura 19 – Modelo e leitura do frasco de Chapman

(a) (b)

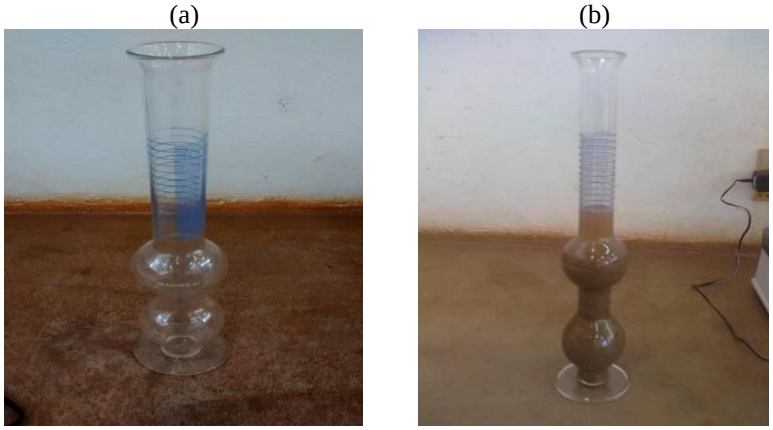

Fonte: Villa, 2012.

ABNT NBR NM 26 (2001), expõe a forma de determinar o valor da massa especifica (g/cm³) do agregado miúdo pela equação Eq. 4.2.

$$\gamma_a = \frac{500{,}00\ g}{L - 200\ cm^3} \qquad \text{[Eq. 4.2]}$$

Sendo que,

- γ_a - Massa específica do agregado miúdo (areia); expressa em g/cm³;
- L - Leitura do frasco de *Chapman* (volume ocupado pelo conjunto água - agregado miúdo).

Na Tabela 8 estão as leituras obtidas no frasco de *Chapman* e os valores das massas específicas de duas amostras do agregado miúdo.

Tabela 8 – Resultados de Leituras do frasco de *Chapman* e valores das massas específicas

Amostra (M1)		**Amostra (M2)**	
Leitura (L)	**Massa Específica (g/cm³)**	**Leitura (L)**	**Massa Específica (g/cm³)**
389 cm³	2,65 g/cm³	388 cm³	2,66 g/cm³

A ABNT NBR NM 53 (2009), trata do ensaio de absorção de água do agregado miúdo. As amostras devem ser levadas à estufa (105 $\pm$ 5) ºC para secagem. Este ensaio deve ser realizado em três amostras, com 1 kg cada, até que atinjam a consistência de massa (M_s).

Após a secagem, estas devem ser resfriadas em temperatura ambiente e, logo em seguida inseridas em três recipientes com água, ficando totalmente imersas no máximo por 24 horas. Passado o tempo de repouso, retira-se totalmente à água do recipiente, sem despejar nenhum dos grãos do agregado miúdo.

Coloca-se o agregado miúdo sobre uma bandeja e o espalha uniformemente para que uma suave corrente de ar quente possa secar os grãos. Deve ser realizada a verificação da amostra, regulamente, até que deixe de existir aderência entre os grãos. Em seguida, a amostra é despejada no molde do tronco de cone e, aplica-se 25 golpes com a haste de compactação (SILVEIRA, 2013).

Após aplicar os golpes retira-se a haste na vertical. Este processo é repetido em intervalos regulares até atingir o ponto de secagem, quando acontece o desmoronamento dos grãos. Em seguida é pesada novamente para obter o valor da massa do agregado na condição saturada seca (M_h). Na Figura 20, está ilustrado o ensaio do tronco de cone.

Figura 20 – Tronco de cone utilizado para teste de absorção da água no agregado miúdo

Fonte: Villa, 2012.

Então é obtido o valor da absorção de água dos agregados miúdos conforme a equação Eq. 4.3.

$$A = \frac{M_h - M_s}{M_s} \qquad \text{[Eq. 4.3]}$$

- A – Porcentagem de absorção de água;
- M_s – Peso em gramas da massa do agregado seco em estufa após resfriamento em temperatura ambiente;
- M_h - Peso em gramas da massa do agregado na condição saturada seca;

Devem ser respeitados os valores de aproximação de 0,1%, sendo que as amostras não devem diferir mais de 0,05%. Também, é recomendado o mesmo procedimento de ensaio para obter a absorção das outras duas amostras, pois serão aproveitadas somente duas que apresentaram melhor desempenho.

Na Tabela 9 tem-se os resultados do ensaio de absorção do agregado miúdo.

Tabela 9 – Resultados do ensaio de absorção do agregado miúdo

Amostra (M1)			**Amostra (M2)**		
M_h	**M_s**	**A**	**M_h**	**M_s**	**A**
1.000,00 (g)	1.060,00 (g)	6,0%	1.000,00 (g)	1.040,00 (g)	4,0%

4.8 MÉTODO DE ENSAIO DE GRANULOMETRIA DOS AGREGADOS GRAÚDOS

O ensaio de granulometria do agregado graúdo foi feito conforme ABNT NBR NM 7211 (2009). A Tabela 10 apresenta os valores retidos e acumulados em massa para duas amostras (M1 e M2) de basalto com diâmetro B0.

Tabela 10 – Resultados dos ensaios de granulometria das amostras M1 e M2 para as britas de basalto B0

Abertura das Peneiras	M1			M2		
	Massa retida (g)	**Massa retida (%)**	**Massa Retida Acumulada (%)**	**Massa retida (g)**	**Massa retida (%)**	**Massa Retida Acumulada (%)**
25,00	0,000	0,00	0,00	0,000	0,00	0,00
19,00	0,000	0,00	0,00	0,000	0,00	0,00
12,50	500,00	10,04	10,04	510,00	10,23	10,23
9,50	2.095,00	42,09	52,13	2.295,00	46,04	56,27
6,30	2.132,00	42,83	94,96	1.940,00	38,92	95,19
4,80	161,00	3,24	98,20	160,00	3,21	98,40
2,40	50,00	1,00	99,20	50,00	1,00	99,40
Fundo	40,00	0,80	100,00	30,00	0,60	100,00
Total	4.978,00			4.985,00		

Na primeira amostra M1, após realizar o agitamento mecânico somou-se as massas do jogo de abertura das peneiras, e a massa total foi de 4.978,00 gramas e um percentual de 0,44%. Enquanto que, na amostra M2 a massa foi de 4.985,00 gramas e um percentual de 0,30%.

As curvas granulométricas dos agregados graúdos de basalto (B0) são apresentadas na Figura 21.

Figura 21 – Curvas das amostras M1 e M2 de granulometria do basalto B0

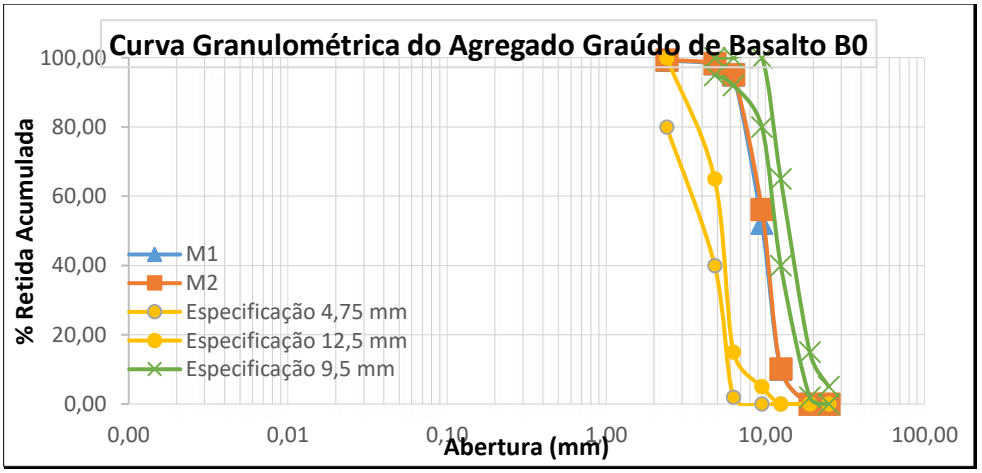

Na Tabela 11, estão apresentados os resultados dos ensaios de granulometria com agregados graúdos de basalto e diâmetro (B1). Realizou-se a soma das massas da amostra

M1 que resultou em 4.980,00 gramas e percentual de 0,40%. Na amostra M2 a massa foi de 4.985,00 gramas e percentual de 0,30%.

Tabela 11: Resultados dos ensaios de granulometria das amostras M1 e M2 para as britas de basalto B1

Abertura das Peneiras	M1			M2		
	Massa retida (g)	Massa retida (%)	Massa Retida Acumulada (%)	Massa retida (g)	Massa retida (%)	Massa Retida Acumulada (%)
25,00	0,00	0,00	0,00	0,00	0,00	0,00
19,00	49,00	0,98	0,98	40,00	0,80	0,80
12,50	4.797,00	96,33	97,31	4.800,00	96,29	97,09
9,50	129,00	2,59	99,90	145,00	2,91	100,00
6,30	5,00	0,10	100,00	0,00	0,00	100,00
4,80	0,00	0,00	100,00	0,00	0,00	100,00
2,40	0,00	0,00	100,00	0,00	0,00	100,00
Total	4.980,00			4.985,00		

Na Figura 22, estão ilustradas as curvas granulométricas para estas amostras, M1 e M2.

Figura 22 - Curvas das amostras M1 e M2 de granulometria do basalto B1

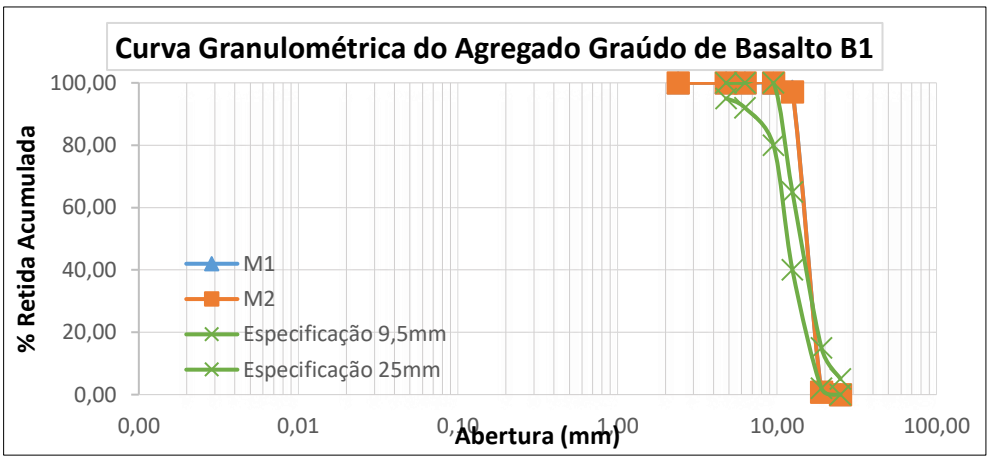

Na amostra M1 encontrou-se 4.970,00 gramas atingindo o percentual de 0,60%, e na amostra M2 a massa foi de 4.980,00 gramas e um percentual de 0,40%.

Na Tabela 12 e Figura 23, se observa a distribuição granulométrica das britas de granito, com diâmetro B0.

Tabela 12 – Resultados dos ensaios de granulometria das amostras M1 e M2 para as britas de granito B0

Abertura das Peneiras	M1			M2		
	Massa retida (g)	**Massa retida (%)**	**Massa Retida Acumulada (%)**	**Massa retida (g)**	**Massa retida (%)**	**Massa Retida Acumulada (%)**
25,00	0,00	0,00	0,00	0,000	0,00	0,00
19,00	40,00	0,80	0,80	10,00	0,20	0,20
12,50	1.600,00	32,19	32,99	1.540,00	30,92	31,12
9,50	730,00	14,69	47,68	740,00	14,86	45,98
6,30	1.240,00	24,95	72,63	1.240,00	24,90	70,88
4,80	900,00	18,11	90,74	900,00	18,07	88,95
2,40	430,00	8,66	99,40	520,00	10,44	99,39
Fundo	30,00	0,60	100,00	30,00	0,61	100,00
Total	**4.970,00**			**4.980,00**		

Figura 23 – Curvas das amostras M1 e M2 de granulometria do granito B0 - ABNT NBR NM 7211 (2009)

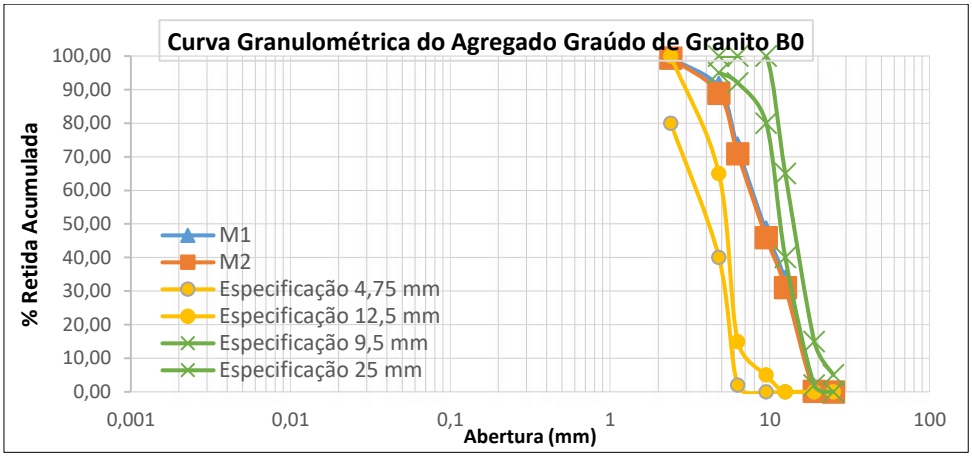

Na Tabela 13, se observa os resultados da amostra M1 de 4.970,00 gramas e o percentual de 0,60%. Enquanto que, a amostra M2 apresentou a soma de massa de 4.980,00 gramas e um percentual de 0,40%.

Tabela 13 – Resultados dos ensaios de granulometria das amostras M1 e M2 para as britas de granito B1

Abertura das Peneiras	M1			M2		
	Massa retida (g)	**Massa retida (%)**	**Massa Retida Acumulada (%)**	**Massa retida (g)**	**Massa retida (%)**	**Massa Retida Acumulada (%)**
25,00	20,00	0,40	0,40	0,00	0,00	0,00
19,00	2.590,00	52,11	52,51	2.610,00	52,41	52,41
12,50	1.500,00	30,18	82,69	1.500,00	30,12	82,53
9,50	360,00	7,24	89,93	360,00	7,23	89,76
6,30	380,00	7,65	97,58	390,00	7,83	97,59
4,80	50,00	1,00	98,58	50,00	1,00	98,59
2,40	30,00	0,61	99,19	50,00	1,00	99,59
Fundo	40,00	0,81	100,00	20,00	0,41	100,00
Total	**4.970,00**			**4.980,00**		

Na Figura 24, são ilustradas as curvas granulométricas das britas de granito e diâmetro B1.

Figura 24 – Curvas das amostras M1 e M2 de granulometria do granito B1 ABNT NBR NM 7211 (2009)

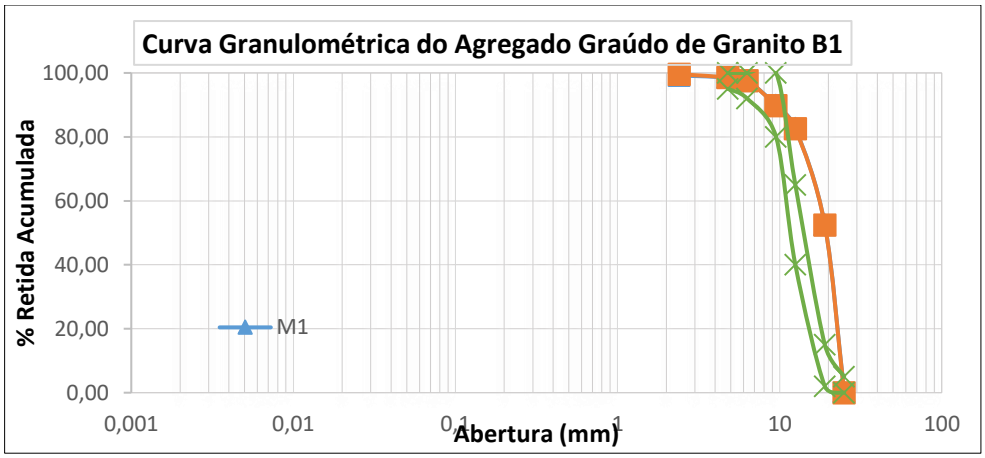

Os resultados apresentados na Tabela 14, são referentes a soma de massa da amostra M1 de 4.970,00 gramas e o percentual de 0,60%. Enquanto que, na amostra M2 a soma foi de 4.980,00 gramas e um percentual de 0,40%.

Tabela 14 – Resultados dos ensaios de granulometria das amostras M1 e M2 das britas de seixo-rolado B1

Abertura das Peneiras	M1			M2		
	Massa retida (g)	**Massa retida (%)**	**Massa Retida Acumulada (%)**	**Massa retida (g)**	**Massa retida (%)**	**Massa Retida Acumulada (%)**
25,00	0,0000	0,00	0,00	0,0000	0,00	0,00
19,00	0,0000	0,00	0,00	0,0490	0,99	0,98
12,50	1,0600	21,24	21,24	4,7970	96,36	97,35
9,50	1,7100	34,27	55,51	0,1290	2,59	99,93
6,30	1,2350	24,75	80,26	0,0005	0,01	99,94
4,80	0,5100	10,22	90,48	0,0000	0,00	100,00
2,40	0,4050	8,12	98,60	0,0000	0,00	100,00
Fundo	0,0700	1,40	100,00	0,0000	0,00	100,00
Total	**4,9900**	100,00		**4,9800**	100,00	

Na Figura 25, são ilustrados os resultados dos ensaios da curva de granulometria das britas B1 de granito:

Figura 25 – Curvas das amostras M1 e M2 de granulometria do seixo rolado B1 - ABNT NBR NM 7211 (2009)

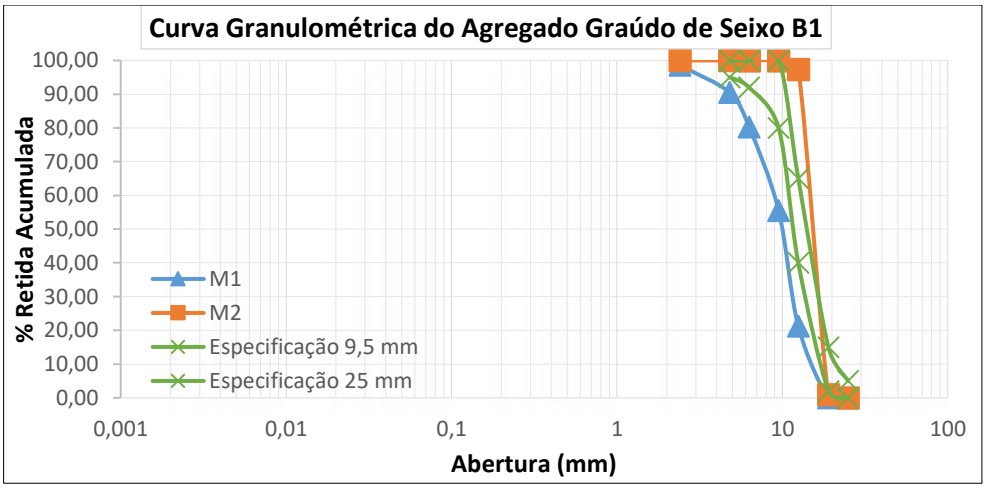

4.9 MÉTODO PARA DETERMINAÇÃO DE MASSA ESPECÍFICA DOS AGREGADOS GRAÚDOS

ABNT NBR NM 52 (2009), trata da realização do ensaio para encontrar a massa especifica (g/cm³) dos agregados graúdos.

Segundo a norma ABNT NBR NM 52 (2009), as amostras devem ser levadas junto à peneira de abertura 4,75 mm e lavadas com água para retirada do pó sobre a superfície

do agregado graúdo. Logo após, devem ser colocadas em bandeja e levadas à estufa (105 ± 5)°C para secarem por 24 horas.

O material seco deve ser retirado e resfriado em temperatura ambiente, em seguida colocado submerso em um balde com água para deixar em repouso por mais 24 horas.

O material mergulhado no balde deve ser retirado e colocado sobre um tecido absorvente. Em seguida, deve enxugar com muito cuidado, sem evaporar a água dos poros da amostra. Mede-se então, a massa na balança de precisão, na condição de agregado saturado com superfície seca (M_h).

Após a determinação da massa, esta amostra é colocada em recipiente vazado e imerso em um balde d'água com temperatura de (24 ± 2) ºC.

O recipiente com os agregados graúdos não deve encostar-se à base, para possa obter a leitura da balança (L) dos agregados imersos na água.

Novamente estas amostras são levadas diretamente à estufa para secarem em temperatura de (105 ± 5) ºC. Estando totalmente secas, ambas as amostras devem ser retiradas para esfriar à temperatura ambiente. Logo após, realiza-se a leitura da massa do agregado na condição de agregado seco em estufa (M_s).

Nos ensaios de densidade foram coletadas duas amostras, a fim de obter o resultado da massa específica das britas de basalto, granito e seixo rolado para isso foram utilizadas as equações Eq. 4.4 e 4.5, cujos valores podem ser vistos na Tabela 15.

Tabela 15 – Resultados dos ensaios para obtenção de massas específicas dos agregados graúdos

Ensaios de Massa Específica dos Agregados Graúdos						
	Amostra (M1)			**Amostra (M2)**		
Dimensão (B0)	**Basalto**	**Granito**	**Seixo Rolado**	**Basalto**	**Granito**	**Seixo Rolado**
M_s (g)	4.960,00	4.970,00	0	4.985,00	4.980,00	0
M_h (g)	4.992,00	5.122,24	0	4.995,00	5.110,00	0
L (g)	3.247,30	3.194,21	0	3.220,30	3.119,00	0
γ_{b0} (g/cm³)	2,84	2,58	0	2,81	2,50	0
Dimensão (B1)	**Basalto**	**Granito**	**Seixo-Rolado**	**Basalto**	**Granito**	**Seixo-Rolado**
M_s (g)	4.980,00	4.970,00	4.980,00	4.985,00	4.980,00	0
M_h (g)	5040,00	5.100,00	5.936,00	4.995,00	5.153,50	0
L (g)	3.200,70	3.125,00	4.157,00	3.253,80	3.154,30	0
γ_{b1} (g/cm³)	2,71	2,52	2,80	2,86	2.49	0

Neste trabalho, para as britas de basalto com dimensões B0 e B1, foi adotado a massa específica para brita B0 de 2,84 g/cm³, enquanto que, a dimensão B1 utilizou-se 2,86

g/cm³. Para as britas de granito com dimensões B0 e B1, também, foi adotado os valores da dimensão B0 de 2,50 g/cm³ e 2,52 g/cm³, respectivamente. Já as britas de seixo rolado com dimensão B1 utilizou a massa específica de 2,80 g/cm³.

4.10 MÉTODO PARA DETERMINAÇÃO DA ABSORÇÃO DOS AGREGADOS GRAÚDOS

ABNT NBR NM 53 (2009), discorre da realização do cálculo que consiste em obter a absorção de água (A) das amostras dos agregados graúdos, de acordo com a equação Eq. 4.6. Para isto, é obtida a massa em gramas do agregado seco em estufa (M_s) e a massa em gramas do agregado na condição saturada seca (M_h).

$$A = \frac{M_h - M_s}{M_s} \qquad \text{[Eq. 4.6]}$$

- A – Porcentagem de absorção de água;
- M_s – Peso em gramas da massa do agregado seco em estufa após resfriamento em temperatura ambiente;
- M_h – Peso em gramas da massa do agregado na condição saturada seca;

O valor de aproximação é de 0,1%, e não deve diferir mais de 0,05%, segundo é recomendado pela norma ABNT NBR NM 53 (2009).

Para os agregados graúdos de basalto, granito e seixo rolado, com dimensões B0 e B1, foram medidas, em duas amostras M1 e M2, a massa seca em estufa (M_s) e na condição saturada e superfície seca (M_h), conforme se observa na Tabela 16. Isso foi feito para cada material e dimensão.

Tabela 16 – Resultados dos ensaios para obtenção de massas específicas dos agregados graúdos

Resultados de Absorção de Água dos Agregados Graúdos						
	Amostra (M1)			**Amostra (M2)**		
Dimensão (B0)	**Basalto**	**Granito**	**Seixo Rolado**	**Basalto**	**Granito**	**Seixo Rolado**
M_s (g)	4.970,00	4.970,00	0	4.985,00	4.980,00	0
M_h (g)	5.020,00	5.000,00	0	5.021,00	5.000,00	0
A (%)	0,90	0,60	0	0,72	0,40	0
Dimensão (B1)	**Basalto**	**Granito**	**Seixo Rolado**	**Basalto**	**Granito**	**Seixo Rolado**
M_s (g)	4.980,00	4.970,00	4.980,00	4.985,00	4.980,00	0
M_h (g)	5.015,00	5.000,00	5.000,00	4.995,00	5.000,00	0
A (%)	0,70	0,60	0,40	0,20	0,40	0

A absorção de água dos agregados graúdos, britas de basalto, granito e seixo rolado, com dimensões B0 e B1, foram calculadas de acordo com a equação Eq. 4.6

4.11 MÉTODO PARA DETERMINAÇÃO DAS RELAÇÕES DOS AGREGADOS GRAÚDOS (B1/B0)

Helene e Terzian (1993), tratam das relações que os diâmetros dos agregados graúdos devem possuir, com a utilização de um método empírico simples.

A princípio este ensaio é realizado em um recipiente de volume conhecido. Coloca-se a quantidade da maior brita, até aproximadamente 33% do volume do recipiente, e aplica-se 25 golpes com o soquete, para que haja uma compactação dos agregados. Após esta primeira compactação, acrescenta mais brita até 66% do volume do recipiente e repetem os 25 golpes. Na terceira etapa preenche o recipiente até a borda e novamente aplica 25 golpes. Ao final deve ser rasada a borda do recipiente e pesada a quantidade inicial (100% de brita B1).

Retira-se a brita do recipiente, acrescenta 10% em massa da menor brita e mistura. Repete-se o processo de acrescentar o material no recipiente e compactá-lo do mesmo modo como foi feito para a brita maior antes da mistura. Novamente mede-se a massa da mistura. Retira essa mistura do recipiente e acrescenta a brita menor até atingir 20% em massa da menor brita. Repete-se todo o processo novamente até que a massa comece a apresentar queda. Após a queda da massa repete o processo para confirmar. A maior massa medida é a relação ideal de brita.

A Figura 26 ilustra o recipiente usado no presente trabalho para medir a relação ideal de B1/B0 e a Tabela 17 apresenta os valores em massa. A mistura de diferentes

tamanhos de britas acarretou em aumento da massa, pois a brita menor preenche os espaços vazios. Este aumento ocorre até que a brita menor comece a ocupar o espaço da brita maior e aumente novamente os vazios da mistura. Para obter o valor da massa unitária do estado compactado, divide a massa total do recipiente, descontando a tará e, dividido pelo volume.

Figura 26 – Recipiente cilíndrico e soquete metálico para compactação

Fonte: Villa, 2012.

Tabela 17 – Valores encontrados da relação brita B1 e B0 (Helene e Terzian, 1993)

Brita 1 / Brita 0 (% / %)	Brita 1 (Kg)	Brita 0 (Kg)	Mistura no Cilindro (Kg)
100 / 0	2,52	0	2,96
88,25 / 11,75	2,52	0,33	2,98
80 / 20	2,52	0,63	2,99
70 / 30	2,52	1,08	3,05
60 / 40	2,52	1,68	3,02
65 / 35 (Verificação)	2,52	1,36	2,95

4.12 MÉTODO DE ENSAIO PARA DOSAGEM DE CONCRETO

Helene e Terzian (1993), obtiveram diagramas de dosagem, para vários cimentos, usando as três dosagens (pobre, médio e rico), conforme ilustrado na Figura 27.

Figura 27 – Exemplo do diagrama de dosagem (Helene e Terzian, 1993)

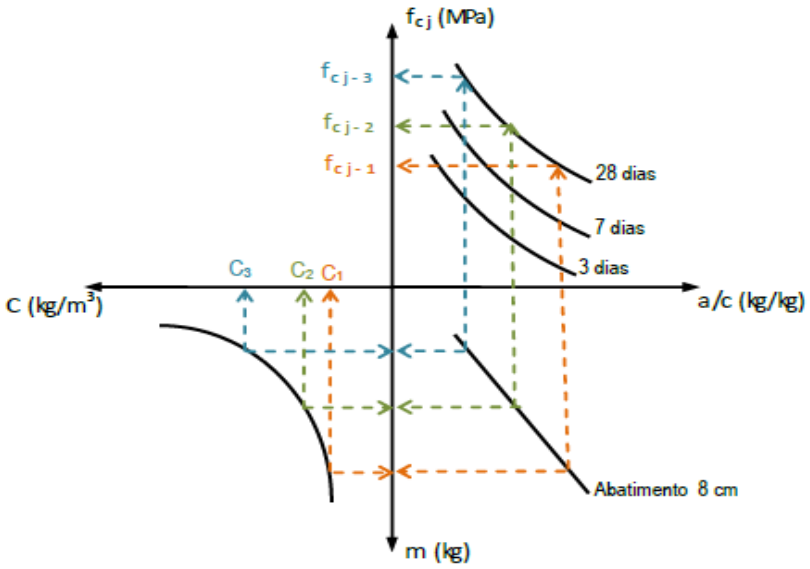

Fonte: Moretti, 2010.

Na Figura 27, o diagrama de dosagem (comportamento) é referente as equações Eq. 4.7, 4.8 e 4.9, das leis de Abrams, Lyse e Molinari.

$$f_{cj} = \frac{k_1}{k_2^{a/c}} \qquad \text{[Eq. 4.7]}$$

$$m = k_3 + k_4 \times a/c \qquad \text{[Eq. 4.8]}$$

$$C = \frac{1000}{(k_5 + k_6 \times m)} \qquad \text{[Eq. 4.9]}$$

Onde:

f_{cj} – resistência à compressão axial, à idade j, em MPa;

a/c – relação água/cimento em massa, em kg/kg.

a – relação do agregado miúdo seco/cimento em massa, em kg/kg;

m – relação agregados secos/cimento em massa, em kg/kg;

k_1, k_2, k_3, k_4, k_5 e k_6 – constantes que dependem exclusivamente dos materiais (cimento, agregados miúdos, agregados graúdos e aditivos).

A fim de obter um diagrama de dosagem, conforme apresentado na Figura 27, deve-se confeccionar o concreto com vários teores de argamassa para a obtenção de um teor ideal (α). Inicia os ensaios com 35% de argamassa e eleva-se o mesmo até o teor de argamassa ideal (α) para confecção do concreto. Isto é feito, acrescentando a massa (kg) de agregados miúdos, cimento e água, sem aumentar a massa dos agregados graúdos. O aumento de argamassa se dá experimentalmente, até que o concreto esteja coeso e liso (sem buracos).

O processo de ensaio consiste primeiramente na confecção do traço 1:5,0 (médio), a fim de encontrar o teor de argamassa ideal (α). Após o término do ensaio, devem ser ensaiadas as demais dosagens 1:3,5 (rico) e 1:6,5 (pobre), com a mesma utilização do teor ideal do concreto 1:5,0 (médio).

Para calcular a quantidade em massa (kg) do cimento é utilizada a equação Eq. 4.10, que é o cálculo correspondente ao consumo em massa de cimento por m³ de concreto referente a lei de Molinari.

$$C = \frac{1000 - Ar}{\left(\frac{1}{\gamma_c} + \frac{a}{\gamma_a} + \frac{b}{\gamma_b} + {}^{a}/_{c}\right)} \qquad \text{[Eq. 4.10]}$$

Onde:

C – consumo de cimento por metro cúbico de concreto adensado em kg/m³;

Ar – teor de ar incorporado e/ou aprisionado por metro cúbico, em dm³/dm³;

a – relação do agregado miúdo seco/cimento em massa, em kg/kg;

b – relação do agregado graúdo seco/cimento em massa, em kg/kg;

γ_c – massa específica do cimento em kg/m³;

γ_a – massa específica do agregado miúdo em kg/m³;

γ_b – massa específica do agregado graúdo em kg/m³;

a/c – Relação água/cimento em massa, em kg/kg.

A quantidade em massa do agregado miúdo é calculada com a equação Eq. 4.11.

$$Ca = a * C \qquad \text{[Eq. 4.11]}$$

Onde:

Ca – consumo em massa de agregado miúdo (kg/m³).

O consumo em massa de britas (kg) é obtido através da equação Eq. 4.12, onde tem massa constante:

$$Cb = b * C \qquad \text{[Eq. 4.12]}$$

Onde:

Cb – Consumo em massa de agregado graúdo (kg/m³).

A quantidade de água é calculada conforme a equação Eq. 4.13.

$$C_{água} = a/c * C \qquad \text{[Eq. 4.13]}$$

Onde:

$C_{água}$ – Consumo em massa de água (kg/m³).

4.13 MÉTODO DA CONSISTÊNCIA PELO ABATIMENTO DO TRONCO DE CONE

ABNT NBR NM 67 (1998) trata do ensaio para obtenção da trabalhabilidade do concreto no estado fresco. Esta é a forma de apresentar a consistência através de uma média numérica, realizando ensaios de abatimentos com os equipamentos como placa metálica rígida e plana (com 500 mm), molde tronco-cônico (com diâmetro de 200 mm, base superior de 100 mm e altura de 300 mm com tolerância de 2 mm), conforme é ilustrado na Figura 28.

Figura 28 – Molde de tronco-cônico

Fonte: Villa, 2012.

Ao ensaiar o concreto se deve umedecer todos os equipamentos que serão utilizados na confecção, inclusive a betoneira.

Todos os materiais como britas, areia e cimento, devem ser despejados com muito cuidado na betoneira e agitado mecanicamente. A água deve ser despejada na betoneira, aos poucos, com os agregados e o cimento sendo agitados. Durante o agitamento deve-se fixar um tempo de 5 minutos até que haja homogeneidade no concreto. Após o agitamento, deve ser verificada a consistência do concreto com a colher, onde é necessário rasar com a colher na base superficial do concreto para verificar a coesão, ou seja, o efeito ligante da argamassa com os agregados graúdos. Neste procedimento deve ser analisada a coesão da consistência do concreto, conforme ilustra a Figura 29.

Figura 29 – Verificação da coesão do concreto fresco

Fonte: Enio José Bolognini

O abatimento é realizado primeiramente colocando 33% do concreto no cone, então aplica-se 25 golpes com a haste, a fim de compactar todos os espaços vazios. Este procedimento deve ser aplicado a um nível de 66% do cone e repete-se a compactação. Ao final deve ser colocado até a cavidade superior do funil e repetir os 25 golpes.

Antes de o cone deve-se rasar a cavidade superior, a fim de encontrar o abatimento. O tronco-cônico deve ser posicionado ao lado do concreto, para medir a diferença de altura do molde com a altura do concreto. Devem-se obter medidas em três locais diferentes, a fim de e realizar a média aritmética do abatimento. Entretanto, se ao retirar o cone o abatimento não estiver de acordo com o desejado, é necessário acrescentar mais água ou bater o concreto novamente com menor quantidade de água.

4.14 MÉTODO DE ENSAIO PARA MOLDAGEM, CURA E CAPEAMENTO

A ABNT NM NBR 5738 (2003), trata da moldagem dos corpos de prova, após realização do abatimento.

Para moldar os concretos é necessário colocá-lo em formas e vibrar, a fim de espalhar na forma e retirar o ar do concreto. Os corpos de prova não devem vibrar por muito tempo, pois pode ocorrer segregação do concreto. Após o concreto ser levado à mesa vibratória, os corpos de prova devem ficar em local protegido até que haja o tempo de pega. Passados um mínimo de 24 horas, os corpos de prova deverão ser desenformados.

Cada corpo de prova deve ser identificado por um número, nome, traço, tipo de concreto e a data de ruptura. Após a identificação, estes devem ser deixados em câmara úmida com temperatura média de (23 ± 2) ºC e, umidade relativa do ar acima de 95%.

Nos primeiros 7 dias, foram retirados da câmara úmida quatro exemplares (cp1, cp2, cp3 e cp4), para serem levados e capeados com enxofre. Na Figura 30 ilustra-se a panela com enxofre. Esta deve estar com temperatura média de 50 a 150° C.

Nas Figuras 30 (a) e (b), pode observar a coleta do enxofre com a concha e a colocação na base de capeamento. Em seguida o corpo de prova é posicionado no centro da base com enxofre derretido e espera-se até que resfrie. Então, retira-se o corpo-de-prova da base de capeamento com auxílio de um martelo. Este processo deve repetido com os demais corpos de prova.

Figura 30 – Ensaio do capeamento por enxofre dos corpos de prova

(a) (b)

Fonte: Enio José Bolognini

Os cilindros da forma para preparação dos corpos de prova, que foram usados neste trabalho, tiveram as medidas nominais de 10 cm de diâmetro e 20 cm de altura, sendo que o interior de cada forma foi untado com óleo, em seguida o concreto foi colocado cuidadosamente em cada cilindro.

4.15 PESQUISA EXPERIMENTAL

Os ensaios tiverem a finalidade de criar uma base de dados para um aplicativo capaz analisar e devolver informações precisas em tempo real. Este aplicativo deve ser capaz de armazenar as resistências à compressão e fornecer a dosagem inicial do concreto em massa, em um intervalo de tempo rápido com economia de materiais.

As realizações dos ensaios foram consideradas com as quantidades em massa de cimento, areia, britas (de mesmo um lote) e água, a fim de confeccionar corpos de prova de concreto para ruptura aos 7, 28 e 91 dias. Durante a confecção foram analisados os abatimentos, cura e tempo de ruptura, com objetivo de encontrar resultados satisfatórios em resistência à compressão axial.

Os tipos de agregados graúdos utilizados, como: basalto, granito, e seixo-rolado, foram definidos e variados com diferentes tipos de cimento.

4.16 METODOLOGIA DE TREINAMENTO PARA REDES NEURAIS ARTIFICIAIS

Neste trabalho, foram realizados modelos de redes neurais *feedforward* com três e quatro camadas do algoritmo *backpropagation*, para que esta rede pudesse treinar os resultados das resistências à compressão. Com este treinamento da rede será possível obter o traço unitário em massa de concreto.

Este planejamento pôde contar com um armazenamento por sistema de gerenciamento para bancos de dados (SGBD), sendo programados com o *MySq*l (*ORACLE Corporation*), para tabelas relacionais.

A saída da rede neural foi uma prioridade para automatizar a confecção de concreto, sendo: uma rede de nove entradas de neurônios na camada um, dez neurônios na camada dois e quatro neurônios na saída da camada três.

Foram realizados testes com valores de entrada das resistências à compressão. As saídas dos valores foram em massas, para cimento, areia, britas e água, sendo que estes valores foram normalizados e desnormalizados, de acordo com a regra do qui-quadrado (Eq. 2.1). A Figura 31 ilustra o modelo desenvolvido para obter a resistência à compressão do concreto.

Figura 31 – Rede Neural Artificial com Quatro Camadas entre quatro entrada, duas camadas intermediárias e uma saída

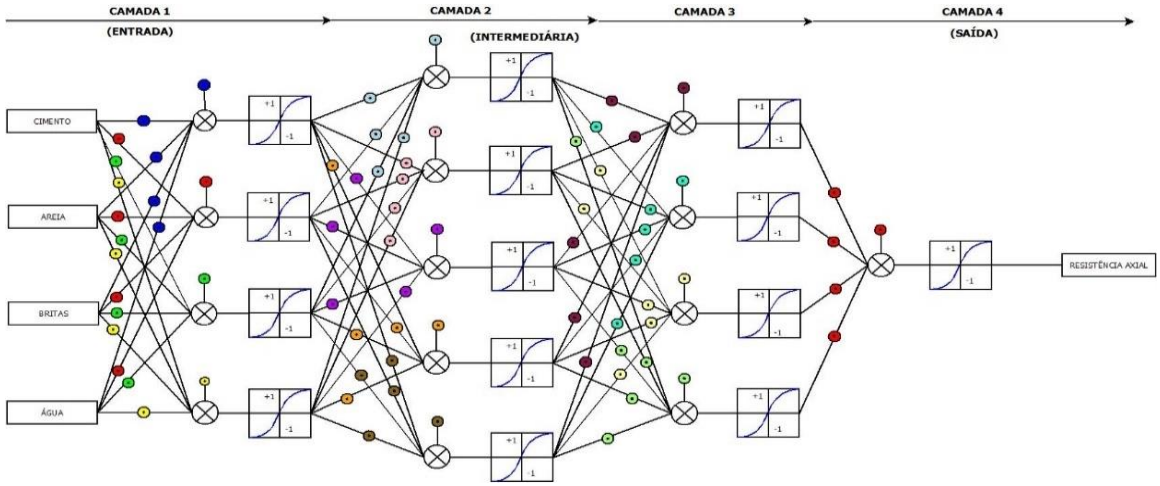

Fonte: Enio José Bolognini (*Software* Dia 0.97.2)

O modelo, ilustrado da Figura 31, refere-se ao primeiro treinamento da rede para a obtenção do traço de concreto. Conforme se observa na Figura 31, os dados de entrada foram as quantidades de material em massa e o dado de saída a resistência. Após treinar a rede desta forma, a mesma foi invertida para que as saídas pudessem devolver os resultados em massa do traço de concreto.

Na Figura 32 está ilustrado o modelo que simula a rede com três neurônios de entrada na camada um, quatro neurônios na camada dois e quatro neurônios de saída na camada três. Esta foi a rede aplicada no presente trabalho.

Figura 32 – Rede neural artificial com três camadas

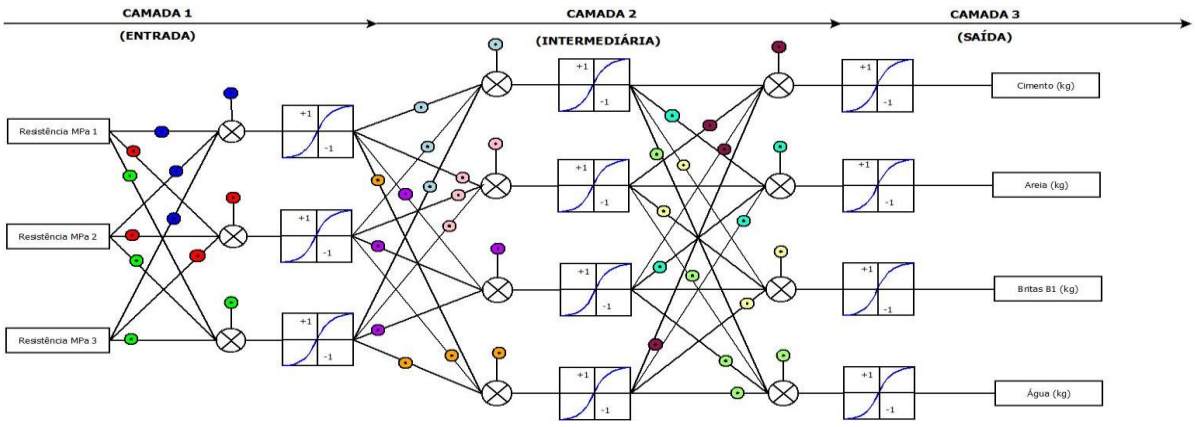

Fonte: Enio José Bolognini (*Software Dia 0.97.2*)

4.17 ELABORAÇÃO DA REDE NEURAL E REALIZAÇÃO DE TESTES

Para se obter as matrizes de pesos, que devem ser preenchidas por função aleatória, a fim de atualizar dados entre $[0, +1]$ ou [-1, +1], foram fornecidas como entradas os valores de saída do traço do concreto em massa como: cimento, areia, britas e água e, foram desenvolvidos os vetores de entrada definidos por $X_i = [x_{11} \quad x_{12} \quad x_{13} \quad x_{14}]$. Os quais foram calculados com as matrizes de pesos, gerando a soma dos vetores para as funções de ativação.

As equações algébricas do algoritmo genético de retropropagação (*backpropagation*), seguirão o padrão desenvolvido por Minussi e Lotufo (2007), apresentadas no anexo I.

Em um primeiro teste, realizado para este algoritmo de retropropagação (*backpropagation*), foi programada uma rede com quatro camadas. Esta rede teve quatro neurônios de entrada na camada um, cinco neurônios na camada intermediária dois, quatro neurônios na camada intermediária três e um neurônio de saída na camada quatro. Foram aplicados os seguintes valores de taxas: inclinação (λ) em 0,2, treinamento (α) em 0,5 e momento (η) em 0,68. Também, contou com um erro (ξ) mínimo de 0,01, testando a rede em 300.000 ciclos, com as equações Eq. 2.5, 2.8 e 2.12.

4.18 MÉTODO PARA DESENVOLVIMENTO COMPUTACIONAL

O desenvolvimento de um *software* aplicativo, para que possa armazenar dados de resistências à compressão, permite administrar treinamentos do algoritmo genético *feedforward* e automatizar confecções de concreto. Este aplicativo utiliza-se de dados armazenados para confecção de concreto e a partir destes faz um treinamento na rede neural, para obter o teor de argamassa e o traço unitário de concreto em massa.

Este *software* contém as entradas do algoritmo genético (*feedforward*), podendo ser somadas as opções de escolha do usuário. Este deve fornecer a dosagem de concretos convencionais (CC) e de alta resistência (CAR). Nas entradas ficam disponíveis as resistências à compressão, pois estas estão armazenadas no banco de dados (SGBD). Enquanto que os valores de saída apresentam o teor de argamassa ideal e o traço unitário expressos em massa de cimento, areia, britas B1, britas B0, água, e a relação água/cimento (a/c).

Para estruturar esta rede neural, foi necessário desenvolver funções de matrizes dinâmicas, para utilizar uma linguagem de programação que também, possa

desenvolver o aplicativo e manipular os dados. Foi gerado um gráfico UML (*Unified Modeling Language*) para apresentar o funcionamento resultante do traço de concreto no *software*.

A orientação a objetos (OO) serve para desenvolver uma engenharia de *software*, sendo comum a programação de modelos para interfaces utilizando técnicas computacionais, a fim de garantir a qualidade e segurança do *software*. Entretanto, este método é recomendado para desenvolvimento comercial e, não é muito recomendado utilizar métodos comerciais em pesquisa e desenvolvimento. O mais apropriado para programar este aplicativo é utilizar o modelo de dados orientados a objetos (MDOO). Esta orientação pode utilizar a pesquisa científica na engenharia, para que usuários (leigos) possam desfrutar de ferramentais visuais acessíveis.

Para elaboração de um *software*, deve ser utilizado um método relacional, para analisar os requisitos e estruturar o desenvolvimento deste aplicativo.

O programador pode determinar o *design* nos campos de resposta, com botões, campos de escolha e texto. Esta programação foi realizada nas opções que o usuário necessita para executar quando escolhido, digitado e executado, obtendo respostas do *software*. Este aplicativo é programado de acordo com uma pesquisa experimental, onde foram obtidas as resistências à compressão dos concretos. Os treinamentos determinados com o algoritmo genético *feedforward*, com as resistências, podem obter a precisão de resposta da saída. Outra, é a influencia no tempo de resposta do *software*, para que as classes programadas sejam ligadas de acordo com a estrutura das funções do *software*.

Estas redes foram programadas com um ambiente gráfico que utiliza modelo de dados orientados a objetos (MDOO). Esta modelagem, foi considerada uma engenharia de *software* que, tem uso de métodos dos modelos entidade relacionamento (MER) e programação orientada a objetos (OOP). Nesta programação do *software*, foram utilizadas a IDE's *Java Netbeans* e do sistema de gerenciamento de banco de dados (SGBD) *MySql (Oracle Corporation)*.

O usuário pode escolher o tamanho da rede, com quantas camadas e vetores que se deseja treinar. Pode-se aumentar ou diminuir a quantidade de neurônios, incluindo a escolha das taxas para uma certa quantidade de ciclos, conforme ilustradas na Tabela 18.

Tabela 18 – Parâmetros de taxas da rede neural *feedforward*

Parâmetros de Taxas da Rede Neural *Feedforward*	
Taxa	**Variável**
Aprendizagem	α
Erro	η
Inclinação	λ
Momento	ξ

Esta múltipla escolha, pode gerar concreto convencional (CC) e de alta resistência (CAR), podendo variar os tipos de cimento e agregados graúdos com diâmetros (B1 e B0). O usuário deve apenas digitar a quantidade em volume de concreto e a resistência inicial.

4.19 ELABORAÇÃO DO SOFTWARE DECCONCRETO COM A REDE NEURAL

A programação do *software* aplicativo foi possível com o ajuda do diagrama relacional para modelo de dados orientados a objetos (MDOO), pois é um padrão conhecido como a linguagem unificada de modelagem *(Unified Modeling Language - UML)*. Nesta programação foram criados diagramas de atividades, conforme a Figura 33, a fim de mapear as realizações dos cadastros de confecções de concretos para encontrar o traço unitário em massa.

Figura 33 – Diagrama de atividades do *software* DECCONCRETO

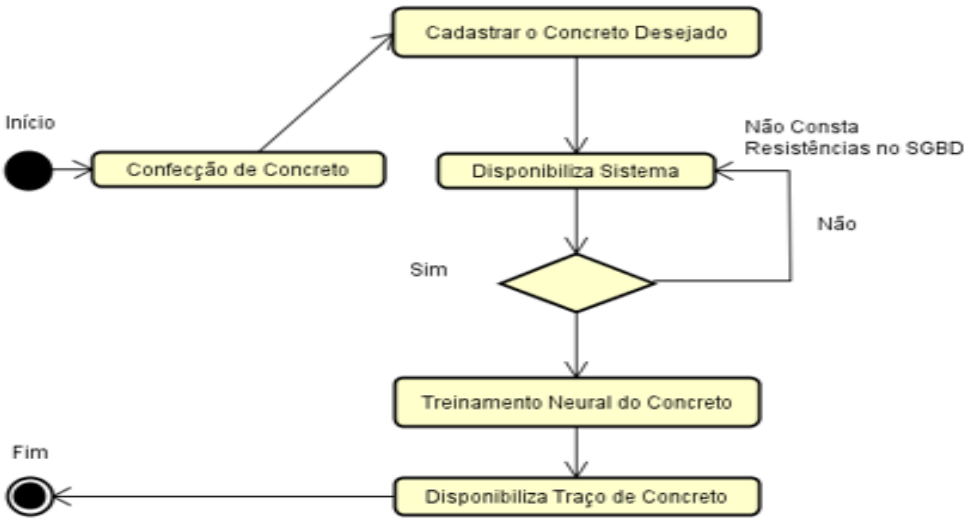

Fonte: Enio José Bolognini (*Activity Diagram – Astah Comunity Freeware*)

O diagrama de atividades, da Figura 33, foi o início para desenvolver o *software* aplicativo DECCONCRETO 1.0. Neste mapeamento pode-se notar os controles do administrador e do usuário ilustrados no diagrama de casos, conforme mostra a Figura 34:

Figura 34 – Diagrama de casos do *software* DECCONCRETO

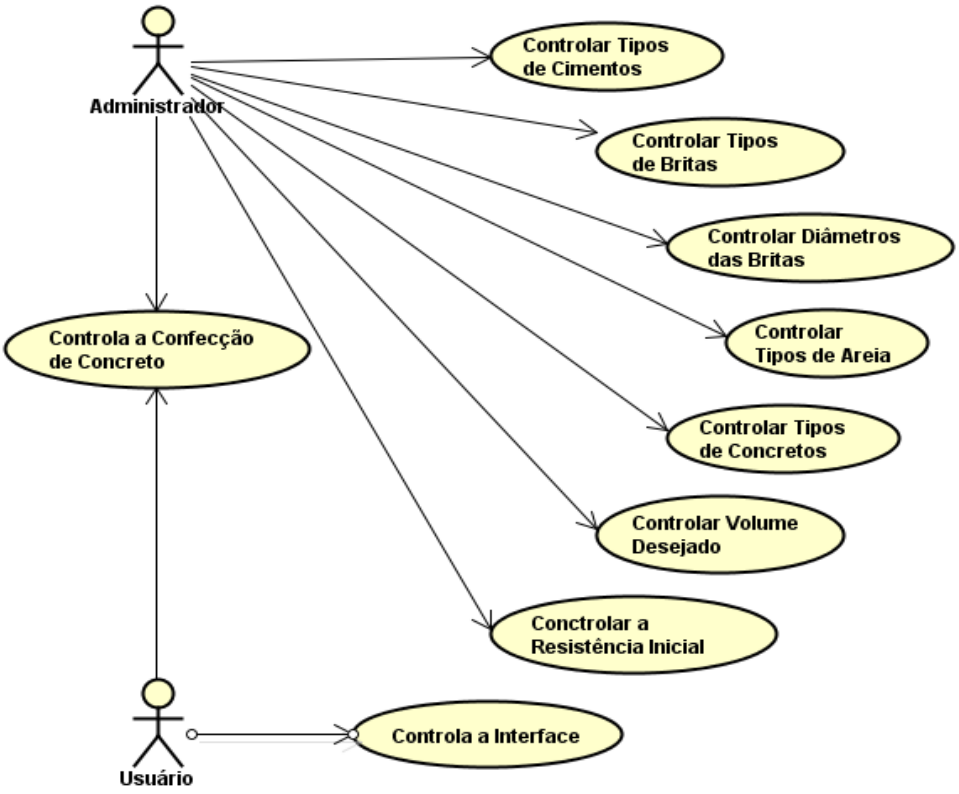

Fonte: Enio José Bolognini (*UseCase Diagram – Astah Comunity Freeware*)

O mapeamento de um *software* também é considerado um diagrama de classes. Neste diagrama, conforme ilustrado na Figura 35, foi possível mapear a estrutura do *software* aplicativo, para demonstrar os relacionamentos de comunicação entre funções de classes e objetos do *software* aplicativo DECCONCRETO 1.0.

Figura 35 – Diagrama de classes do *software* DECCONCRETO

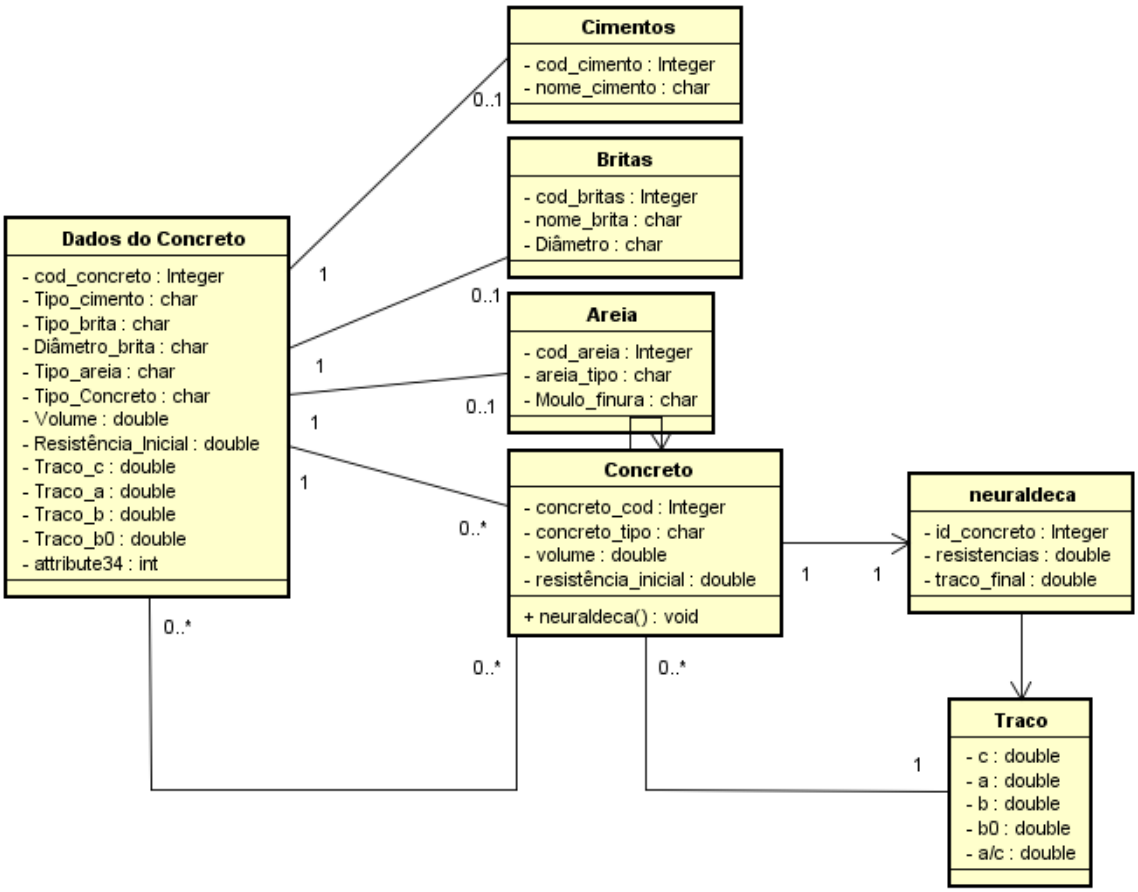

Fonte: Enio José Bolognini (*Class Diagram – Astah Comunity Freeware*)

4.20 ELABORAÇÃO DE INTERFACES

Para programar uma interface gráfica, foi necessário adquirir os requisitos de sistema através do usuário. De acordo com a engenharia de *software*, estes requisitos ajudaram a programar o *software* aplicativo DECCONCRETO 1.0, conforme a ilustra a Figura 36.

Figura 36 – *Software* DECCONCRETO

Fonte: Enio José Bolognini

Esta interface é composta por *menus* de controle de acessos:

- Dosagem por RNA (Cadastro, Consulta, Dosagem, Relatórios e Sair);
- Ensaios Inteligentes (RNA e Consulta);
- Sobre (Autoria).

Nesta interface, é possível cadastrar os valores e tipos de concretos, materiais e resistências à compressão, antes de realizar a confecção de concreto, conforme ilustrado na Figura 37.

Figura 37 – Cadastramento de Resistências no DECCONCRETO

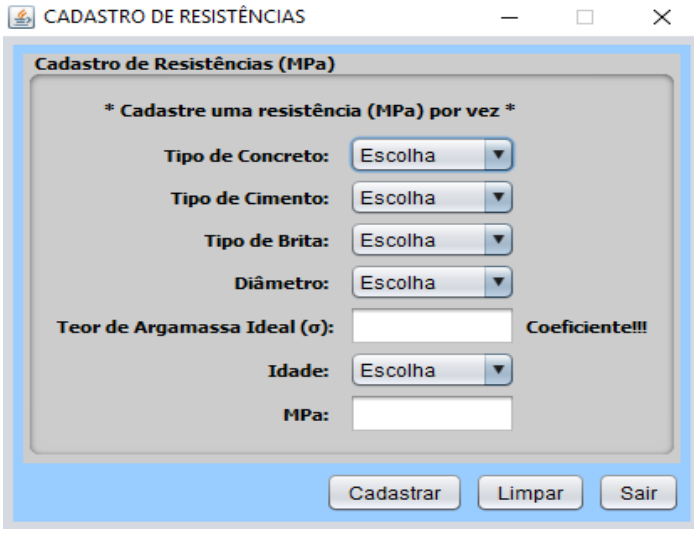

Fonte: Enio José Bolognini (*Netbeans* 8.0.2)

Conforme se observa na Figura 38, podem-se consultar quais resistências à compressão, tipos de concretos e materiais que estão cadastradas no banco de dados.

Figura 38 – Painel de consultas de resistências (MPa)

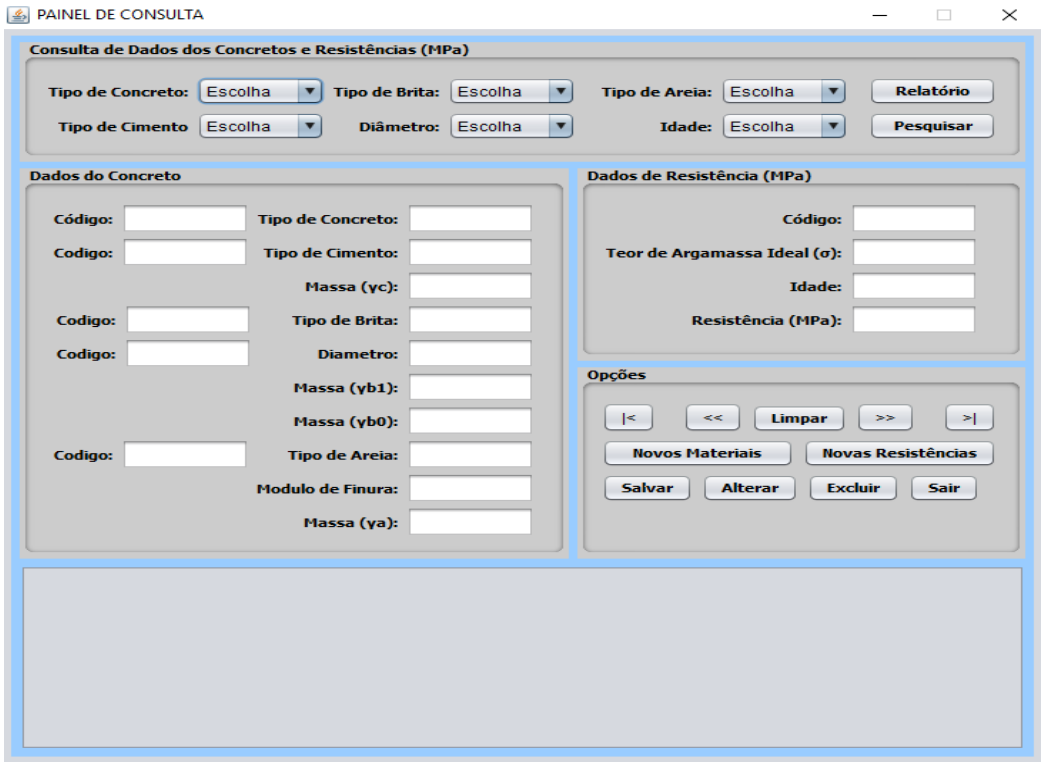

Fonte: Enio José Bolognini (*Netbeans* 8.0.2)

Conforme apresenta a Figura 39, foi possível confeccionar o concreto e encontrar o traço experimental. Nesta possibilidade, utilizaram-se redes neurais artificiais do algoritmo genético *feedforward*. Esta confecção de concreto, teve um banco de dados (SGBD) de resistências à compressão, para obter o traço unitário em massa de concreto.

Figura 39 – Traço de concreto inteligente por redes neurais artificiais *feedfoward*

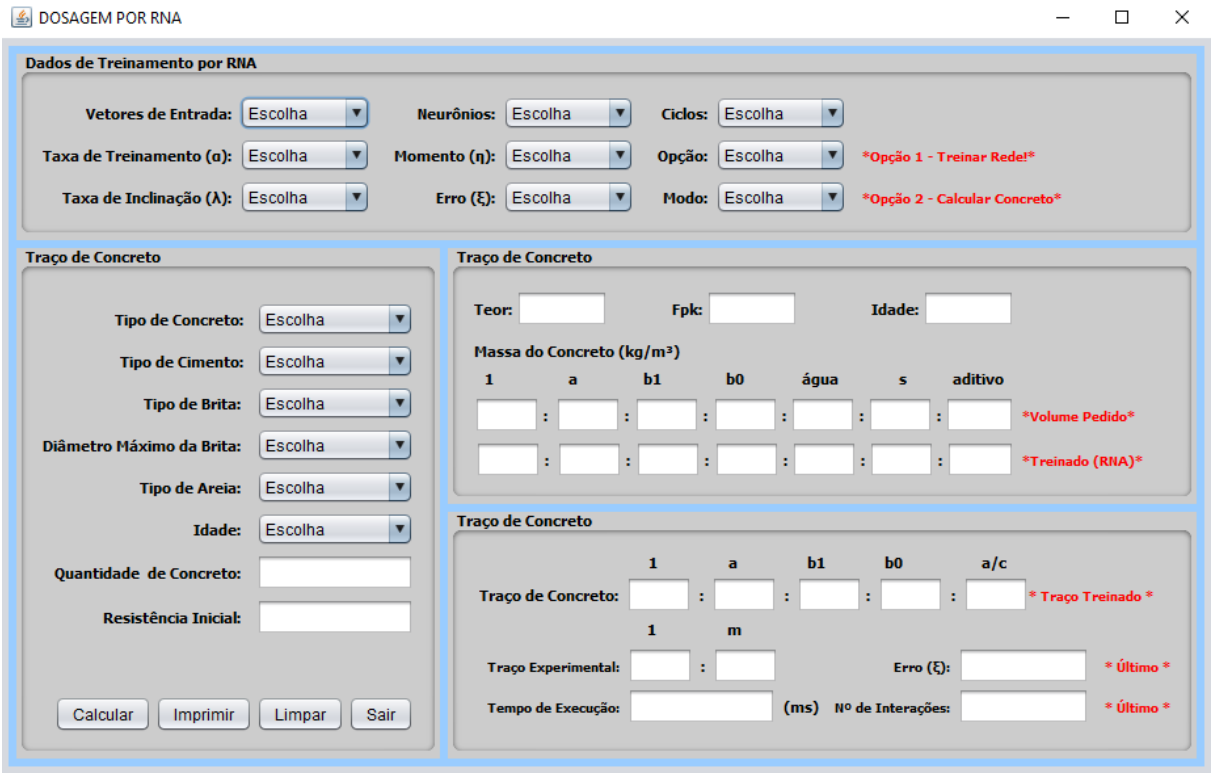

Fonte: Enio José Bolognini (*Netbeans* 8.0.2)

A Figura 40 ilustra a autoria deste *software* aplicativo. Este trabalho refere-se à confecção de concreto por redes neurais artificiais (RNA). Então, ficou determinado que este *software* aplicativo DECCONCRETO 1.0, foi de autoria do Departamento de Engenharia Civil – DEC, da Faculdade de Engenharia de Ilha Solteira – FEIS, campus UNESP.

Figura 40 – Direitos autorais

Fonte: Enio José Bolognini (*Netbeans* 8.0.2)

4.21 MÉTODO DE DESENVOLVIMENTO DE BANCO DE DADOS

Conforme ilustrado na Figura 41, o modelo de dados orientados a objetos (MDOO) pode ser apresentado como proposta deste trabalho, para criar uma base de dados e armazenar as resistências à compressão e os demais materiais utilizados.

Figura 41 – Proposta do modelo entidade relacionamento (MER) de *software* DECCONCRETO

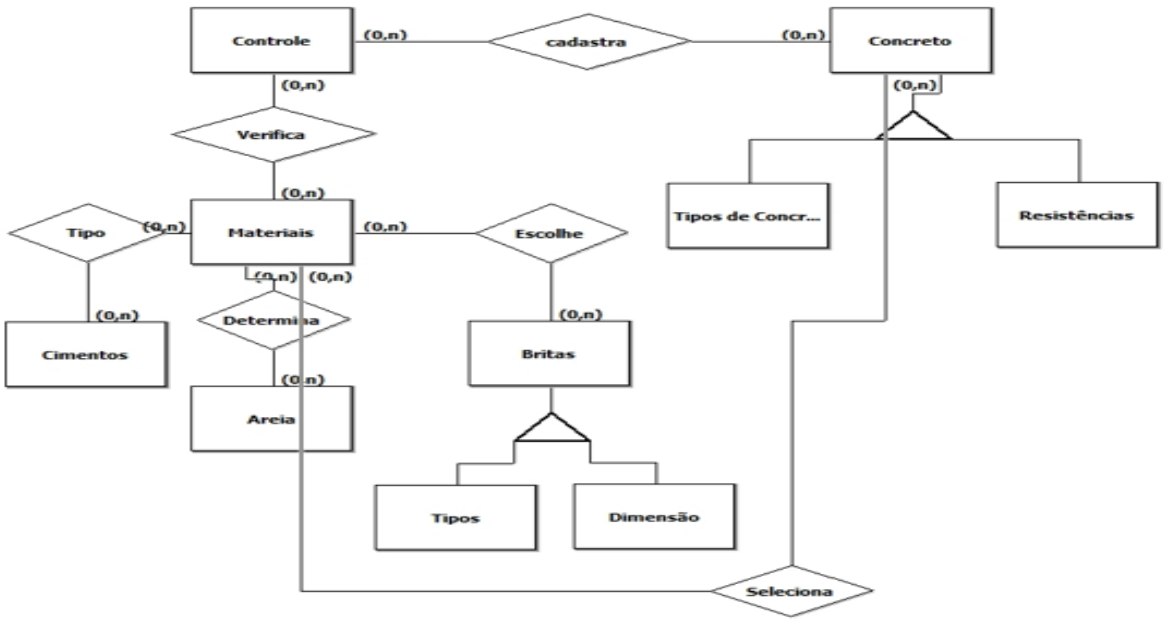

Fonte: Enio José Bolognini

As tabelas relacionais do diagrama, entidade, relacionamento podem ser demonstradas da seguinte forma:

- Areia (**idareia**, tipo_areia, modulo_finura, gama_a);
- Britas (**idbritas**, tipo_britas);
- Cimento (**idcimento**, tipo_cimento, gama_c);
- Concreto (**idconcreto**, tipo_de_concreto);
- Diametro (**iddiametro**, diametro, gama_b, idbritas);
- Resistencia_cad (**idrescad**, resistencia, teor, idade, idconcreto, idcimento, idbritas, iddiametro);
- Resistencia_convencional (**idresconv**, resistencia, teor, idade, idconcreto, idcimento, idbritas, iddiametro);
- Tracocad (**idtracocad**, c, a, b, fator, idade, idconcreto, idcimento, idbritas, iddiametro);
- Traconormal (**idtraconormal**, c, a, b, fator, idade, idconcreto, idcimento, idbritas, iddiametro).

Durante a realização desta pesquisa, um modelo de dados orientados a objeto foi criado para mapear graficamente o *software* aplicativo.

O objetivo deste *software* é reconhecer os dados do problema na forma de interfaces gráficas.

Desta forma, o trabalho do usuário se torna ágil e intuitivo.

5 RESULTADOS E DISCUSSÕES

5.1 DOSAGENS DOS CONCRETOS

5.1.1 Dosagens de Concreto Convencional com Agregados Graúdos de Basalto

Na Tabela 19 são apresentados os resultados das dosagens “ideais” para os concretos convencionais (CC) com o cimento Portland CP II 32 – Z e agregado graúdo de basalto com diâmetro (B1).

Tabela 19 – Resultados das dosagens “ideais” dos concretos convencionais (CC), para agregados graúdos de basalto com diâmetro (B1)

Teor de Argamassa Ideal	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
50%	1 : 3,5	1 : 1,25 : 2,25	13,64 : 16,51 : 31,41 : 4,78 : 0,38	7,5
50%	1 : 5,0	1 : 2,00 : 3,00	11,83 : 20,81 : 35,38 : 5,74 : 0,49	7,0
50%	1 : 6,5	1 : 2,75 : 3,75	9,86 : 23,96 : 36,79 : 5,68 : 0,68	7,0

A Tabela 20 apresenta as dosagens “ideais” para os concretos confeccionados com cimento Portland CP II 32 – Z, agregado graúdo de basalto com mistura dos diâmetros (B1/B0).

Tabela 20 – Resultados das dosagens “ideais” dos concretos convencionais (CC), para agregados graúdos de basalto com diâmetros (B1/B0)

Teor de Argamassa Ideal	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
49%	1 : 3,5	1 : 1,21 : 2,29	12,00 : 14,52 : 20,17 : 8,64 : 4,49 : 0,37	7,0
49%	1 : 5,0	1 : 1,94 : 3,06	9,82 : 19,05 : 21,01 : 9,00 : 5,24 : 0,53	6,5
49%	1 : 6,5	1 : 2,68 : 3,82	8,43 : 22,49 : 21,53 : 9,23 : 6,07 : 0,72	6,5

O traço de argamassa “ideal” de concreto com agregado graúdo de basalto, com a mistura da brita B1 e B0, permitiu diminuir em 1% o teor de argamassa em relação ao

mesmo concreto, com a brita B1 e sem a brita B0. Isto deve ter ocorrido, pois a colocação de uma brita menor juntamente com uma maior tende a diminuir o espaço vazio do concreto e, portanto, o teor de argamassa.

Os abatimentos para todos os concretos estiveram dentro do desejado, ou seja, 7 $\pm$ 1. A relação a/c aumenta na medida em que diminuiu a quantidade cimento, conforme era de se esperar.

5.1.2 Dosagens de Concreto Convencional com Agregados Graúdos de Granito

As dosagens "ideais" dos concretos convencionais (CC), confeccionados com cimento Portland CP II 32 – Z e agregados graúdos de granito com diâmetros B0 e B1, estão ilustradas nas Tabelas 21 e 22, respectivamente.

Tabela 21 – Resultados das dosagens "ideais" dos concretos convencionais (CC), para agregados graúdos de granito com diâmetro (B0)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
47%	1 : 3,5	1 : 1,21 : 2,29	10,92 : 12,23 : 26,80 : 4,08 : 0,37	7,5
47%	1 : 5,0	1 : 1,82 : 3,18	8,88 : 16,16 : 27,84 : 4,53 : 0,51	6,5
47%	1 : 6,5	1 : 2,83 : 3,67	7,58 : 19,17 : 28,44 : 5,43 : 0,71	7,0

Tabela 22 – Resultados das dosagens "ideais" dos concretos convencionais (CC), para agregados graúdos de granito com diâmetro (B1)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
47%	1 : 3,5	1 : 1,12 : 2,38	10,96 : 12,28 : 26,92 : 4,09 : 0,37	7,0
47%	1 : 5,0	1 : 1,82 : 3,18	8,91 : 16,22 : 27,97 : 4,73 : 0,53	6,5
47%	1: 6,5	1 : 2,83 : 3,67	7,61 : 19,25 : 28,57 : 5,44 : 0,71	6,5

As dosagens "ideais", para o mesmo cimento e a mistura dos diâmetros (B1/B0) dos agregados graúdos de granitos, são mostrados na Tabela 23.

Tabela 23 – Resultados das dosagens "ideais" dos concretos convencionais (CC), para agregados graúdos de granito com diâmetros (B1/B0)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
47%	1 : 3,5	1 : 1,12 : 2,38	10,95 : 12,26 : 18,85 : 8,07 : 4,09 : 0,37	7,5
47%	1 : 5,0	1 : 1,82 : 3,18	8,90 : 16,20 : 19,55 : 8,38 : 4,54 : 0,51	6,5
47%	1 : 6,5	1 : 2,68 : 3,82	7,60 : 19,22 : 19,97 : 8,56 : 5,44 : 0,72	8,0

Todas as dosagens dos concretos convencionais com agregados graúdos de granito tiveram o teor de argamassa ideal de 47%. Todos os abatimentos foram de acordo com o desejado, ou seja, 7 ± 1 e a relação a/c aumentou com a diminuição de cimento, conforme era esperado.

5.1.3 Traço de Concreto Convencional com Agregados Graúdos de Seixo Rolado

Também foi confeccionado o concreto convencional (CC) com agregados graúdos de seixo rolado de diâmetro (B1), e cimento Portland CP II 32 – Z. Foram obtidas as dosagens "ideais" do concreto, conforme apresentados na Tabela 24.

Tabela 24 – Resultados das dosagens "ideais" dos concretos convencionais (CC), para agregados graúdos de seixo rolado com diâmetro (B1)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
53%	1 : 3,5	1 : 1,39 : 2,11	12,72 : 17,69 : 26,82 : 4,45 : 0,35	7,0
53%	1 : 5,0	1 : 2,18 : 2,82	10,57 : 23,04 : 29,72 : 5,97 : 0,56	7,5
53%	1 : 6,5	1 : 2,98 : 3,52	9,19 : 27,39 : 32,24 : 6,74 : 0,73	7,0

O concreto convencional (CC) com seixo rolado foi o que necessitou de maior teor de argamassa. O abatimento ficou dentro do desejado e a relação a/c aumentou com a diminuição, conforme era esperado.

5.1.4 Dosagens de CAR com Agregados Graúdos de Basalto

Para o concreto de alta resistência (CAR), com cimento Portland: CP II 32 – Z, agregados graúdos de basalto e diâmetro (B0), com adição de microssílica e superplastificante, as dosagens "ideais" estão apresentadas na Tabela 25.

Tabela 25 – Resultados das dosagens "ideais" dos concretos de alta resistência (CAR), para agregados graúdos de basalto com diâmetro (B0)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
49%	1 : 3,5	1 : 1,30 : 2,20	11,96 : 14,47 : 28,76 : 4,49 : 0,96 : 0,06 : 0,38	7,5
49%	1 : 5,0	1 : 1,94 : 3,06	9,79 : 18,99 : 29,95 : 5,23 : 0,78 : 0,05 : 0,53	8,0
49%	1 : 6,5	1 : 2,53 : 3,97	8,40 : 22,52 : 30,65 : 6,05 : 0,70 : 0,04 : 0,72	6,0

A Tabela 26, expressa os resultados das dosagens "ideais" de concretos com cimento Portland CP III 40 – RS, agregados graúdos de basalto e diâmetro (B1), com adição de microssílica e superplastificante.

Tabela 26 – Resultados das dosagens "ideais" dos concretos de alta resistência (CAR), para agregados graúdos de basalto com diâmetro (B1)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
53%	1 : 3,5	1 : 1,39 : 2,11	12,77 : 17,75 : 28,66 : 4,85 : 1,02 : 0,064 : 0,38	7,0
53%	1 : 5,0	1 : 2,18 : 2,82	10,65 : 23,15 : 29,90 : 6,23 : 0,85 : 0,053 : 0,59	7,0
53%	1 : 6,5	1 : 2,98 : 3,52	9,24 : 27,54 : 30,63 : 6,77 : 0,74 : 0,046 : 0,73	7,0

O concreto de alta resistência (CAR) com agregados graúdos de basalto e diâmetro B1 exigiu maior teor de argamassa em relação ao concreto de alta resistência (CAR) com brita de basalto com diâmetro B0. Esse comportamento é esperado visto que a brita com menor diâmetro deve vir ocupar no empacotamento das partículas. O abatimento destas dosagens ficou dentro do desejado e a relação a/c aumentou com a diminuição do consumo de cimento.

5.1.5 Dosagens de CAR com Agregados Graúdos de Granito

Nas Tabelas 27 e 28 pode-se observar as dosagens "ideais" dos concretos com cimento Portland CP II 32 – Z, agregados graúdos de granito e diâmetros B1 e B0, com adição de microssílica e superplastificante.

Tabela 27 – Resultados das dosagens "ideais" dos concretos de alta resistência (CAR), para agregados graúdos de granito com diâmetro (B0)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
49%	1 : 3,5	1 : 1,30 : 2,20	11,29 : 13,66 : 26,80 : 4,25 : 0,95 : 0,06 : 0,38	7,5
49%	1 : 5,0	1 : 1,94 : 3,06	9,25 : 17,94 : 27,84 : 4,97 : 0,74 : 0,05 : 0,54	8,0
49%	1 : 6,5	1 : 2,53 : 3,97	7,95 : 21,30 : 28,44 : 5,76 : 0,64 : 0,04 : 0,72	6,0

Tabela 28 – Resultados das dosagens "ideais" dos concretos de alta resistência (CAR), para agregados graúdos de granito com diâmetro (B1)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
49%	1 : 3,5	1 : 1,30 : 2,20	11,33 : 13,71 : 26,92 : 4,27 : 0,90 : 0,06 : 0,38	8,0
49%	1 : 5,0	1 : 1,94 : 3,06	9,28 : 18,00 : 27,97 : 4,98 : 0,74 : 0,05 : 0,54	7,0
49%	1 : 6,5	1 : 2,53 : 3,97	7,98 : 21,38 : 28,57 : 5,78 : 0,64 : 0,04 : 0,72	6,0

A Tabela 29, apresenta as dosagens "ideais" dos concretos com agregados graúdos de granitos e diâmetros (B1/B0), cimento Portland CP II 32 – Z, com adição de microssílica e superplastificante.

Tabela 29 – Resultados das dosagens "ideais" dos concretos de alta resistência (CAR), para agregados graúdos de granito com diâmetros (B1/B0)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
47%	1 : 3,5	1 : 1,21 : 2,29	10,95 : 12,26 : 28,23 : 4,09 : 0,87 : 0,06 : 0,37	6,0
47%	1 : 5,0	1 : 1,82 : 3,18	8,90 : 16,20 : 27,93 : 4,54 : 0,71 : 0,04 : 0,51	7,5
47%	1 : 6,5	1 : 2,53 : 3,97	7,60 : 19,22 : 29,96 : 5,44 : 0,61 : 0,04 : 0,72	8,0

Para o concreto de alta resistência (CAR), com agregado graúdo de granito, o traço com a mistura de duas britas (B1 e B0) foi o que exigiu menos argamassa. Isto fez com que o teor de argamassa ideal fosse de 47%. Este é o comportamento desejado, visto que a mistura das duas britas deve diminuir os espaços vazios entre as mesmas, com preenchimento de argamassa.

O abatimento foi dentro do esperado e a relação a/c cresceu com a diminuição do cimento.

5.1.6 Dosagens de CAR com Agregados Graúdos de Seixo Rolado

O traço "ideal" para os concretos de alta resistência (CAR) com agregados graúdos de seixo-rolado e diâmetro (B1), cimento Portland CP III 40 – RS, com adição de microssílica e superplastificante, estão apresentados na Tabela 30.

Tabela 30 – Resultados das dosagens "ideais" dos concretos de alta resistência (CAR), para agregados graúdos de seixo rolado com diâmetros (B1)

Teor	Traço	Traço Experimental	Traço em Massa (kg)	Abatimento
53%	1 : 3,5	1 : 1,39 : 2,11	12,66 : 17,59 : 28,34 : 4,81 : 1,01 : 0,06 : 0,38	7,0
53%	1 : 5,0	1 : 2,18 : 2,82	10,53 : 22,95 : 29,55 : 6,18 : 0,84 : 0,05 : 0,59	7,0
53%	1 : 6,5	1 : 2,98 : 3,52	9,16 : 27,31 : 30,26 : 6,73 : 0,73 : 0,05 : 0,74	7,0

Novamente o concreto de alta resistência (CAR) com seixo rolado foi o que exigiu maior teor de argamassa. O abatimento ficou dentro do esperado e a relação a/c diminui o consumo de cimento.

5.2 RESULTADOS DOS ENSAIOS MECÂNICOS

5.2.1 Resultados de Resistência à Compressão do Concreto Convencional com Agregado Graúdo de Basalto B1

Na Tabela 31 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z e agregados graúdos de basalto com diâmetro (B1). Na Tabela 31 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 31 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de basalto com diâmetro (B1)

Corpo de Prova	**1:3,5**	**1:5,0**	**1:6,5**	**Corpo de Prova**	**1:3,5**	**1:5,0**	**1:6,5**	**Corpo de Prova**	**1:3,5**	**1:5,0**	**1:6,5**
	Tensão (MPa)				**Tensão (MPa)**				**Tensão (MPa)**		
	7 dias	**7 dias**	**7 dias**		**28 dias**	**28 dias**	**28 dias**		**91 dias**	**91 dias**	**91 dias**
CP1	20,76	12,6	6,94	CP5	26,8	25,92	12,21	CP09	36,62	38,34	19,69
CP2	16,32	16,37	6,31	CP6	26,25	22,14	10,2	CP10	42,21	38,83	18,63
CP2	17,09	16,24	8,42	CP7	24,07	24,38	13,07	CP11	36,4	37,7	19,07
CP3	18,71	17,43	6,47	CP8	-	-	11,4	CP12	-	-	18,74
Média	18	16	7	**Média**	26	24	12	**Média**	38,5	38	19
σ	2	2	1	**σ**	1,5	2	1	**σ**	3	1	0,5

Tabela 31 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de basalto com diâmetro (B1)

Idade	**Mpa**	**Traço (c : a : b : a/c)**	**c : m**
7	18	1 : 1,21 : 2,297 : 0,355	1:3,507
7	16	1 : 1,76 : 2,984 : 0,490	1:4,744
7	7	1 : 2,43 : 3,725 : 0,582	1:6,155
28	26	1 : 1,21 : 2,297 : 0,356	1:3,510
28	24	1 : 1,76 : 2,985 : 0,491	1:4,474
28	12	1 : 2,43 : 3,725 : 0,582	1:6,155
91	38,5	1 : 1,21 : 2,297 : 0,359	1:3,508
91	38	1 : 1,76 : 2,985 : 0,491	1:4,744
91	19	1 : 2,43 : 3,725 : 0,583	1:6,155

O concreto convencional (CC) com britas de basalto B1 apresentou resultados de acordo com esperado aos 7, 28 e 91 dias. Ou seja, a resistência aumenta com idade e o consumo de cimento, conforme se observa na Figura 42.

Figura 42 – Curvas do diagrama de dosagem dos CCs para dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de basalto com diâmetro (B1)

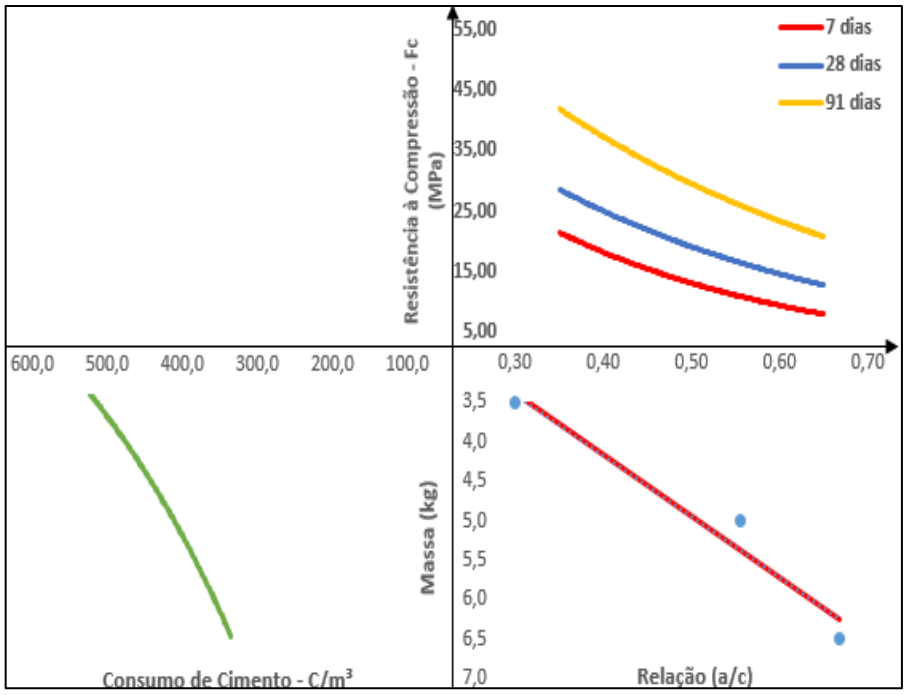

Fonte: Enio José Bolognini

5.2.2 Resultados de Resistência à Compressão do Concretos Convencionais com Agregado Graúdos de Basalto B1/B0

Na Tabela 32 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z e agregados graúdos de basalto com diâmetro (B1/B0). Na Tabela 32 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 32 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de basalto e diâmetros (B1/B0)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	17,67	15,63	5,92	CP5	20,89	22,23	9,32	CP09	33,32	29,90	16,86
CP2	15,80	14,99	6,92	CP6	23,20	21,73	9,65	CP10	37,79	31,46	16,88
CP2	18,11	15,35	6,88	CP7	20,51	16,17	10,26	CP11	39,00	29,75	18,79
CP3	18,19	14,92	6,93	CP8	23,94	19,89	11,12	CP12	39,37	30,23	16,25
Média	17	15	7	**Média**	22	20	10	**Média**	37	30	17
σ	1,1	0,3	0,5	**σ**	1,7	2,7	0,8	**σ**	2,8	0,8	1,1

Tabela 32 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de basalto com diâmetro (B1/B0)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	17	1:1,21:1,68:0,72:0,39	1:3,610
7	15	1:1,94:2,14:0,92:0,47	1:4,993
7	7	1:2,66:2,55:1,09:0,57	1:6,311
28	22	1:1,20:1,68:0,72:0,39	1:3,610
28	20	1:1,93:2,13:0,92:0,47	1:4,993
28	10	1:2,66:2,55:1,09:0,57	1:6,312
91	37	1:1,21:1,68:0,72:0,39	1:3,610
91	30	1:1,94:2,14:0,92:0,47	1:4,994
91	17	1:2,66:2,55:1,09:0,57	1:6,313

O concreto convencional (CC) com britas de basalto B1/B0 apresentou resultados de acordo com esperado aos 7, 28 e 91 dias. Pode-se concluir que a resistência aumenta com idade e o consumo de cimento, conforme se observa na Figura 43.

Figura 43 – Curvas do diagrama de dosagem dos CCs para dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de basalto com diâmetros (B1/B0)

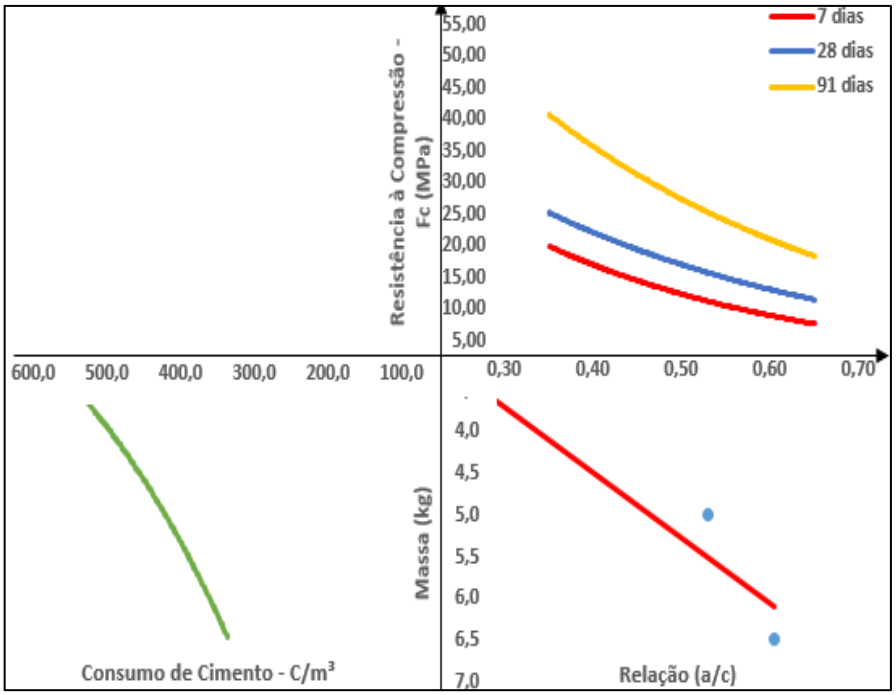

Fonte: Enio José Bolognini

5.2.3 Resultados de Resistência à Compressão dos Concretos Convencionais com Agregados Graúdos de Granito B0

Na Tabela 33 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z e agregados graúdos de granito com diâmetro (B0). Na Tabela 33 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 33 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de granito com diâmetro (B0)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	32	21,46	20,85	CP5	35,2	29,94	23,51	CP09	48,52	27,87	27,59
CP2	24,24	21,5	20,26	CP6	39,42	30,44	26,55	CP10	46,75	31,81	35,01
CP2	30,84	22,44	22,66	CP7	38,76	31,01	23,2	CP11	45,5	35,39	28,84
CP3	23,13	-	-	CP8	37,72	30,18	-	CP12	42,87	33,93	26,48
Média	28	22	21	**Média**	38	30	24	**Média**	46	32	29
σ	4,5	1	1	**σ**	2	0,5	2	**σ**	2,5	3	4

Tabela 33 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de granito com diâmetro (B0)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	28	1:1,12:2,448:0,379	1:3,568
7	22	1:1,82:3,129:0,516	1:4,948
7	21	1:2,53:3,745:0,722	1:6,274
28	38	1:1,12:2,448:0,379	1:3,568
28	30	1:1,82:3,129:0,516	1:4,948
28	24	1:2,53:3,745:0,722	1:6,274
91	46	1:1,12:2,448:0,379	1:3,568
91	32	1:1,82:3,129:0,516	1:4,948
91	29	1:2,53:3,745:0,722	1:6,274

Conforme se observa na Figura 44, foi apresentado o resultado do concreto convencional, com britas de granito B0 de acordo com esperado aos 7, 28 e 91 dias. Pode-se concluir que a resistência aumenta com idade e o consumo de cimento.

Figura 44 – Curvas do diagrama de dosagem dos CCs para dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetro (B0)

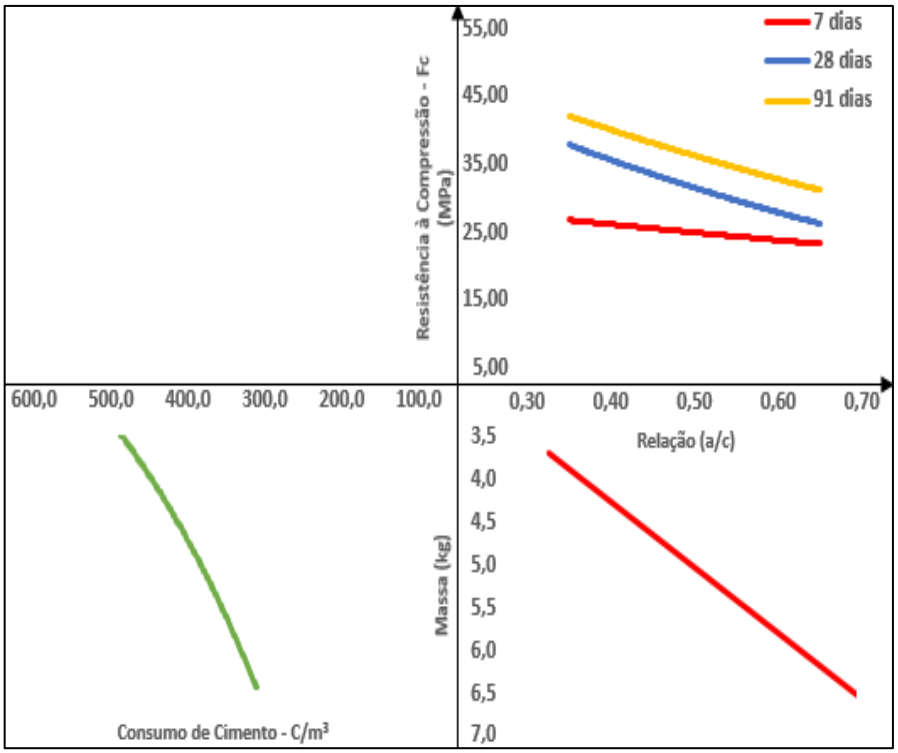

Fonte: Enio José Bolognini

5.2.4 Resultados de Resistência à Compressão do Concreto Convencional com Agregado Graúdos de Granito B1

Na Tabela 34 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z e agregados graúdos de granito com diâmetro (B1). Na Tabela 34 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 34 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de granito com diâmetro (B1)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	23,42	24,22	22,19	CP5	35,84	28,98	29,59	CP09	38,98	31,97	29,87
CP2	28,89	21,6	21,64	CP6	40,22	28,83	30,28	CP10	36,31	37	34,03
CP2	22,85	21,64	17,35	CP7	38,22	32,11	30,74	CP11	40,88	31,52	34,5
CP3	29,35	18,28	-	CP8	39,35	32,37	-	CP12	38,71	36,6	30,61
Média	26	21	20	**Média**	38	31	30	**Média**	39	34	32
σ	3	2	3	**σ**	2	2	1	**σ**	2	3	2

Tabela 34 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de granito com diâmetro (B1)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	26	1:1,12:2,45:0,378	1:3,570
7	21	1:1,82:3,13:0,536	1:4,953
7	20	1:2,53:3,75:0,720	1:6,300
28	38	1:1,12:2,45:0,378	1:3,570
28	31	1:1,82:3,13:0,536	1:4,953
28	30	1:2,53:3,75:0,720	1:6,300
91	39	1:1,12:2,45:0,378	1:3,570
91	34	1:1,82:3,13:0,536	1:4,953
91	32	1:2,53:3,75:0,720	1:6,300

Na Figura 45 observa-se que o concreto convencional, com britas de granito B1, obtiveram os resultados de acordo com esperado aos 7, 28 e 91 dias. Nota-se que a resistência aumenta com a idade e o consumo de cimento.

Figura 45 – Curvas do diagrama de dosagem dos CCs para dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetro (B1)

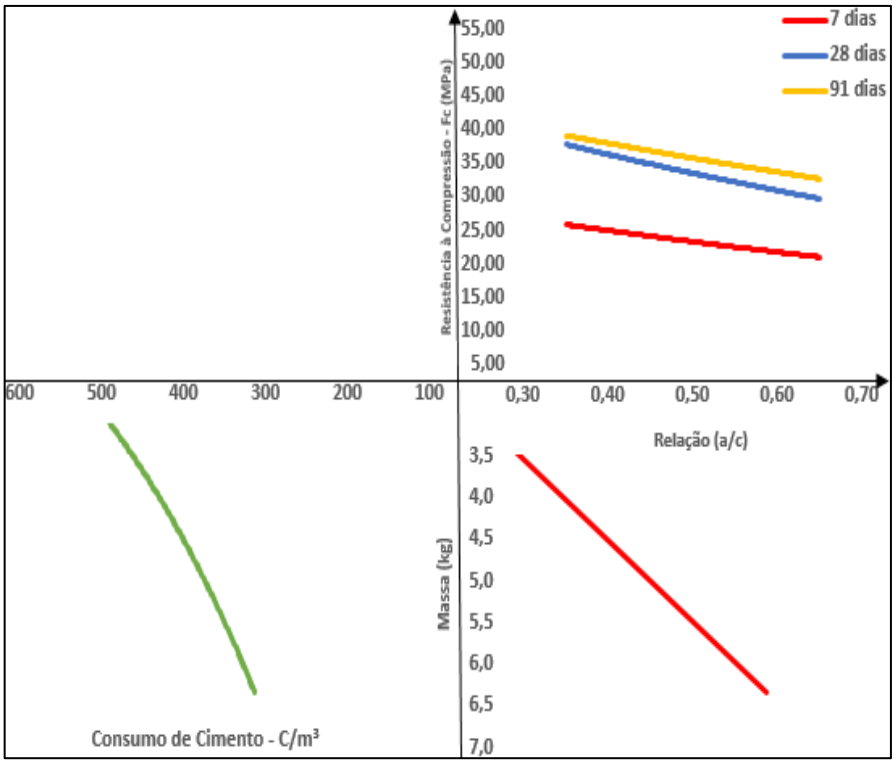

Fonte: Enio José Bolognini

5.2.5 Resultados de Resistência à Compressão do Concreto Convencional com Agregado Graúdos de Granito (B1/B0)

Na Tabela 35 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z e agregados graúdos de granito com diâmetro (B1/B0). Na Tabela 35 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 35 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de granito com diâmetros (B1/B0)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	28,17	22,94	22,78	CP5	32,75	29	25,8	CP09	34,54	32,45	29,62
CP2	26,24	22,66	23,13	CP6	28,7	30,61	25,75	CP10	30,67	33,98	27,87
CP2	25,28	25,32	21,74	CP7	32,98	28,76	24,87	CP11	38,43	32,94	25,06
CP3	28,3	25,33	21,55	CP8	30,75	27,59	24,64	CP12	-	-	-
Média	27	24	22	**Média**	31	29	25	**Média**	35	33	28
σ	1	1	1	**σ**	2	1	1	**σ**	4	1	2

Tabela 35 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de granito com diâmetro (B1/B0)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	27	1:1,12:1,72:0,74:0,376	1:3,572
7	24	1:1,82:2,19:0,94:0,513	1:4,955
7	22	1:2,53:2,64:1,13:0,719	1:6,279
28	31	1:1,12:1,72:0,74:0,376	1:3,572
28	29	1:1,82:2,19:0,94:0,513	1:4,955
28	25	1:2,53:2,64:1,13:0,719	1:6,279
91	35	1:1,12:1,72:0,74:0,376	1:3,572
91	33	1:1,82:2,19:0,94:0,513	1:4,955
91	28	1:2,53:2,64:1,13:0,719	1:6,279

Conforme se observa na Figura 46, os agregados graúdos de granito com britas B1/B0, também obtiveram resultados dentro do esperado aos 7, 28 e 91 dias. Pode-se observar o aumento da resistência com a idade e o consumo de cimento.

Figura 46 – Curvas do diagrama de dosagem dos CCs para dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetros (B1/B0)

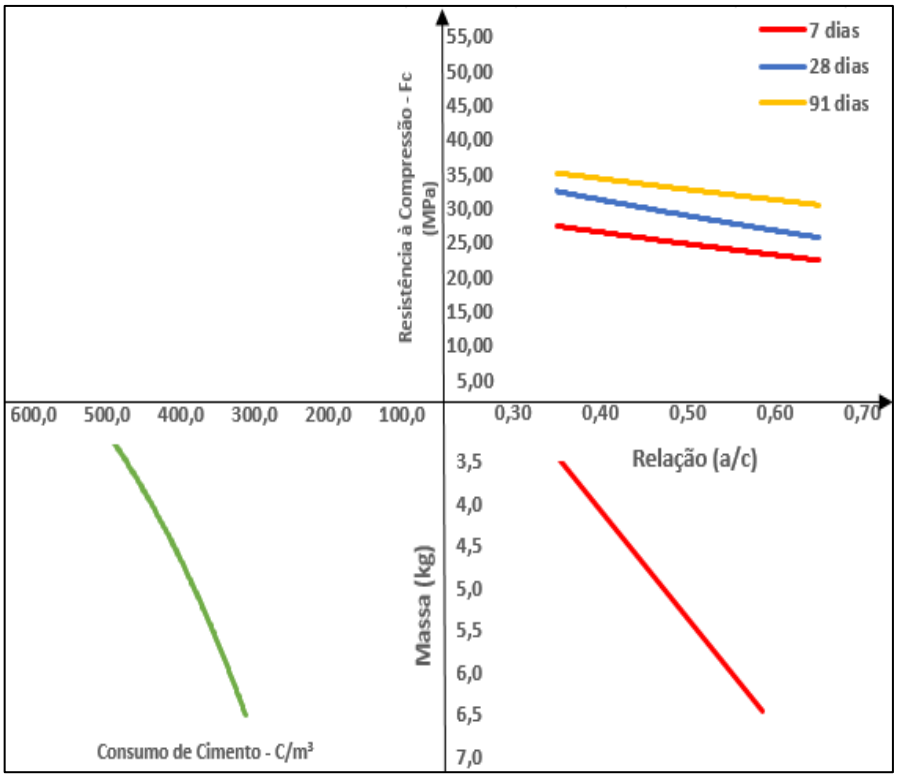

Fonte: Enio José Bolognini

5.2.6 Resultados de Resistência à Compressão do Concreto Convencional com Agregado Graúdos de Seixo-Rolado B1

Na Tabela 36 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z e agregados graúdos de seixo rolado com diâmetro (B1). Na Tabela 36 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 36 (a) – Resultados de resistência à compressão (MPa) dos CCs para agregados graúdos de seixo rolado com diâmetro (B1)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	25,5	25,33	16,01	CP5	33,41	31,01	22,71	CP09	37,79	34,33	24,71
CP2	25,35	24,73	15,45	CP6	33,31	30,27	22,45	CP10	35,46	34,28	23,91
CP2	24,94	23,32	15,04	CP7	31,74	29,57	21,93	CP11	35,34	33,34	23,63
CP3	24,73	23,32	14,98	CP8	-	-	20,87	CP12	-	33,11	23,13
Média	25	24	15	**Média**	33	30	22	**Média**	36	34	24
σ	0,5	1	0,5	**σ**	1	1	1	**σ**	1	1	1

Tabela 36 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CCs para agregados graúdos de seixo rolado com diâmetro (B1)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	25	1:1,39:2,10:0,354	1:3,494
7	24	1:2,18:2,81:0,569	1:4,986
7	15	1:2,98:3,50:0,739	1:6,482
28	33	1:1,39:2,10:0,354	1:3,494
28	30	1:2,18:2,81:0,569	1:4,986
28	22	1:2,98:3,50:0,739	1:6,482
91	36	1:1,39:2,10:0,354	1:3,494
91	34	1:2,18:2,81:0,569	1:4,986
91	24	1:2,98:3,50:0,739	1:6,482

Conforme se observa na Figura 47, o concreto convencional (CC) com britas de seixo rolado B1, obteve resultados de acordo com esperado aos 7, 28 e 91 dias. Ou seja, a resistência aumenta com a idade e consumo de cimento.

Figura 47 – Curvas do diagrama de dosagem dos CCs para dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de seixo rolado com diâmetro (B1)

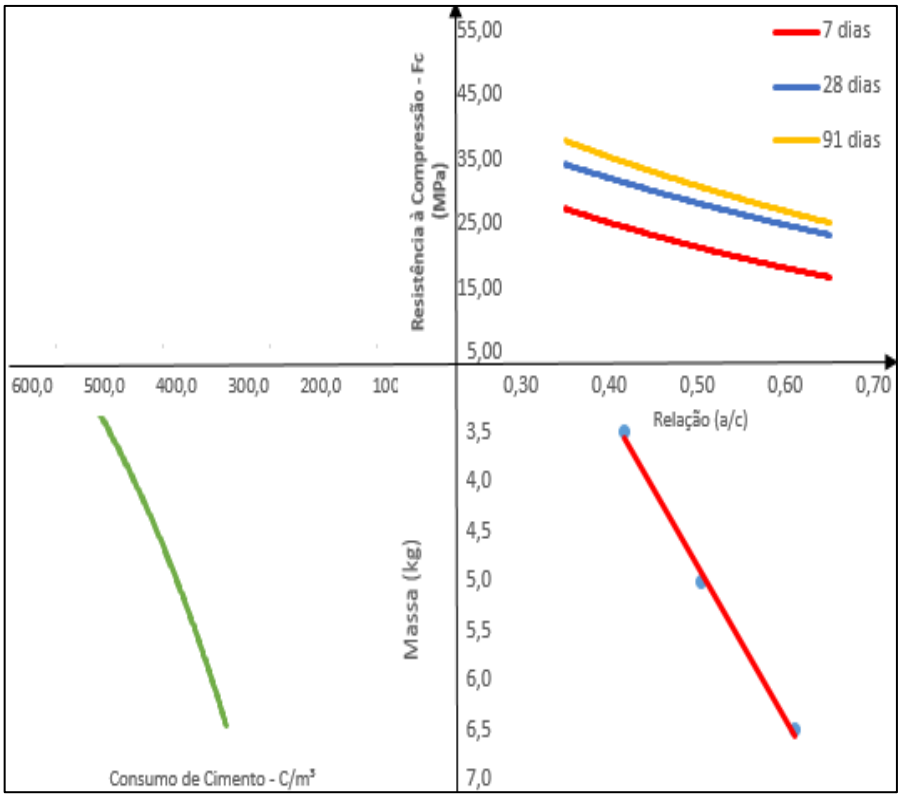

5.2.7 Resultados de Resistência à Compressão do Concreto de Alta Resistência com Agregados Graúdos de Basalto B0

Na Tabela 37 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z, microssílica, superplastificante e agregados graúdos de basalto com diâmetro (B0). Na Tabela 37 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 37 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de basalto com diâmetro (B0)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	38,45	30,34	23,18	CP5	53,47	48,31	38,24	CP09	56,71	54,15	39,3
CP2	31,86	40,25	25,09	CP6	58,76	50,29	40,04	CP10	57,84	48,1	39,94
CP2	34,47	27,16	23,41	CP7	57,04	50,6	39,14	CP11	44,26	48,83	38,71
CP3	39,76	25,23	17,83	CP8	51,73	-	-	CP12	52,58	-	-
Média	36	31	22	**Média**	55	50	39	**Média**	53	50,5	39,5
σ	3,5	7	3	**σ**	3	1	1	**σ**	6	3	1

Tabela 37 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de basalto com diâmetro (B0)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	36	1:1,21:2,39:0,375	1:3,609
7	31	1:1,94:3,05:0,534	1:4,993
7	22	1:2,68:3,64:0,720	1:6,324
28	55	1:1,21:2,39:0,375	1:3,609
28	51	1:1,94:3,05:0,534	1:4,993
28	39	1:2,68:3,64:0,720	1:6,324
91	53	1:1,21:2,39:0,375	1:3,609
91	50.5	1:1,94:3,05:0,534	1:4,993
91	39.5	1:2,68:3,64:0,720	1:6,324

Na Figura 48, observa-se os resultados de 7, 28 e 91 dias, que estiveram de acordo com esperado para o concreto de alta resistência (CAR) com britas de basalto B0. Ou seja, a resistência aumenta com a idade e o consumo de cimento.

Figura 48 – Curvas do diagrama de dosagem dos CARs para dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de basalto com diâmetro (B0)

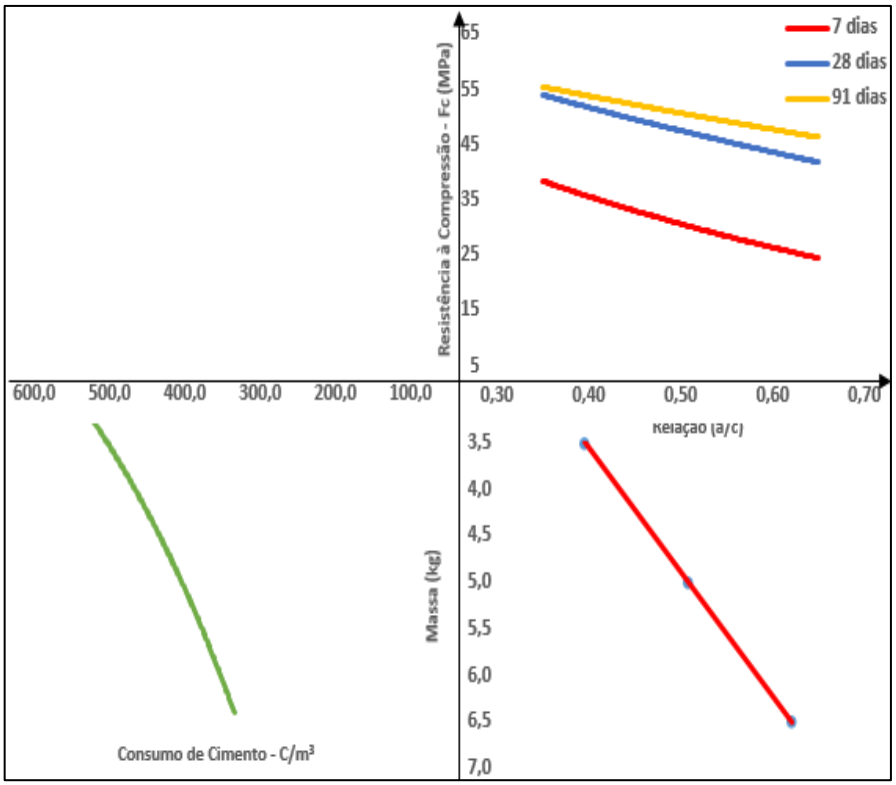

Fonte: Enio José Bolognini

5.2.8 Resultados de Resistência à Compressão do Concreto de Alta Resistência com Britas de Basalto B1

Na Tabela 38 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP III 40 – RS, microssílica, superplastificante e agregados graúdos de basalto com diâmetro (B1). Na Tabela 38 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 38 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de basalto com diâmetro (B1)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	31,78	23,48	17,78	CP5	38,73	37,04	27,66	CP09	50,36	37,99	31,95
CP2	31,74	23,15	16,43	CP6	37,18	35,84	27,37	CP10	46,73	37,8	31,12
CP2	31,26	23,04	15,21	CP7	33,22	34,64	26,44	CP11	45,48	37,33	29,71
CP3	31,19	22,42	15,16	CP8	-	30,27	24,99	CP12	43,34	36,88	28,22
Média	31	23	16	**Média**	36	34	27	**Média**	46	37,5	31
σ	0,5	0,5	1	**σ**	3	3	1	**σ**	3	0,5	1

Tabela 38 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de basalto com diâmetro (B1)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	31	1:1,38:2,23:0,379	1:3,629
7	23	1:2,18:2,81:0,586	1:4,990
7	16	1:2,98:3,31:0,732	1:6,290
28	36	1:1,38:2,23:0,379	1:3,629
28	34	1:2,18:2,81:0,586	1:4,990
28	27	1:2,98:3,31:0,732	1:6,290
91	46	1:1,38:2,23:0,379	1:3,629
91	37,5	1:2,18:2,81:0,586	1:4,990
91	31	1:2,98:3,31:0,732	1:6,290

Os resultados obtidos do concreto de alta resistência (CAR) com britas de granito B0 para 7, 28 e 91 dias estão de acordo com o esperado. Houve aumento das resistências com aumento da idade e do consumo de cimento, conforme ilustrados na Figura 49.

Figura 49 – Curvas do diagrama de dosagem dos CARs para dosagens: 1:3,5; 1:5,0 e 1:6,5 aos 7, 28 e 91 dias, referente aos agregados graúdos de basalto com diâmetro (B1)

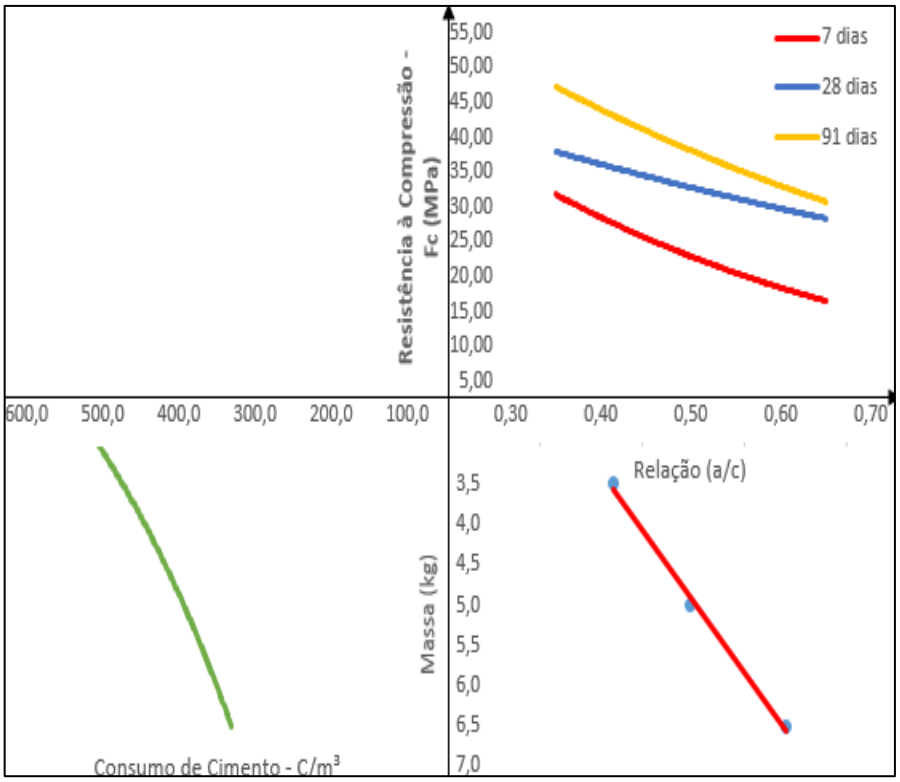

Fonte: Enio José Bolognini

5.2.9 Resultados de Resistência à Compressão do Concreto de Alta Resistência com Agregados Graúdos de Granito B0

Na Tabela 39 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z, microssílica, superplastificante e agregados graúdos de granito com diâmetro (B0). Na Tabela 39 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 39 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de granito com diâmetro (B0)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	40,91	32,71	23,09	CP5	52,11	39,35	33,2	CP09	49,65	43,08	35,18
CP2	41,74	34,89	22,02	CP6	51,09	42,54	34,4	CP10	53,62	45,32	34,05
CP2	42,37	30,20	21,62	CP7	53,01	38,05	32,49	CP11	53,64	41,94	34,42
CP3	44,56	30,09	21,88	CP8	-	35,32	-	CP12	-	34,19	-
Média	42	32	22	**Média**	52	39	34	**Média**	52,5	41	34,5
σ	1,5	2,5	0,5	**σ**	1	3	1	**σ**	2	5	4

Tabela 39 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de granito com diâmetro (B0)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	42	1:1,21:2,37:0,376	1:3,578
7	32	1:1,94:3,00:0,537	1:4,943
7	22	1:2,68:3,57:0,724	1:6,250
28	52	1:1,21:2,37:0,376	1:3,578
28	39	1:1,94:3,00:0,537	1:4,943
28	34	1:2,68:3,57:0,724	1:6,250
91	52.5	1:1,21:2,37:0,376	1:3,578
91	41	1:1,94:3,00:0,537	1:4,943
91	34.5	1:2,68:3,57:0,724	1:6,250

Na Figura 50, pode ser observado os resultados obtidos do concreto de alta resistência (CAR) com britas de granito B0 para 7, 28 e 91 dias estão de acordo com o esperado. Houve aumento das resistências com aumento da idade e do consumo de cimento.

Figura 50 – Curvas do diagrama de dosagem dos CARs para dosagens: 1:3,5; 1:5,0 e 1:6,5 entre 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetro (B0)

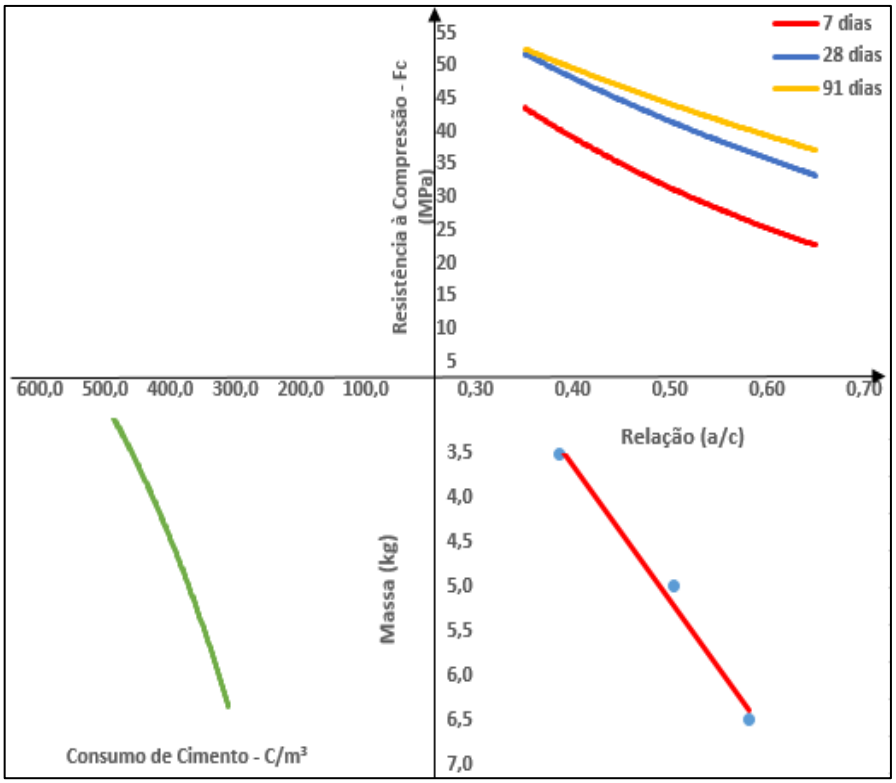

Fonte: Enio José Bolognini

5.2.10 Resultados de Resistência à Compressão do Concreto de Alta Resistência com Agregado Graúdos de Granito B1

Na Tabela 40 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z, microssílica, superplastificante e agregados graúdos de granito com diâmetro (B0). Na Tabela 40 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 40 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de granito com diâmetro (B1)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	32,94	40,82	28,10	CP5	48,55	55,90	31,50	CP09	50,67	56,52	42,02
CP2	44,23	45,11	33,25	CP6	53,05	53,69	39,78	CP10	54,85	50,22	36,54
CP2	44,63	41,00	30,80	CP7	50,83	50,84	37,54	CP11	49,98	53,08	43,81
CP3	35,48	42,04	25,96	CP8	-	-	38,27	CP12	-	-	44,14
Média	39	42	30	**Média**	51	53	37	**Média**	52	53,5	41
σ	6	2	3	**σ**	2	3	4	**σ**	3	3	4

Tabela 40 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de granito com diâmetro (B1)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	39	1:1,21:2,37:0,376	1:3,581
7	42	1:1,94:3,01:0,536	1:4,948
7	30	1:2,68:3,57:0,724	1:6,254
28	51	1:1,21:2,37:0,376	1:3,581
28	53	1:1,94:3,01:0,536	1:4,948
28	37	1:2,68:3,57:0,724	1:6,254
91	52	1:1,21:2,37:0,376	1:3,581
91	53,5	1:1,94:3,01:0,536	1:4,948
91	41	1:2,68:3,57:0,724	1:6,254

Conforme se observa na Figura 51, os resultados do concreto de alta resistência (CAR) com britas de granito B1 para 7, 28 e 91 dias estes estão de acordo com o esperado. Houve aumento das resistências com aumento da idade e do consumo de cimento.

Figura 51 – Curvas do diagrama de dosagem dos CARs para dosagens: 1:3,5; 1:5,0 e 1:6,5 entre 7, 28 e 91 dias, referente aos agregados graúdos de granito com diâmetro (B1)

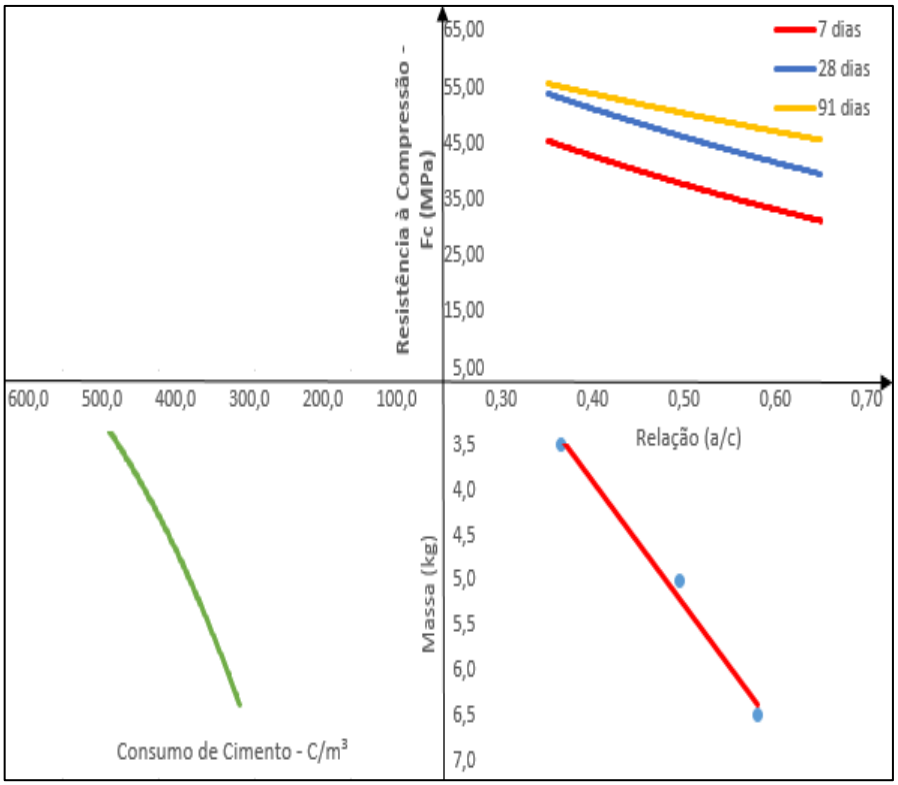

Fonte: Enio José Bolognini

5.2.11 Resultados de Resistência à Compressão do Concretos de Alta Resistência com Agregados Graúdos de Granito (B1/B0)

Na Tabela 41 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP II 32 – Z, microssílica, superplastificante e agregados graúdos de granito com diâmetro (B1/B0). Na Tabela 41 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 41 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de granito com diâmetros (B1/B0)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	31,92	28,76	28,79	CP5	47,37	39,7	32,54	CP09	50,27	39,83	39,09
CP2	41,74	30,21	28,81	CP6	50,31	33,08	38,86	CP10	52,08	42,21	39,28
CP2	38,24	28,6	28,65	CP7	44,33	39,76	36,8	CP11	51,28	40,3	41,87
CP3	37,44	29,64	27,47	CP8	51,42	39,57	-	CP12	-	38,72	-
Média	37	29	28	**Média**	48	38	36	**Média**	51	41	40
σ	4	1	0,5	**σ**	3	4	3	**σ**	1	1,5	2

Tabela 41 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de granito com diâmetro (B1/B0)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	37	1:1,12:1,80:0,77:0,373	1:3,694
7	29	1:1,82:2,19:0,94:0,510	1:4,954
7	29	1:2,52:2,75:1,18:0,715	1:6,466
28	48	1:1,12:1,80:0,77:0,373	1:3,694
28	39	1:1,82:2,19:0,94:0,510	1:4,954
28	39	1:2,52:2,75:1,18:0,715	1:6,466
91	49	1:1,12:1,80:0,77:0,373	1:3,694
91	40	1:1,82:2,19:0,94:0,510	1:4,954
91	41	1:2,52:2,75:1,18:0,715	1:6,466

Observando os resultados do concreto de alta resistência (CAR) com britas de granito B1/B0 para 7, 28 e 91 dias estes estão de acordo com o esperado. Também, houve um aumento das resistências com aumento da idade e do consumo de cimento.

A Figura 52 demonstra as curvas do diagrama de dosagem, para relações de agregados graúdos com diâmetro (B1/B0) de granito.

Figura 52 – Curvas do diagrama de dosagem dos CARs para dosagens: 1:3,5; 1:5,0 e 1:6,5 entre 7, 28 e 91 dias, referente a relação dos agregados graúdos de granito com diâmetro (B1/B0)

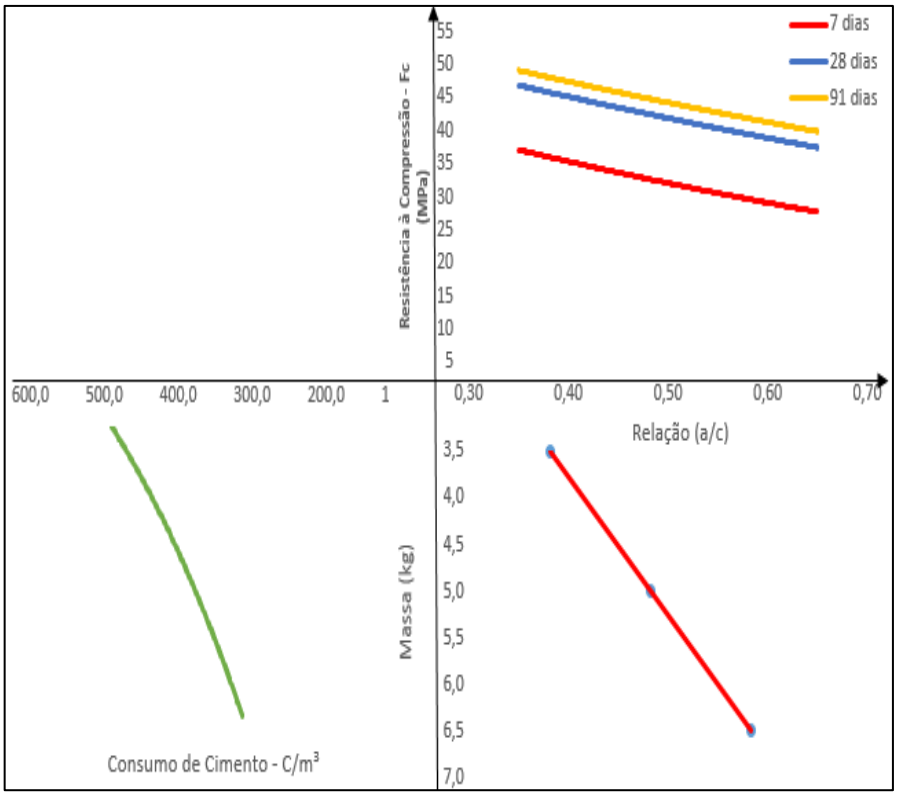

Fonte: Enio José Bolognini

5.2.12 Resultados de Resistência à Compressão do Concreto de Alta Resistência com Agregados Graúdos de Seixo Rolado B1

Na Tabela 42 (a), é possível observar os valores de resistência ä compressão (MPa) para as idades de 7, 28 e 91 dias, obtidos experimentalmente, juntamente com suas respectivas dosagens, para concreto confeccionado com cimento Portland CP III 40 – RS, microssílica, superplastificante e agregados graúdos de seixo rolado com diâmetro (B1). Na Tabela 42 (b), pode-se observar os valores de resistência, com suas respectivas dosagens, obtidos pela rede neural.

Tabela 42 (a) – Resultados de resistência à compressão (MPa) dos CARs para agregados graúdos de seixo rolado com diâmetro (B1)

Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5	Corpo de Prova	1:3,5	1:5,0	1:6,5
	Tensão (MPa)				Tensão (MPa)				Tensão (MPa)		
	7 dias	7 dias	7 dias		28 dias	28 dias	28 dias		91 dias	91 dias	91 dias
CP1	25,04	22,75	17,35	CP5	33,73	36,32	28,09	CP09	37,82	38,12	32,54
CP2	26,79	25,75	16,50	CP6	34,04	31,53	26,34	CP10	39,09	38,17	29,19
CP2	25,84	25,96	16,31	CP7	32,27	27,97	24,05	CP11	39,31	36,87	27,54
CP3	31,76	21,25	17,00	CP8	33,18	33,74	25,32	CP12	-	-	-
Média	27	24	17	**Média**	33	32	26	**Média**	39	38	30
σ	3	2,3	0,5	**σ**	0,8	3,5	1,7	**σ**	0,9	1	2,4

Tabela 42 (b) – Resultados dos treinamentos por redes neurais das dosagens dos CARs para agregados graúdos de seixo rolado com diâmetro (B1)

Idade	Mpa	Traço (c : a : b : a/c)	c : m
7	27	1:1,38:2,23:0,379	1:3,623
7	24	1:2,18:2,80:0,586	1:4,980
7	17	1:2,98:3,30:0,734	1:6,279
28	33	1:1,38:2,23:0,379	1:3,623
28	32	1:2,18:2,80:0,586	1:4,980
28	26	1:2,98:3,30:0,734	1:6,279
91	38	1:1,38:2,23:0,379	1:3,623
91	38	1:2,18:2,80:0,586	1:4,980
91	29	1:2,98:3,30:0,734	1:6,279

Os resultados do concreto de alta resistência (CAR) com britas de seixo rolado B1 para 7, 28 e 91 dias estão de acordo com o esperado. Houve um aumento das resistências com aumento da idade e do consumo de cimento.

A Figura 53 ilustra as curvas do diagrama de dosagem para agregados graúdos de seixo rolado com diâmetro (B1).

Figura 53 – Curvas do diagrama de dosagem dos CARs para dosagens: 1:3,5; 1:5,0 e 1:6,5 entre 7, 28 e 91 dias, referente aos agregados graúdos de seixo rolado com diâmetro (B1)

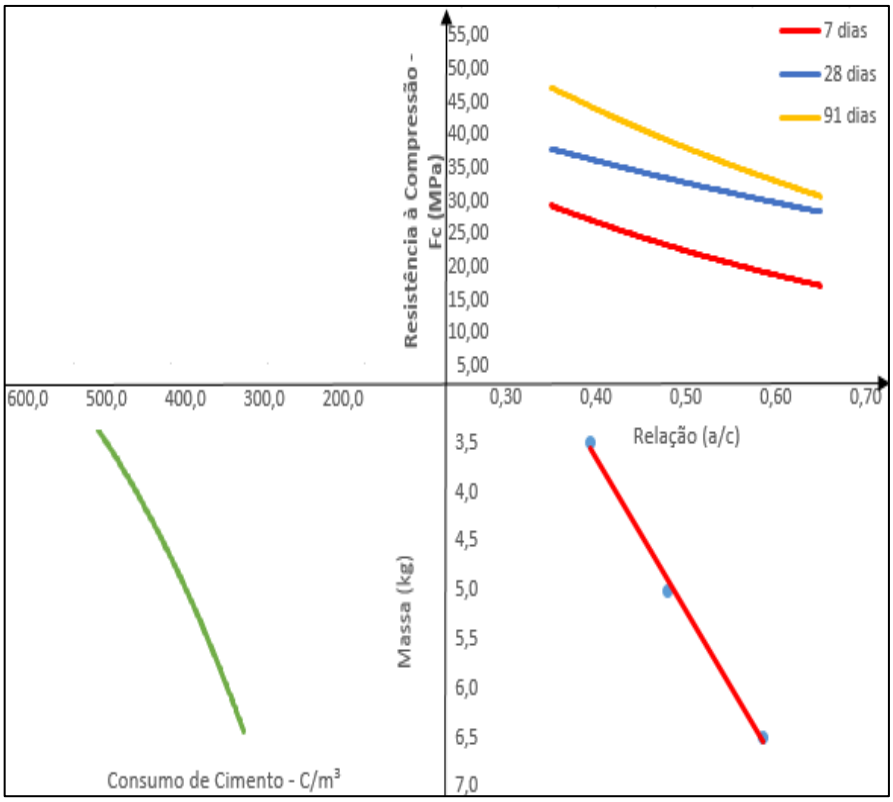

Fonte: Enio José Bolognini

5.3 REALIZAÇÃO DE TESTES DOS ERROS COM A REDE NEURAL

A fim de obter os erros gerados na rede neural apresentada na Figura 31, foram realizados quatro testes.

No primeiro teste foram escolhidos nove vetores resistências à compressão para uma rede de três camadas, com nove neurônios de entrada na camada um, dez neurônios na camada intermediária dois e quatro neurônios de saída na camada três (9 – 10 – 4).

Considerando as respostas de saída para cimento (kg), areia (kg), britas B1 (kg) e água (kg), foram apresentados os erros (ξ) através do *software* aplicativo, conforme ilustrado na Figura 54. Nesta rede, considerou-se no treinamento os seguintes valores de taxas: inclinação $\lambda = 0,2$, treinamento $\alpha = 0,5$, momento em $\eta = 0,68$ e o erro $\xi = 0,01$, para 300.000 ciclos.

Figura 54 – Resultados dos erros (ε) de três camadas

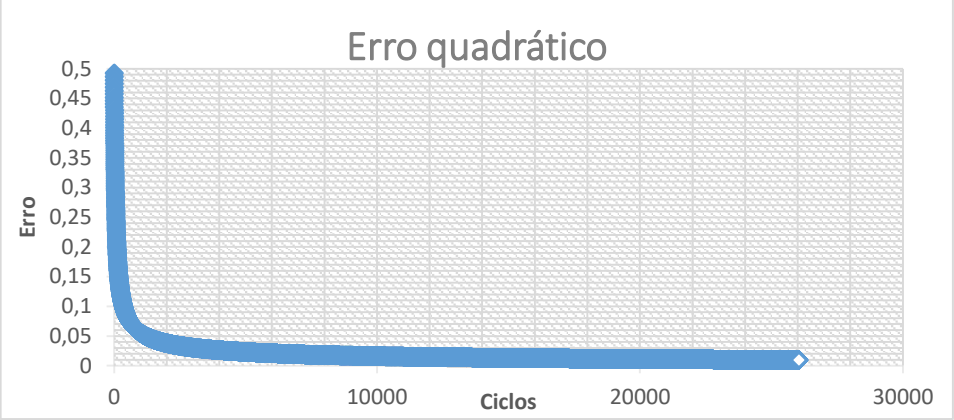

Fonte: Enio José Bolognini

Utilizando a ideia do teste anterior, foi realizado outro teste em uma rede de quatro camadas, com nove vetores de entrada, nove neurônios na camada um, dez neurônios na camada dois, nove neurônios na camada três e quatro neurônios de saída na camada quatro (9 – 10 – 9 – 4). A Figura 55, ilustra o erro em função do número de ciclos. Para obtenção da mesma, foram consideradas as seguintes taxas de treinamento: inclinação $\lambda = 0,2$, treinamento $\alpha = 0,5$, momento $\eta = 0,68$ e o erro $\xi = 0,01$, para 300.000 ciclos.

Figura 55 – Resultados dos erros (ε) de quatro camadas

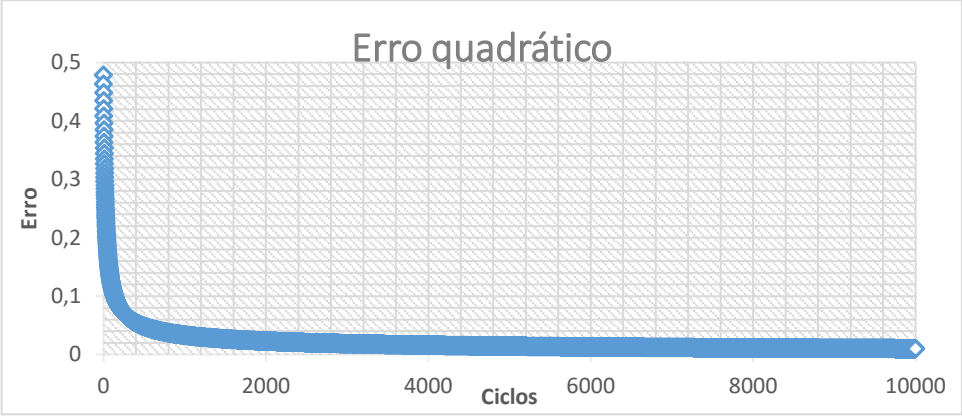

Fonte: Enio José Bolognini

Comparando estas duas redes, conclui-se que o tempo de geração do erro desejado ($\xi = 0,01$), na rede de três camada, foi alcançado em 26042 ciclos (Figura 55). Enquanto que, a rede com quatro camadas de neurônios alcançou o erro desejado ($\xi = 0,01$),

com 10015 ciclos. Então, pode-se concluir que o tempo de resposta na rede de quatro camadas, foi mais rápido em relação à rede de três camadas.

Foi realizado um novo teste com uma rede de três camadas, sendo considerados vinte sete vetores de entrada, vinte sete neurônios na camada um, vinte oito neurônios na camada dois e quatro neurônios na camada três (27 – 28 – 4). As camadas foram treinadas com dados anteriores: inclinação $\lambda = 0,2$, treinamento $\alpha = 0,5$, momento $\eta = 0,68$ e o erro $\xi = 0,01$, para 300.000 ciclos, conforme ilustra a Figura 56.

Figura 56 – Resultados dos erros (ε) de três camadas

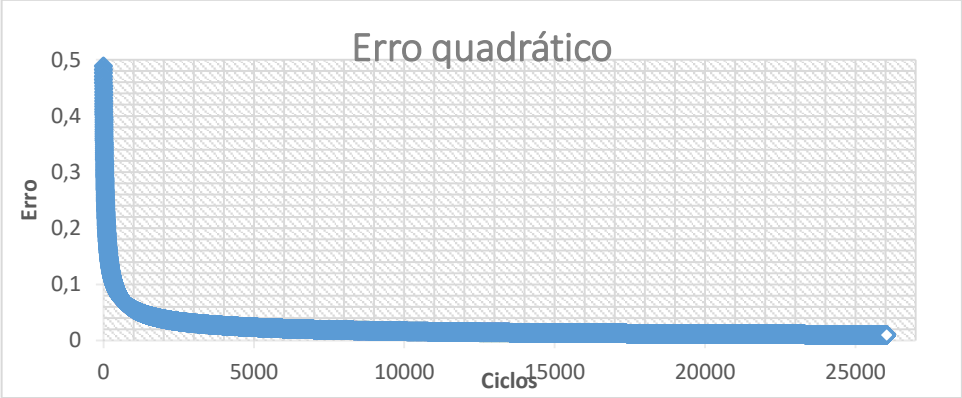

Fonte: Enio José Bolognini

A rede de três de camadas apresentadas na Figura 56, alcançou 26321 ciclos.

Após o treinamento, realiza-se um novo teste de rede com quatro camadas, sendo considerados nove vetores de entrada, com nove neurônios na camada um, dez neurônios na camada dois, nove neurônios na camada três, e sete neurônios de saída na camada quatro. Novamente foram utilizadas as mesmas taxas: inclinação $\lambda = 0,2$, treinamento $\alpha = 0,5$, momento em 0,68 e o erro $\xi = 0,01$, para 300.000 ciclos, conforme ilustra a Figura 57.

Figura 57 – Resultados dos erros (ε) de quatro camadas

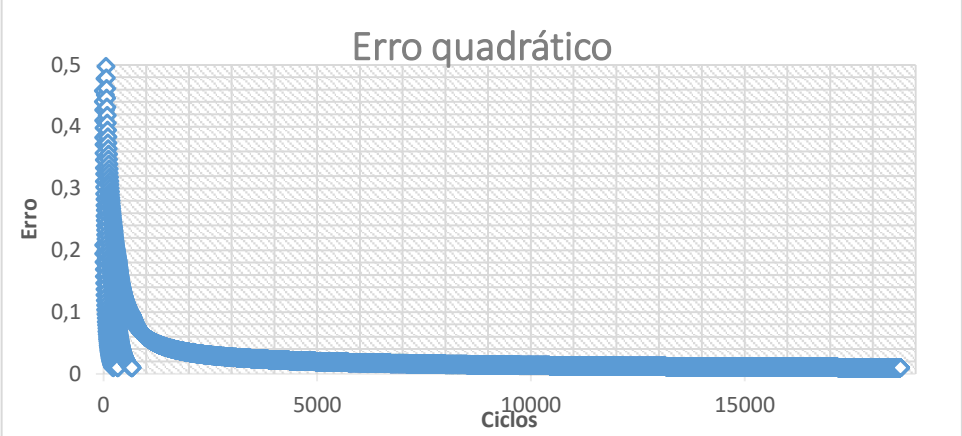

Fonte: Enio José Bolognini

Conforme se observa na Figura 57, as saídas dos erros desejados, apresentaram três resultados. Isto deve ter ocorrido devido à quantidade de vetores na camada de saída ter sido maior em relação ao teste realizado na Figura 56, também com quatro camadas. Comparando estas duas redes, conclui-se que o tempo de geração do erro desejado ($\xi = 0{,}01$), na rede de três camada, foi alcançado em 26321 ciclos (Figura 54). Enquanto que, a rede com quatro camadas de neurônios alcançou o erro desejado ($\xi = 0{,}01$), com 18715 ciclos.

Nota-se que as redundantes respostas de saída destas duas redes foram um pouco mais rápidas, mas a rede com quatro camadas, de acordo com a Figura 57, apresentou menor tempo de resposta em relação a rede com três camadas.

Assim, conclui-se que a rede, com quatro camadas, pode gerar com eficácia a confecção de concreto.

As redes com quatro camadas ou mais são conhecidas como super redes neurais *(Deep Learning Neural Network*), portanto, neste trabalho o objetivo final foi de obter resultados mais precisos, com a utilização desta super rede.

5.4 CONSIDERAÇÕES FINAIS

Os resultados obtidos nesta pesquisa mostraram que:

i. Como foi possível armazenar as resistências à compressão (MPa) em banco de dados, e, também variados tipos de cimentos e agregados

graúdos com diâmetros (B1 e B0). Foram obtidos do treinamento por redes os resultados para dosagens de concretos. Conclui-se que este método aplicado foi eficaz para confeccionar concretos por redes neurais;

ii. Nos ensaios realizados foram obtidos resultados satisfatórios com a variação dos aglomerantes hidráulicos na mistura da argamassa. De acordo com os tipos de concretos confeccionados, os materiais utilizados em diversas dosagens experimentais, pode-se obter resultados com a economia de cimento e preenchimento de espaços vazios na mistura dos diâmetros (B1/B0) para agregados graúdos;

iii. Os tipos de britas como basalto, granito e seixo rolado, preencheram os espaços vazios, com a mistura dos diâmetros (B1/B0) na confecção do concreto. Pode-se concluir que estes preenchimentos deixaram o concreto no tronco de cone totalmente lisos, e não houve aumento excessivo de argamassa. Também, podemos observar que houve um aumento de argamassa no seixo rolado devido ao preenchimento dos espaços vazios, pois foi necessário que o abatimento do concreto estivesse totalmente liso no tronco de cone;

iv. Também, foi possível a geração dos diagramas de dosagem dos concretos convencionais (CC) e de alta resistência (CAR), utilizando o *software Microsoft Excel*. Estes gráficos apresentaram curvas de resistência à compressão (MPa), para concretos convencionais e de alta resistência (misturada com microssílica e superplastificante);

v. Com relação a estas resistências à compressão (MPa), também foi possível obter estes resultados satisfatórios da mistura, pois o agregado miúdo obteve um módulo de finura excelente, e foi classificado como areia grossa.

vi. Foram realizadas diversas análises dos gráficos com relação a frequentes quedas ou aumentos de resistências à compressão aos 7, 28 e 91 dias. A análise da média e do desvio padrão nas dosagens (1 : 3,5; 1 : 5,0; 1 : 6,5), foi fundamental para que futuramente possam realizar novas confecções de concreto, a fim de melhorar o desempenho destes gráficos;

vii. Realizados testes com a rede neural artificial do algoritmo de aprendizagem por retropropagação (*backpropagation*), foi observado

nas redes de quatro camadas *(Deep Learning Neural Network*), a velocidade do tempo de resposta em 300.000 ciclos. É fundamental que a rede neural com quatro camadas de neurônios, seja muito mais rápida devido a quantidade de neurônios, pois quanto maior o número de neurônios menor o tempo de resposta. Otimizando a confecção de concreto por meio da metodologia de super redes *(Deep Learning Neural Network*), foram obtidos os valores de saída para cimento (kg), agregado miúdo (kg), agregado graúdo (kg) e água (kg), com poucos ciclos aceitos do erro estipulado;

viii. Utilizando a IDE *Netbeans* e a programação *Java*, foi necessário realizar a construção de funções de otimização na programação orientada a objetos (OO), para realizar os cálculos por meio de classes encapsuladas e de classes estáticas. Pois, sendo estruturadas desde a classe principal até as classes de sub-rotina, foi possível programar a interface de controle para dosagem de concreto. Também, foi enfatizado a necessidade de classes de cadastro de novos materiais e para resistências, a fim de otimizar outros tipos de concretos.

ix. Pode-se afirmar que o desenvolvimento do *software* com interface gráfica facilitou os estudos deste trabalho. Quando testados dentro da rede neural para confeccionar os concretos, foi possível testar vários tipos de aglomerantes hidráulicos e agregados graúdos com diâmetros (B0 e B1). Também, conclui-se que foi necessário confeccionar um manual de instruções para que usuários do *software*, possam instalar e manusear a ferramenta, onde ficará disponível para pesquisas e estudos científicos.

Todos estes testes estão ilustrados nos anexos C e D.

No anexo I, são apresentas as equações de cálculo referente a Figura 31, que foram utilizadas neste trabalho.

No anexo II, ilustra-se as planilhas do *software* aplicativo *Microsoft Excel*, que foram utilizadas neste trabalho.

No anexo III, foi ilustrado a produção de concreto com volume de um metro cúbico (1 m^3), sendo geradas as planilhas do *software* aplicativo *Microsoft Excel*.

Nos anexos IV e V, são ilustradas as realizações dos testes para confeccionar concretos, com o *software* aplicativo DECCONCRETO.

6 CONCLUSÃO

Como os diagramas de dosagem dos concretos convencionais e de alta resistência apresentaram diferentes resistências para os diferentes materiais, pode-se então concluir a importância de um *software* para agilizar o cálculo da dosagem.

É necessário que os cálculos de dosagem obtenham dados precisos, pois evitaria o desperdício de materiais. Contudo, estes mesmos cálculos, podem ser realizados por um *software* de dosagem que pode apresentar resultados em tempo real, onde aumenta a economia dos materiais e diminui o tempo de respostas.

Ao realizar os testes com algoritmo de aprendizagem usando retropropagação (*backpropagation*), os erros (ξ) diminuíram nas saídas para estas super redes de quatro camadas. Também, pode-se concluir que aumento do número de neurônios da super rede neural, com quatro camadas, o tempo de resposta foi menor e a otimização das respostas de saída foram obtidos com precisão.

Destaca-se neste trabalho o método numérico na elaboração da super rede neural de quatro camadas. Foram utilizadas funções não lineares para que pudessem obter as matrizes de pesos durante o treinamento e, também, do ajuste de pesos, para que possam armazenar somente as matrizes de pós treinamento. Conclui-se que neste método numérico, foi possível obter os melhores resultados de treinamentos e armazena-los, a fim de utilizar somente como funções de cálculo na rede, para gerar novas simulações de confecção de concreto.

Pode-se concluir que a simulação com redes neurais para diversas dosagens de concretos experimentais (1 : 3,5, 1 : 5,0 e 1 : 6,5), está permitindo otimizar o concreto, para obter respostas dos valores das dosagens (c : a : b : a/c) em massa (kg) e, também, o teor de argamassa ideal (α). Conclui-se que a otimização do concreto depende de um armazenamento de vários resultados de resistência à compressão (MPa) e, também, de materiais, para que possa obter a dosagem do concreto.

Outros materiais foram inseridos na argamassa de concreto, com objetivo de obter novos resultados e armazena-los no *software*. Estes materiais, são a base da mistura para concretos de alta resistência (CAR), como é o caso da microssílica e do superplastificante.

Bases de concretos de alta resistência (CAR), tem como objetivo de obter uma consistência plástica (ou uma trabalhabilidade), ou seja, estes concretos foram otimizados

utilizando as resistências à compressão (MPa), que foram armazenadas no *software* bem como os materiais.

As simulações de saída bem como o erro quadrático da super rede neural, com quatro camadas, também, foram precisos ao obter um menor tempo de resposta e com poucas interações. Foram obtidas as massas (kg) de agregados graúdos, agregados miúdos, cimento, água, microssílica e superplastificante. Estas respostas são conclusivas, para que o objetivo de otimizar o concreto fosse completado.

O custo computacional com relação ao *software*, foi analisado durante os tempos de processamento nos computadores, que realizaram os testes. Estes processos geraram pouco processamento de memória para obter os resultados no *software*, portanto, conclui-se que o mesmo não gera custo computacional.

O objetivo do trabalho foi elaborar esta rede neural para otimizar vários tipos de confecções de concreto, onde destacamos as simulações realizadas com o *software*. Pois, é necessário enfatizar que ao utilizar o *software* de otimização de concreto, pode-se concluir que este evita desperdícios de materiais e, obtém resultados experimentais mais confiáveis.

Nesta interface gráfica, o usuário poderá pesquisar e concluir os estudos para confecções de concretos, buscando resultados com qualidade e precisão.

É proposta a continuação deste trabalho para ensaiar outros tipos de concretos, com variados tipos de cimentos Portland, agregados graúdos, agregados miúdos e a utilização de aditivos no concreto. Com a obtenção destes novos resultados, estes podem ser armazenados no banco de dados para realizar novos treinamentos por redes neurais, a fim de obter os valores em massa (kg) para novas confecções de concreto.

REFERÊNCIAS

ABDEEN, M. A. M.; HODHOD, H. Analytic formulae for concrete mix design based on experimental data base and predicting the concrete behavior using ANN technique. **International Journal of Engineering**, Kuala Lumpur, v. 4, p. 368-386, 2010.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM 26**: agregados - amostragem. Rio de Janeiro: ABNT, 2001.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM 27**: agregados – redução da amostra de campo para ensaios em laboratório. Rio de Janeiro: ABNT, 2001.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM 30**: agregado miúdo - determinação da absorção de água. Rio de Janeiro: ABNT, 2001.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM 52**: determinação da massa específica aparente e absorção de água de agregados miúdos. Rio de Janeiro: ABNT, 2009.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM 53**: agregado graúdo - Determinação de massa específica, massa específica aparente e absorção de água. Rio de Janeiro: ABNT, 2009.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 5732**: cimento portland comum. Rio de Janeiro: ABNT, 1991.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 5733**: cimento portland com alta resistencia inicial. Rio de Janeiro: ABNT, 1991.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 5735**: cimento portland de alto-forno. Rio de Janeiro: ABNT, 1991.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 5736**: cimento portland pozolânico. Rio de Janeiro: ABNT, 1991.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 5737**: cimento portland resistentes a sulfatos. Rio de Janeiro: ABNT, 1992.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 11578**: cimento portland composto. Rio de Janeiro: ABNT, 1997.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 5739**: concreto ensaio de compressão de corpos de prova cilíndricos. Rio de Janeiro: ABNT, 2007.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 5738**: moldagem e cura de corpos de prova cilíndricos ou prismáticos de concreto. Rio de Janeiro: ABNT, 2003.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM 7211**: agregados para concretos – especificação. Rio de Janeiro: ABNT, 2009.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM 67**: concreto – determinação da consistência pelo abatimento do tronco de cone. Rio de Janeiro: ABNT, 1998.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM 248**: agregados – determinação da composição granulométrica. Rio de Janeiro: ABNT, 2003.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 6118**: projeto de estruturas de concreto- procedimento. Rio de Janeiro: ABNT, 2007.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM-ISSO 3310**-1: peneiras de ensaio - requisitos técnicos e verificação - parte 1: peneiras de ensaio com tela de tecido metálico. Rio de Janeiro. ABNT, 1997.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM-ISSO 3310**-2: peneiras de ensaio - requisitos técnicos e verificação - parte 2: peneiras de ensaio de chapa metálica perfurada. Rio de Janeiro. ABNT, 1997.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR NM ISSO 7500**-1: materiais metálicos - calibração de máquinas de ensaio estático uniaxial – parte 1: máquinas de ensaio de tração/compressão - calibração do sistema de medição da força. Rio de Janeiro. ABNT, 2004.

BADDE, D. S. et al. Cascade and feed forward back propagation artificial neural network models for prediction of compressive strength of ready mix concrete. **IOSR Journal of Mechanical and Civil Engineering**, Uttar Pradesh, v. 3, p. 1-6, 2013.

CAMPOS, J. R. et al. Implementação de redes neurais artificiais utilizando a linguagem de programação Java. In: PROCEEDINGS OF THE BRAZILIAN CONFERENCE ON DYNAMICS CONTROL AND THEIR APPLICATIONS, 9, 2010, Serra Negra. **Proceedings of the…** Serra Negra: [S.n.], 2010. p. 391-397. Disponível em: < http://www.sbmac.org.br/dincon/trabalhos/PDF/control/67995.pdf>. Acesso em: 05 out. 2016.

CAZACLIU, B. et al. New methods for accurate water dosage in concrete central mix plants., **Materials and Structures**, Dordrecht, v. 41, p. 1681-1696, 2008.

COLOMBO, I. G. et al. Textile reinforced concrete: experimental investigation on design parameters. **Materials and Structures**, Dordrecht , v. 46, p. 1933-1951, 2013.

DRAGAN, B. et al. application of neural networks in determination of compressive strength of concrete. **Romanian Journal of Materials**, Bucarest, v. 42, n. 1, p. 16 – 22, 2012.

DEITEL, H. M.; DEITEL, P. J. **Java**: como programar. 6. ed. São Paulo: Pearson Education, 2005. 1110 p.

DIAMOND, S.; SAHU, S. Densified silica fume: particle sizes and dispersion in concrete. **Materials and Structures**, Dordrecht, v. 39, p. 849-859, 2006.

ELGIN, N. N.; SENOUCI, A. B. Measurement and Prediction of the Strength of Rubberized Concrete. **Cement & Concrete Composites**, Kidlington, v. 16, p. 287 – 298, 1994.

FLATT, R. J. Towards a prediction of superplasticized concrete rheology. **Materials and Structures**, Dordrecht , v. 37, p. 289-300, 2004.

GUPTA, S. Concrete mix design: using artificial neural network. **Journal on Today's Ideas – Tomorrow's Technologies**, v. 1, n. 1, p. 29–43, 2013. Disponível em: < http://jotitt.chitkara.edu.in/pdf/JOTTITT_Sakshi%20Gupta_new_V3.pdf>. Acesso em: 04 out. 2016.

HASAN, M. M.; KABIR, A. Artificial neural network for concrete mix design. In:UKIERI CONCRETE CONGRESS - INNOVATIONS IN CONCRETE CONSTRUCTION, 4, 2013, Jalandhar. **Proceedings of the...** Jalandhar: [S.n.], 2013. p. 1754-1764.

HAYKIN, S. **Redes neurais**: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HELENE, P.; TERZIAN, P. **Manual de dosagem e controle do concreto**. São Paulo: Pini, 1993. 349 p.

JO, W. B. et al. Investigations on the development of powder concrete with nano-SiO2 particles. **KSCE Journal of Civil Engineering**, Seoul, v. 11, n. 1, p. 37 – 42, 2007.

KARAYIANNIS N. B.; VENETSANOPOULOS, A. N. **Artificial neural networks**: learning algorithms, performance evaluation, and applications. Norwell. Massachusetts: Kluwer, 1993. 440 p.

KIM, S. H. et al. Effect of temperature-induced load on airport concrete pavement behavior. **KSCE Journal of Civil Engineering**, Heidelberg, v. 18, p. 182-187, 2014.

MATIAS, D. et al. Mechanical properties of concrete produced with recycled coarse aggregates – Influence of the use of superplasticizers. **Construction and Building Materials**, Amsterdam, v. 44, p. 101-109, 2013.

MINUSSI, C. R.; LOTUFO, A, D. **Redes neurais**: introdução e principais conceitos. Ilha Solteira: Departamento de Engenharia Elétrica; FEIS/UNESP, 2007. 86 p.

MORETTI, J. F. S**istema inteligente baseado na redes neurais artificiais para dosagem do concreto**. 2010. 95 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

NESHAT, M. et al. Predication of concrete mix design using adaptive neural fuzzy inference systems and fuzzy inference systems. **International Journal of Advanced Manufacturing Technology**, London, v. 63, n. 1, p. 373–390, 2012.

PILEGGI, R. G. **Ferramentas para o estudo e desenvolvimento de concretos refratários**. 2001. 204 f. Tese (Doutorado em Ciência e Engenharia de Materiais) - Universidade Federal de São Carlos, São Carlos, 2001.

PRESSMAN, R. S. **Engenharia de software**. 7. ed. São Paulo: AMGH, 2011. 764 p.

REIS, J. F. A. **Determinação de parâmetros reológicos de concretos através do ensaio de abatimento de tronco de cone modificado:** estudo de caso. 2008. Dissertação (Mestrado em Estruturas) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2008. Ispon´vel em: < http://repositorio.unesp.br/bitstream/handle/11449/94495/reis_jfa_me_ilha.pdf?sequence=1&isAllowed=y>. Acesso em: 26 out. 2016.

SILVEIRA, P. M. **Estudo da resistência à fadiga de concretos de cimento Portland para pavimentação com adição de borracha**. 2013. 116 f. Dissertação (Mestrado em Estruturas) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira.

VILLA, F. M. F. **Propriedades mecânicas de concreto com borracha**. 2012. 79 f. Dissertação (Mestrado em Estruturas) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.

YOUNIS, K. H.; PILAKOUTAS, K. Strength prediction model and methods for improving recycled aggregate concrete. **Construction and Building Materials**, Amsterdam, v. 49, p. 688-701, 2013.

YURDAKUL, E. et al. Effect of Paste-to-Voids Volume Ratio on the Performance of Concrete Mixtures. **Journal of Materials in Civil Engineering**, Resto, v. 25, p.1840-1851, 2013.

ANEXOS

ANEXO I - Elaboração das equações referentes ao algoritmo *backpropagation* Redes Neurais Artificiais

Matrizes de pesos das camadas referentes a Figura 31.

$$W_{ij} = \begin{bmatrix} w_{11} & w_{12} & w_{13} & w_{14} \\ w_{21} & w_{22} & w_{23} & w_{24} \\ w_{31} & w_{32} & w_{33} & w_{34} \\ w_{41} & w_{42} & w_{43} & w_{44} \\ w_{01} & w_{02} & w_{03} & w_{04} \end{bmatrix}$$ matriz de pesos da camada 1 de entrada;

[Eq. A.1]

$$U_{ij} = \begin{bmatrix} u_{11} & u_{12} & u_{13} & u_{14} & u_{15} \\ u_{21} & u_{22} & u_{23} & u_{24} & u_{25} \\ u_{31} & u_{32} & u_{33} & u_{34} & u_{35} \\ u_{41} & u_{42} & u_{43} & u_{44} & u_{45} \\ u_{01} & u_{02} & u_{03} & u_{04} & u_{05} \end{bmatrix}$$ matriz de pesos da camada 2 escondida;

[Eq. A.2]

$$V_{ij} = \begin{bmatrix} v_{11} & v_{12} & v_{13} & v_{14} \\ v_{21} & v_{22} & v_{23} & v_{24} \\ v_{31} & v_{32} & v_{33} & v_{34} \\ v_{41} & v_{42} & v_{43} & v_{44} \\ v_{51} & v_{52} & v_{53} & v_{54} \\ v_{01} & v_{02} & v_{03} & v_{04} \end{bmatrix}$$ matriz de pesos da camada 3 escondida;

[Eq. A.3]

$$Z_{ij} = \begin{bmatrix} z_{11} \\ z_{21} \\ z_{31} \\ z_{41} \\ z_{01} \end{bmatrix}$$ matriz de pesos da camada 4 de saída. [Eq. A.4]

A fim de obter as funções sigmóides (B_{ij}), foram realizados os cálculos com as equações Eq. A1, 2.2 e 2.4, multiplicando a entrada dos vetores, com a matriz de pesos (Eq. A.1) e obtendo a soma (A_{ij}).

$$A_1 = w_{11}\times x_1 + w_{21}\times x_2 + w_{31}\times x_3 + w_{41}\times x_4 + w_{01} \quad \text{[Eq. A.5]}$$
$$A_2 = w_{12}\times x_1 + w_{22}\times x_2 + w_{32}\times x_3 + w_{42}\times x_4 + w_{02} \quad \text{[Eq. A.6]}$$
$$A_3 = w_{13}\times x_1 + w_{23}\times x_2 + w_{33}\times x_3 + w_{43}\times x_4 + w_{03} \quad \text{[Eq. A.7]}$$
$$A_4 = w_{14}\times x_1 + w_{24}\times x_2 + w_{34}\times x_3 + w_{44}\times x_4 + w_{04} \quad \text{[Eq. A.8]}$$

Sendo que o cálculo das funções sigmóides foram:

$$f(B_1) = \frac{1-e^{-\lambda\times A_1}}{1+e^{-\lambda\times A_1}} \quad \text{[Eq. A.9]}$$
$$f(B_2) = \frac{1-e^{-\lambda\times A_2}}{1+e^{-\lambda\times A_2}} \quad \text{[Eq. A.10]}$$
$$f(B_3) = \frac{1-e^{-\lambda\times A_3}}{1+e^{-\lambda\times A_3}} \quad \text{[Eq. A.11]}$$
$$f(B_4) = \frac{1-e^{-\lambda\times A_4}}{1+e^{-\lambda\times A_4}} \quad \text{[Eq. A.12]}$$

Na camada dois foram realizados os cálculos com as equações Eq. A2, 2.2 e 2.4, para multiplicar as saídas (B_{ij}) das funções sigmóides (D_{ij}), a fim de obter a soma (C_{ij}) com os pesos da camada dois e, gerando os valores de saída das funções sigmóides (D_{ij}).

$$C_1 = u_{11}\times b_1 + u_{21}\times b_2 + u_{31}\times b_3 + u_{41}\times b_4 + u_{01} \quad \text{[Eq. A.13]}$$
$$C_2 = u_{12}\times b_1 + u_{22}\times b_2 + u_{32}\times b_3 + u_{42}\times b_4 + u_{02} \quad \text{[Eq. A.14]}$$
$$C_3 = b_{13}\times b_1 + u_{23}\times b_2 + u_{33}\times b_3 + u_{43}\times b_4 + u_{03} \quad \text{[Eq. A.15]}$$
$$C_4 = u_{14}\times b_1 + u_{24}\times b_2 + u_{34}\times b_3 + u_{44}\times b_4 + u_{04} \quad \text{[Eq. A.16]}$$
$$C_5 = u_{15}\times b_1 + u_{25}\times b_2 + u_{35}\times b_3 + u_{45}\times b_4 + u_{05} \quad \text{[Eq. A.17]}$$

Sendo que o cálculo das funções sigmóides foram:

$$f(D_1) = \frac{1-e^{-\lambda \times C_1}}{1+e^{-\lambda \times C_1}} \quad \text{[Eq. A.18]}$$

$$f(D_2) = \frac{1-e^{-\lambda \times C_2}}{1+e^{-\lambda \times C_2}} \quad \text{[Eq. A.19]}$$

$$f(D_3) = \frac{1-e^{-\lambda \times C_3}}{1+e^{-\lambda \times C_3}} \quad \text{[Eq. A.20]}$$

$$f(D_4) = \frac{1-e^{-\lambda \times C_4}}{1+e^{-\lambda \times C_4}} \quad \text{[Eq. A.21]}$$

$$f(D_5) = \frac{1-e^{-\lambda \times C_5}}{1+e^{-\lambda \times C_5}} \quad \text{[Eq. A.22]}$$

A camada três é calculada com as equações Eq. A.3, 2.2 e 2.4, para multiplicar as saídas da função sigmóides (D_{ij}), a fim de obter a soma (E_{ij}) com os pesos da camada três e gerar os valores de saída das funções sigmóides (F_{ij}).

$$E_1 = v_{11} \times d_1 + v_{21} \times d_2 + v_{31} \times d_3 + v_{41} \times d_4 + v_{51} \times d_5 + v_{01} \quad \text{[Eq. A.23]}$$

$$E_2 = v_{12} \times d_1 + v_{22} \times d_2 + v_{32} \times d_3 + v_{42} \times d_4 + v_{52} \times d_5 + v_{05} \quad \text{[Eq. A.24]}$$

$$E_3 = v_{13} \times d_1 + v_{23} \times d_2 + v_{33} \times d_3 + v_{43} \times d_4 + v_{53} \times d_5 + v_{01} \quad \text{[Eq. A.25]}$$

$$E_4 = v_{14} \times d_1 + v_{24} \times d_2 + v_{34} \times d_3 + v_{44} \times d_4 + v_{54} \times d_5 + v_{01} \quad \text{[Eq. A.26]}$$

Sendo que o cálculo das funções sigmóides foram:

$$f(F_1) = \frac{1-e^{-\lambda \times E_1}}{1+e^{-\lambda \times E_1}} \quad \text{[Eq. A.27]}$$

$$f(F_2) = \frac{1-e^{-\lambda \times E_2}}{1+e^{-\lambda \times E_2}} \quad \text{[Eq. A.28]}$$

$$f(F_3) = \frac{1-e^{-\lambda \times E_3}}{1+e^{-\lambda \times E_3}} \quad \text{[Eq. A.29]}$$

$$f(F_4) = \frac{1-e^{-\lambda \times E_4}}{1+e^{-\lambda \times E_4}} \quad \text{[Eq. A.30]}$$

A camada quatro é calculada com as equações Eq. A.4, 2.2 e 2.4, para multiplicar as saídas da função sigmóide da (F_{ij}), a fim de obter a soma (G_{ij}) com os pesos da camada quatro e gerar o valor de saída da função sigmóide (Y_i):

$$G_1 = z_{11}\times f_1 + z_{21}\times f_2 + z_{31}\times f_3 + z_{41}\times f_4 + z_{01} \quad \text{[Eq. A.31]}$$

Sendo que o cálculo da função sigmóide foi:

$$f(Y_1) = \frac{1-e^{-\lambda\times G_1}}{1+e^{-\lambda\times G_1}} \quad \text{[Eq. A.32]}$$

Na retropropagação (*backpropagation*) foi gerado um erro na saída da camada quatro. Então, para atualizar os pesos da camada quatro, foram obtidos os valores do erro (ε_i^4) e ângulos θ e δ. Estes valores geram o ajuste dos pesos através da função (σ_i), para representar o (k + 1) – ésima destes pesos. Com a equação Eq. A.37, pode-se este ajustar os pesos utilizando as equações Eq. 2.8, 2.12, 2.13 e 2.15:

$$\sigma_1^{(4)} = 2\alpha\varepsilon_1^{(4)}\theta_1^{(4)} \quad \text{[Eq. A.33]}$$

$$\varepsilon_1^{(4)} = d_1 - y_1 \quad \text{[Eq. A.34]}$$

$$\theta_1^{(4)} = d(G_1) = 0{,}5\lambda(1 - y_1) \quad \text{[Eq. A.35]}$$

$$\delta_1^{(4)} = \varepsilon_1^{(4)}\theta_1^{(4)} \quad \text{[Eq. A.36]}$$

$$\begin{bmatrix} z_{11} \\ z_{21} \\ z_{31} \\ z_{41} \\ z_{01} \end{bmatrix}^{k+1} = \begin{bmatrix} z_{11} \\ z_{21} \\ z_{31} \\ z_{41} \\ z_{01} \end{bmatrix}^{k} + \sigma_1^{(4)}\times \begin{bmatrix} F_1 \\ F_2 \\ F_3 \\ F_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.37]}$$

Na camada três foi necessário receber os valores de ($\delta_i^{(4)}$), para calcular o erro ($\varepsilon_i^{(3)}$) e ajustar os pesos. Com as equações Eq. A.42, A.47, A.52 e A.57, pode-se este ajustar os pesos utilizando as equações Eq. 2.8, 2.12, 2.13 e 2.15:

$$\sigma_1^{(3)} = 2\alpha\varepsilon_1^{(3)}\theta_1^{(3)} \quad \text{[Eq. A.38]}$$

$$\varepsilon_1^{(3)} = z_{11}\delta_1^{(4)} \quad \text{[Eq. A.39]}$$

$$\theta_1^{(3)} = d(E_1) = 0{,}5\lambda(1 - F_1) \quad \text{[Eq. A.40]}$$

$$\delta_1^{(3)} = \varepsilon_1^{(3)}\theta_1^{(3)} \quad \text{[Eq. A.41]}$$

$$\begin{bmatrix} v_{11} \\ v_{21} \\ v_{31} \\ v_{41} \\ v_{51} \\ v_{01} \end{bmatrix}^{k+1} = \begin{bmatrix} v_{11} \\ v_{21} \\ v_{31} \\ v_{41} \\ v_{51} \\ v_{01} \end{bmatrix}^{k} + \sigma_1^{(3)} \times \begin{bmatrix} D_1 \\ D_2 \\ D_3 \\ D_4 \\ D_5 \\ 1 \end{bmatrix} \text{[Eq. A.42]}$$

$$\sigma_2^{(3)} = 2\alpha\varepsilon_2^{(3)}\theta_2^{(3)} \quad \text{[Eq. A.43]}$$

$$\varepsilon_2^{(3)} = z_{21}\delta_1^{(4)} \quad \text{[Eq. A.44]}$$

$$\theta_2^{(3)} = d(E_2) = 0{,}5\lambda(1 - F_2) \quad \text{[Eq. A.45]}$$

$$\delta_2^{(3)} = \varepsilon_2^{(3)}\theta_2^{(3)} \quad \text{[Eq. A.46]}$$

$$\begin{bmatrix} v_{12} \\ v_{22} \\ v_{32} \\ v_{42} \\ v_{52} \\ v_{02} \end{bmatrix}^{k+1} = \begin{bmatrix} v_{12} \\ v_{22} \\ v_{32} \\ v_{42} \\ v_{52} \\ v_{02} \end{bmatrix}^{k} + \sigma_2^{(3)} \times \begin{bmatrix} D_1 \\ D_2 \\ D_3 \\ D_4 \\ D_5 \\ 1 \end{bmatrix} \text{[Eq. A.47]}$$

$$\sigma_3^{(3)} = 2\alpha\varepsilon_3^{(3)}\theta_3^{(3)} \quad \text{[Eq. A.48]}$$

$$\varepsilon_3^{(3)} = z_{31}\delta_1^{(4)} \quad \text{[Eq. A.49]}$$

$$\theta_3^{(3)} = d(E_3) = 0{,}5\lambda(1 - F_3) \quad \text{[Eq. A.50]}$$

$$\delta_3^{(3)} = \varepsilon_3^{(3)}\theta_3^{(3)} \quad \text{[Eq. A.51]}$$

$$\begin{bmatrix} v_{13} \\ v_{23} \\ v_{33} \\ v_{43} \\ v_{53} \\ v_{03} \end{bmatrix}^{k+1} = \begin{bmatrix} v_{13} \\ v_{23} \\ v_{33} \\ v_{43} \\ v_{53} \\ v_{03} \end{bmatrix}^{k} + \sigma_3^{(3)} \times \begin{bmatrix} D_1 \\ D_2 \\ D_3 \\ D_4 \\ D_5 \\ 1 \end{bmatrix} \quad \text{[Eq. A.52]}$$

$$\sigma_4^{(3)} = 2\alpha\varepsilon_4^{(3)}\theta_4^{(3)} \quad \text{[Eq. A.53]}$$

$$\varepsilon_4^{(3)} = z_{41}\delta_1^{(4)} \quad \text{[Eq. A.54]}$$

$$\theta_4^{(3)} = d(E_4) = 0{,}5\lambda(1 - F_4) \quad \text{[Eq. A.55]}$$

$$\delta_4^{(3)} = \varepsilon_4^{(3)}\theta_4^{(3)} \quad \text{[Eq. A.56]}$$

$$\begin{bmatrix} v_{14} \\ v_{24} \\ v_{34} \\ v_{44} \\ v_{54} \\ v_{04} \end{bmatrix}^{k+1} = \begin{bmatrix} v_{14} \\ v_{24} \\ v_{34} \\ v_{44} \\ v_{54} \\ v_{04} \end{bmatrix}^{k} + \sigma_4^{(3)} \times \begin{bmatrix} D_1 \\ D_2 \\ D_3 \\ D_4 \\ D_5 \\ 1 \end{bmatrix} \quad \text{[Eq. A.57]}$$

Com os valores de ($\delta_i^{(3)}$) foi necessário calcular os valores dos erros ($\varepsilon_i^{(2)}$), para ajustar os pesos na camada dois. Com as equações Eq. A.62, A.67, A.72, A.77 e A.82, pode-se este ajustar os pesos utilizando as equações Eq. 2.8, 2.12, 2.13 e 2.15:

$$\sigma_1^{(2)} = 2\alpha\varepsilon_1^{(2)}\theta_1^{(2)} \quad \text{[Eq. A.58]}$$

$$\varepsilon_1^{(2)} = v_{11}\delta_1^{(3)} + v_{12}\delta_2^{(3)} + v_{13}\delta_3^{(3)} + v_{14}\delta_4^{(3)} \quad \text{[Eq. A.59]}$$

$$\theta_1^{(2)} = d(C_1) = 0{,}5\lambda(1 - D_1) \quad \text{[Eq. A.60]}$$

$$\delta_1^{(2)} = \varepsilon_1^{(2)}\theta_1^{(2)} \quad \text{[Eq. A.61]}$$

$$\begin{bmatrix} u_{11} \\ u_{21} \\ u_{31} \\ u_{41} \\ u_{01} \end{bmatrix}^{k+1} = \begin{bmatrix} u_{11} \\ u_{21} \\ u_{31} \\ u_{41} \\ u_{01} \end{bmatrix}^{k} + \sigma_1^{(2)} \times \begin{bmatrix} B_1 \\ B_2 \\ B_3 \\ B_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.62]}$$

$$\sigma_2^{(2)} = 2\alpha\varepsilon_2^{(2)}\theta_2^{(2)} \quad \text{[Eq. A.63]}$$

$$\varepsilon_2^{(2)} = v_{21}\delta_1^{(3)} + v_{22}\delta_2^{(3)} + v_{23}\delta_3^{(3)} + v_{24}\delta_4^{(3)} \quad \text{[Eq. A.64]}$$

$$\theta_2^{(2)} = d(C_2) = 0{,}5\lambda(1 - D_2) \quad \text{[Eq. A.65]}$$

$$\delta_2^{(2)} = \varepsilon_2^{(2)}\theta_2^{(2)} \quad \text{[Eq. A.66]}$$

$$\begin{bmatrix} u_{12} \\ u_{22} \\ u_{32} \\ u_{42} \\ u_{02} \end{bmatrix}^{k+1} = \begin{bmatrix} u_{12} \\ u_{22} \\ u_{32} \\ u_{42} \\ u_{02} \end{bmatrix}^{k} + \sigma_2^{(2)} \times \begin{bmatrix} B_1 \\ B_2 \\ B_3 \\ B_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.67]}$$

$$\sigma_3^{(2)} = 2\alpha\varepsilon_3^{(2)}\theta_3^{(2)} \quad \text{[Eq. A.68]}$$

$$\varepsilon_3^{(2)} = v_{31}\delta_1^{(3)} + v_{32}\delta_2^{(3)} + v_{33}\delta_3^{(3)} + v_{34}\delta_4^{(3)} \quad \text{[Eq. A.69]}$$

$$\theta_3^{(2)} = d(C_3) = 0{,}5\lambda(1 - D_3) \quad \text{[Eq. A.70]}$$

$$\delta_3^{(2)} = \varepsilon_3^{(2)}\theta_3^{(2)} \quad \text{[Eq. A.71]}$$

$$\begin{bmatrix} u_{13} \\ u_{23} \\ u_{33} \\ u_{43} \\ u_{03} \end{bmatrix}^{k+1} = \begin{bmatrix} u_{13} \\ u_{23} \\ u_{33} \\ u_{43} \\ u_{03} \end{bmatrix}^{k} + \sigma_3^{(2)} \times \begin{bmatrix} B_1 \\ B_2 \\ B_3 \\ B_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.72]}$$

$$\sigma_4^{(2)} = 2\alpha\varepsilon_4^{(2)}\theta_4^{(2)} \quad \text{[Eq. A.73]}$$

$$\varepsilon_4^{(2)} = v_{41}\delta_1^{(3)} + v_{42}\delta_2^{(3)} + v_{43}\delta_3^{(3)} + v_{44}\delta_4^{(3)} \quad \text{[Eq. A.74]}$$

$$\theta_4^{(2)} = d(C_4) = 0{,}5\lambda(1 - D_4) \quad \text{[Eq. A.75]}$$

$$\delta_4^{(2)} = \varepsilon_4^{(2)}\theta_4^{(2)} \quad \text{[Eq. A.76]}$$

$$\begin{bmatrix} u_{14} \\ u_{24} \\ u_{34} \\ u_{44} \\ u_{04} \end{bmatrix}^{k+1} = \begin{bmatrix} u_{14} \\ u_{24} \\ u_{34} \\ u_{44} \\ u_{04} \end{bmatrix}^{k} + \sigma_4^{(2)} \times \begin{bmatrix} B_1 \\ B_2 \\ B_3 \\ B_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.77]}$$

$$\sigma_5^{(2)} = 2\alpha\varepsilon_5^{(2)}\theta_5^{(2)} \quad \text{[Eq. A.78]}$$

$$\varepsilon_5^{(2)} = v_{51}\delta_1^{(3)} + v_{52}\delta_2^{(3)} + v_{53}\delta_3^{(3)} + v_{54}\delta_4^{(3)} \quad \text{[Eq. A.79]}$$

$$\theta_5^{(2)} = d(C_5) = 0{,}5\lambda(1 - D_5) \quad \text{[Eq. A.80]}$$

$$\delta_5^{(2)} = \varepsilon_5^{(2)}\theta_5^{(2)} \quad \text{[Eq. A.81]}$$

$$\begin{bmatrix} u_{15} \\ u_{25} \\ u_{35} \\ u_{45} \\ u_{05} \end{bmatrix}^{k+1} = \begin{bmatrix} u_{15} \\ u_{25} \\ u_{35} \\ u_{45} \\ u_{05} \end{bmatrix}^{k} + \sigma_5^{(2)} \times \begin{bmatrix} B_1 \\ B_2 \\ B_3 \\ B_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.82]}$$

Na camada um, os valores dos erros ($\varepsilon_i^{(1)}$), foi multiplicada com as funções de ($\delta_i^{(2)}$), para ajustar os pesos da camada um. Com as equações Eq. A.87, A.92, A.97, e A.102, pode-se este ajustar os pesos utilizando as equações Eq. 2.8, 2.12, 2.13 e 2.15:

$$\sigma_1^{(1)} = 2\alpha\varepsilon_1^{(1)}\theta_1^{(1)} \quad \text{[Eq. A.83]}$$

$$\varepsilon_1^{(1)} = u_{11}\delta_1^{(2)} + u_{12}\delta_2^{(2)} + u_{13}\delta_3^{(2)} + u_{14}\delta_4^{(2)} + u_{15}\delta_5^{(2)} \quad \text{[Eq. A.84]}$$

$$\theta_1^{(1)} = d(A_1) = 0{,}5\lambda(1 - B_1) \quad \text{[Eq. A.85]}$$

$$\delta_1^{(1)} = \varepsilon_1^{(1)}\theta_1^{(1)} \quad \text{[Eq. A.86]}$$

$$\begin{bmatrix} w_{11} \\ w_{21} \\ w_{31} \\ w_{41} \\ w_{01} \end{bmatrix}^{k+1} = \begin{bmatrix} w_{11} \\ w_{21} \\ w_{31} \\ w_{41} \\ w_{01} \end{bmatrix}^{k} + \sigma_1^{(1)} \times \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.87]}$$

$$\sigma_2^{(1)} = 2\alpha\varepsilon_2^{(1)}\theta_2^{(1)} \quad \text{[Eq. A.88]}$$

$$\varepsilon_2^{(1)} = u_{21}\delta_1^{(2)} + u_{22}\delta_2^{(2)} + u_{23}\delta_3^{(2)} + u_{24}\delta_4^{(2)} + u_{25}\delta_5^{(2)} \quad \text{[Eq. A.89]}$$

$$\theta_2^{(1)} = d(A_2) = 0{,}5\lambda(1 - B_2) \quad \text{[Eq. A.90]}$$

$$\delta_2^{(1)} = \varepsilon_2^{(1)}\theta_2^{(1)} \quad \text{[Eq. A.91]}$$

$$\begin{bmatrix} w_{12} \\ w_{22} \\ w_{32} \\ w_{42} \\ w_{02} \end{bmatrix}^{k+1} = \begin{bmatrix} w_{12} \\ w_{22} \\ w_{32} \\ w_{42} \\ w_{02} \end{bmatrix}^{k} + \sigma_2^{(2)} \times \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.92]}$$

$$\sigma_3^{(1)} = 2\alpha\varepsilon_3^{(1)}\theta_3^{(1)} \quad \text{[Eq. A.93]}$$

$$\varepsilon_3^{(1)} = u_{31}\delta_1^{(2)} + u_{32}\delta_2^{(2)} + u_{33}\delta_3^{(2)} + u_{34}\delta_4^{(2)} + u_{35}\delta_5^{(2)} \quad \text{[Eq. A.94]}$$

$$\theta_3^{(1)} = d(A_3) = 0{,}5\lambda(1 - B_3) \quad \text{[Eq. A.95]}$$

$$\delta_3^{(1)} = \varepsilon_3^{(1)}\theta_3^{(1)} \quad \text{[Eq. A.96]}$$

$$\begin{bmatrix} w_{13} \\ w_{23} \\ w_{33} \\ w_{43} \\ w_{03} \end{bmatrix}^{k+1} = \begin{bmatrix} w_{13} \\ w_{23} \\ w_{33} \\ w_{43} \\ w_{03} \end{bmatrix}^{k} + \sigma_3^{(1)} \times \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.97]}$$

$$\sigma_4^{(1)} = 2\alpha\varepsilon_4^{(1)}\theta_4^{(1)} \quad \text{[Eq. A.98]}$$

$$\varepsilon_4^{(1)} = u_{41}\delta_1^{(2)} + u_{42}\delta_2^{(2)} + u_{43}\delta_3^{(2)} + u_{44}\delta_4^{(2)} + u_{45}\delta_5^{(2)} \quad \text{[Eq. A.99]}$$

$$\theta_4^{(1)} = d(A_4) = 0{,}5\lambda(1 - B_4) \quad \text{[Eq. A.100]}$$

$$\delta_4^{(1)} = \varepsilon_4^{(1)}\theta_4^{(1)} \quad \text{[Eq. A.101]}$$

$$\begin{bmatrix} w_{14} \\ w_{24} \\ w_{34} \\ w_{44} \\ w_{04} \end{bmatrix}^{k+1} = \begin{bmatrix} w_{14} \\ w_{24} \\ w_{34} \\ w_{44} \\ w_{04} \end{bmatrix}^{k} + \sigma_4^{(1)} \times \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ 1 \end{bmatrix} \quad \text{[Eq. A.102]}$$

ANEXO II - Tabelas do Microsoft Excel dos Concretos Experimentais (1:3,5; 1:5,0; 1:6,5) Concretos Convencionais (CC) e de Alta Resistência (CAR)

Traço 1:3,5

				Areia		Cimento		Água	0,30	Brita
Teor de argamass	Traço unitário			massa total	acréscimo	massa total	acrescimo	massa total	acrescimo	massa total
35	1	0,58	2,92	5,32	0,99	9,18	0,25	2,75	0,08	26,80
37	1	0,67	2,83	6,32	1,05	9,43	0,26	2,83	0,08	Brita 1 (70%)
39	1	0,76	2,74	7,36	1,10	9,69	0,27	2,91	0,08	18,76
41	1	0,85	2,65	8,47	1,18	9,96	0,30	2,99	0,09	Brita 0 (30%)
43	1	0,94	2,56	9,64	1,25	10,26	0,32	3,08	0,10	8,04
45	1	1,03	2,47	10,90	1,33	10,58	0,34	3,17	0,10	
47	1	1,12	2,38	12,23	1,43	10,92	0,37	3,28	0,11	
49	1	1,21	2,29	13,66	1,54	11,29	0,40	3,39	0,12	
51	1	1,30	2,20	15,20	1,66	11,69	0,44	3,51	0,13	
53	1	1,39	2,11	16,86	1,79	12,13	0,47	3,64	0,14	
55	1	1,48	2,02	18,65	1,95	12,60	0,52	3,78	0,16	
57	1	1,57	1,93	20,60	2,13	13,12	0,57	3,94	0,17	
59	1	1,66	1,84	22,72		13,69		4,11		

Cálculo em massa	Quantidade der Corpos de Prova	volume total
quantidade	12	18,84955592
Ya	2,66	kg/dm³
Yc	3,15	kg/dm³
Yp (brita 0)	2,50	kg/dm³
Yp (brita 1)	2,52	kg/dm³
a/c	0,35	

quantidade de cimento (kg)		
9,18	12 cp´s	

Acréscimo de 8% de Sílica em Relação ao Cimento
0,734

Acréscimo de 0,5 % de Superplastificante
0,046

Cálculo do Volume da CP 10cm X 20cm
1,570796327

	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
1					SLUMP-TEST:	6,5	7	8					Cálculo em massa	Quantidade der Corpos de Prova	volume total
2															
3	Traço 1:5												quantidade	12	18,84955592
4					Areia		Cimento		Água	0,49	Brita		Ya	2,66	kg/dm³
5	eor de argamass	Traço unitário			massa total	acréscimo	massa total	acrescimo	massa total	acrescimo	massa total		Yc	3,15	kg/dm³
6	35	1	1,10	3,90	8,45	1,23	7,68	0,25	3,76	0,12	29,95		Yp (brita 0)	2,84	kg/dm³
7	37	1	1,22	3,78	9,68	1,30	7,93	0,26	3,89	0,13	Brita 1 (70%)		Yp (brita 1)	2,86	kg/dm³
8	39	1	1,34	3,66	10,98	1,38	8,19	0,27	4,01	0,13	20,97		a/c	0,35	
9	41	1	1,46	3,54	12,35	1,49	8,46	0,30	4,15	0,15	Brita 0 (30%)				
10	43	1	1,58	3,42	13,84	1,60	8,76	0,32	4,29	0,16	8,99		quantidade de cimento (kg)		
11	45	1	1,70	3,30	15,44	1,71	9,08	0,34	4,45	0,17			7,68	12 cp´s	
12	47	1	1,82	3,18	17,15	1,85	9,42	0,37	4,62	0,18					
13	49	1	1,94	3,06	18,99	2,00	9,79	0,40	4,80	0,20			Acréscimo de 8% de Sílica em Relação ao Cimento		
14	51	1	2,06	2,94	20,99	2,18	10,19	0,44	4,99	0,22			0,614		
15	53	1	2,18	2,82	23,17	2,36	10,63	0,47	5,21	0,23					
16	55	1	2,30	2,70	25,53	2,59	11,10	0,52	5,44	0,25					
17	57	1	2,42	2,58	28,12	2,84	11,62	0,57	5,69	0,28			Acréscimo de 0,5 % de Superplastificante		
18	59	1	2,54	2,46	30,96		12,19		5,97				0,038		
19															
20													Cálculo do Volume da CP 10cm X 20cm		
21													1,570796327		

Traço 1:6,5

				Areia		Cimento		Água	0,30	Brita
Teor de argamass	Traço unitário			massa total	acréscimo	massa total	acrescimo	massa total	acrescimo	massa total
35	1	1,63	4,87	9,52	1,32	5,84	0,25	1,75	0,08	28,44
37	1	1,78	4,72	10,84	1,42	6,09	0,26	1,83	0,08	Brita 1 (70%)
39	1	1,93	4,57	12,25	1,51	6,35	0,27	1,90	0,08	19,90
41	1	2,08	4,42	13,77	1,66	6,62	0,30	1,99	0,09	Brita 0 (30%)
43	1	2,23	4,27	15,43	1,80	6,92	0,32	2,08	0,10	8,53
45	1	2,38	4,12	17,23	1,95	7,24	0,34	2,17	0,10	
47	1	2,53	3,97	19,17	2,13	7,58	0,37	2,27	0,11	
49	1	2,68	3,82	21,30	2,32	7,95	0,40	2,38	0,12	
51	1	2,83	3,67	23,63	2,56	8,35	0,44	2,50	0,13	
53	1	2,98	3,52	26,19	2,79	8,79	0,47	2,64	0,14	
55	1	3,13	3,37	28,98	3,09	9,26	0,52	2,78	0,16	
57	1	3,28	3,22	32,07	3,42	9,78	0,57	2,93	0,17	
59	1	3,43	3,07	35,50		10,35		3,10		

Cálculo em massa	Quantidade der Corpos de Prova	volume total
quantidade	12	18,84955592
Ya	2,66	kg/dm³
Yc	3,15	kg/dm³
Yp (brita 0)	2,50	kg/dm³
Yp (brita 1)	2,52	kg/dm³
a/c	0,35	

quantidade de cimento (kg)		
5,84	12 cp´s	

Acréscimo de 8% de Sílica em Relação ao Cimento
0,467

Acréscimo de 0,5 % de Superplastificante
0,029

Cálculo do Volume da CP 10cm X 20cm
1,570796327

ANEXO III - Planilha de Cálculo dos Concretos Experimentais (1 : 3,5; 1 : 5,0; 1 : 6,5) para 1m³ Concretos Convencionais (CC) e de Alta Resistência (CAR)

Dados da Dosagem de Concreto Convencional (CC) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z	Teor de Argamassa Ideal:		50%	Brita:		BASALTO		
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	524,29	587,21	1525,86	0,00	246,42	0,00	0,00	0,31	18
	28									25
	91									37
1:5,0	7	409,20	744,74	1589,09	0,00	192,32	0,00	0,00	0,54	16
	28									25
	91									39
1:6,5	7	335,63	849,13	1626,03	0,00	157,74	0,00	0,00	0,64	7
	28									12
	91									19

Dados da Dosagem de Concreto Convencional (CC) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z	Teor de Argamassa Ideal:		49%	Brita:		BASALTO		
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	526,04	636,51	1070,92	458,97	257,76	0,00	0,00	0,27	17
	28									22
	91									37
1:5,0	7	410,69	796,74	1115,42	478,04	201,24	0,00	0,00	0,52	15
	28									20
	91									30
1:6,5	7	336,93	902,99	1141,42	489,18	165,10	0,00	0,00	0,59	7
	28									10
	91									17

Dados da Dosagem de Concreto Convencional (CC) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z	Teor de Argamassa Ideal:		47%	Brita:		GRANITO		
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	488,71	547,36	0,00	1421,96	229,69	0,00	0,00	0,34	28
	28									38
	91									46
1:5,0	7	380,39	692,30	0,00	1476,72	178,78	0,00	0,00	0,47	21
	28									30
	91									29
1:6,5	7	311,51	788,11	0,00	1508,56	146,41	0,00	0,00	0,71	24
	28									26
	91									33

Dados da Dosagem de Concreto Convencional (CC) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z	Teor de Argamassa Ideal:		47%	Brita:		GRANITO		
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	490,92	549,83	1428,41	0,00	230,73	0,00	0,00	0,30	26
	28									38
	91									39
1:5,0	7	382,17	695,55	1483,67	0,00	179,62	0,00	0,00	0,47	20
	28									31
	91									34
1:6,5	7	313,00	791,88	1515,82	0,00	147,11	0,00	0,00	0,57	22
	28									31
	91									32

Dados da Dosagem de Concreto Convencional (CC) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z		Teor de Argamassa Ideal:			47%	Brita:	GRANITO	
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	490,26	549,09	998,53	427,94	230,42	0,00	0,00	0,36	27
	28									31
	91									29
1:5,0	7	381,63	694,57	1037,11	444,47	179,37	0,00	0,00	0,47	24
	28									29
	91									34
1:6,5	7	312,55	790,75	1059,54	454,09	146,90	0,00	0,00	0,57	22
	28									25
	91									29

Dados da Dosagem de Concreto Convencional (CC) para Produção de 1m³									
Classe de Cimento:	CP II 32 - Z		Teor de Argamassa Ideal:			52%	Brita:	SEIXO	
idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
7	521,08	677,41	1514,24	0,00	265,75	0,00	0,00	0,40	25
28									31
91									35
7	405,97	837,88	1576,49	0,00	207,44	0,00	0,00	0,51	24
28									31
91									34
7	332,92	842,28	1612,83	0,00	170,18	0,00	0,00	0,62	15
28									22
91									24

Dados da Dosagem de Concreto de Alto Desempenho (CAD) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z		Teor de Argamassa Ideal:			49%	Brita:	Basalto	
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	520,96	630,36	0,00	1515,04	255,27	41,51	2,594	0,38	36
	28									55
	91									53
1:5,0	7	407,31	790,19	0,00	1580,29	199,58	32,42	2,03	0,49	31
	28									51
	91									50
1:6,5	7	334,48	896,41	0,00	1618,64	163,90	26,590	1,66	0,60	22
	28									40
	91									38

Dados da Dosagem de Concreto de Alto Desempenho (CAD) para Produção de 1m³										
Sigla e Classe de Cimento:		CP III 40 - RS		Teor de Argamassa Ideal:			53%	Brita:	Basalto	
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	523,74	728,00	0,00	1520,71	277,58	41,66	2,604	0,41	31
	28									35
	91									46
1:5,0	7	409,74	893,22	0,00	1586,46	217,16	32,54	2,03	0,53	23
	28									34
	91									38
1:6,5	7	336,65	1003,22	0,00	1625,12	178,42	26,696	1,67	0,65	16
	28									27
	91									30

Dados da Dosagem de Concreto de Alto Desempenho (CAD) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z		Teor de Argamassa Ideal:			49%	Brita:	GRANITO	
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	488,71	547,36	0,00	1421,96	229,69	38,96	2,435	0,37	38
	28									49
	91									48
1:5,0	7	380,39	692,30	0,00	1476,72	178,78	30,29	1,89	0,49	29
	28									37
	91									37
1:6,5	7	311,51	788,11	0,00	1508,56	146,41	24,781	1,55	0,57	25
	28									33
	91									32

Dados da Dosagem de Concreto de Alto Desempenho (CAD) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z		Teor de Argamassa Ideal:			49%	Brita:	GRANITO	
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	490,92	549,83	1428,41	0,00	230,73	39,13	2,45	0,37	39
	28									52
	91									50
1:5,0	7	382,17	695,55	1483,67	0,00	179,62	30,43	1,90	0,49	42
	28									54
	91									50
1:6,5	7	313,00	791,88	1515,82	0,00	147,11	24,90	1,56	0,57	30
	28									37
	91									42

Dados da Dosagem de Concreto de Alto Desempenho (CAD) para Produção de 1m³										
Sigla e Classe de Cimento:		CP II 32 - Z		Teor de Argamassa Ideal:			47%	Brita:	GRANITO	
Traço	idade	CC (Kg/m³)	Areia (Kg/m³)	Brita (B1) (Kg/m³)	Brita (B0) (Kg/m³)	Água (Kg/m³)	Microssílica (Kg/m³)	Superplastificante (Kg/m³)	Relação (a/c)	Resistência (MPa)
1:3,5	7	490,92	549,83	999,88	428,52	230,73	35,67	2,23	0,37	37
	28									48
	91									49
1:5,0	7	381,63	694,57	1038,57	445,10	179,37	30,39	1,90	0,47	29
	28									36
	91									40
1:6,5	7	313,00	791,88	1061,07	454,75	147,11	24,86	1,55	0,57	29
	28									39
	91									41

ANEXO IV - Treinamentos por redes neurais artificiais (RNA) do *software* DECCONCRETO para Concretos Convencionais (CC) aos 28 dias

RNA com quatro camadas para concretos convencionais (CC), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de basalto com diâmetro B1, agregados miúdos e água.

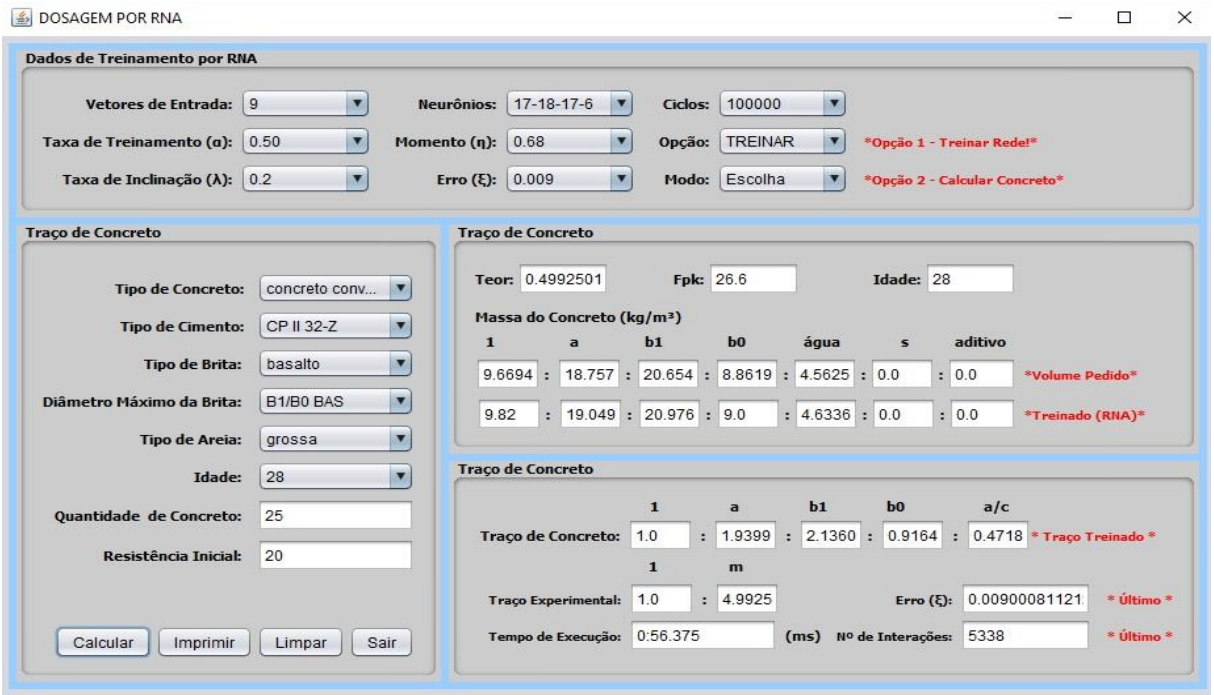

RNA com quatro camadas para concretos convencionais (CC), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de basalto com diâmetros B1/B0, agregados miúdos e água.

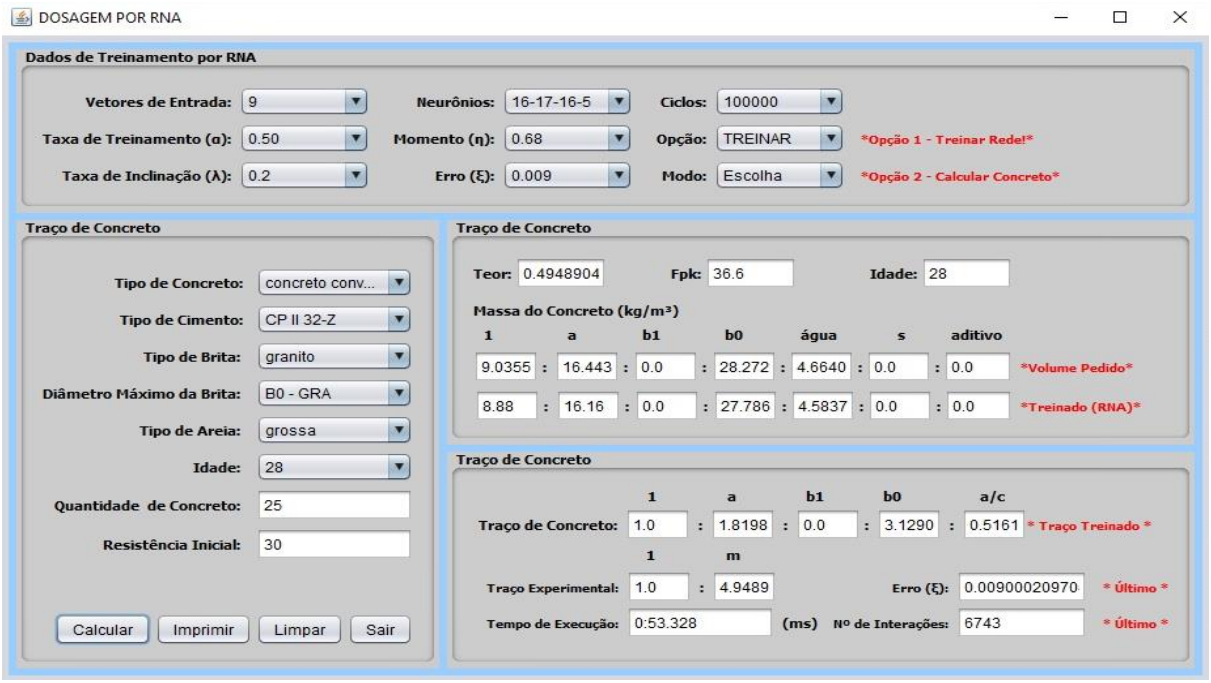

RNA com quatro camadas para concretos convencionais (CC), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de granito com diâmetro B0, agregados miúdos e água.

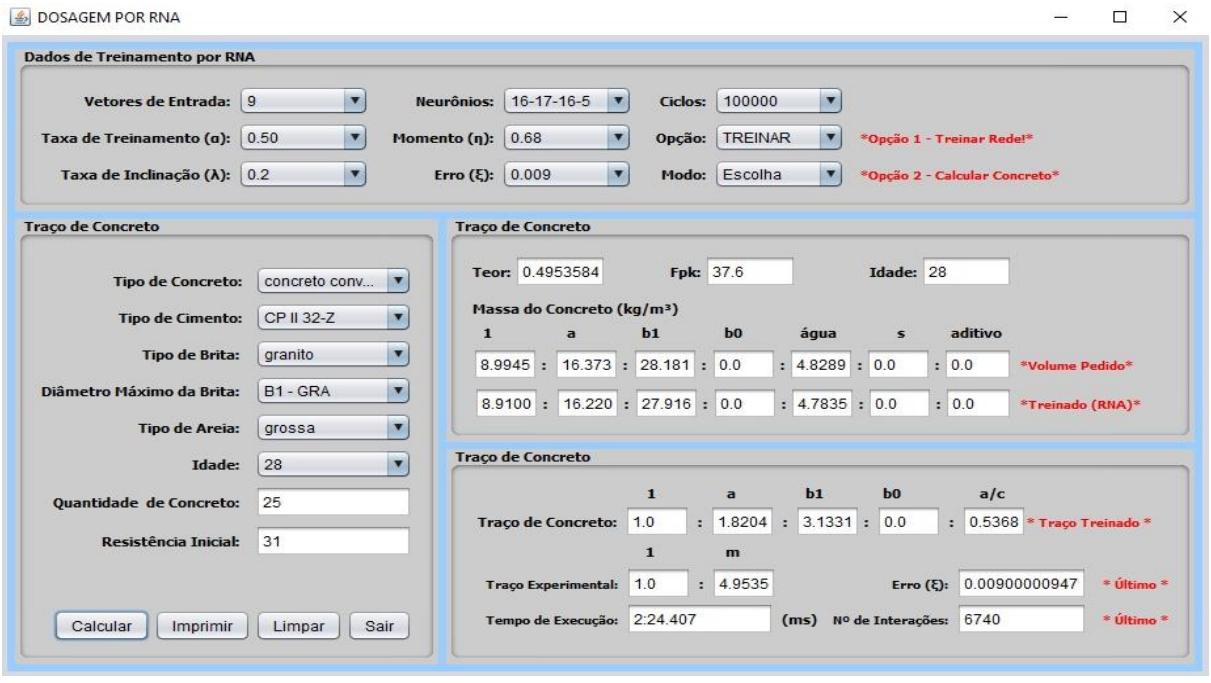

RNA com quatro camadas para concretos convencionais (CC), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de granito com diâmetro B1, agregados miúdos e água.

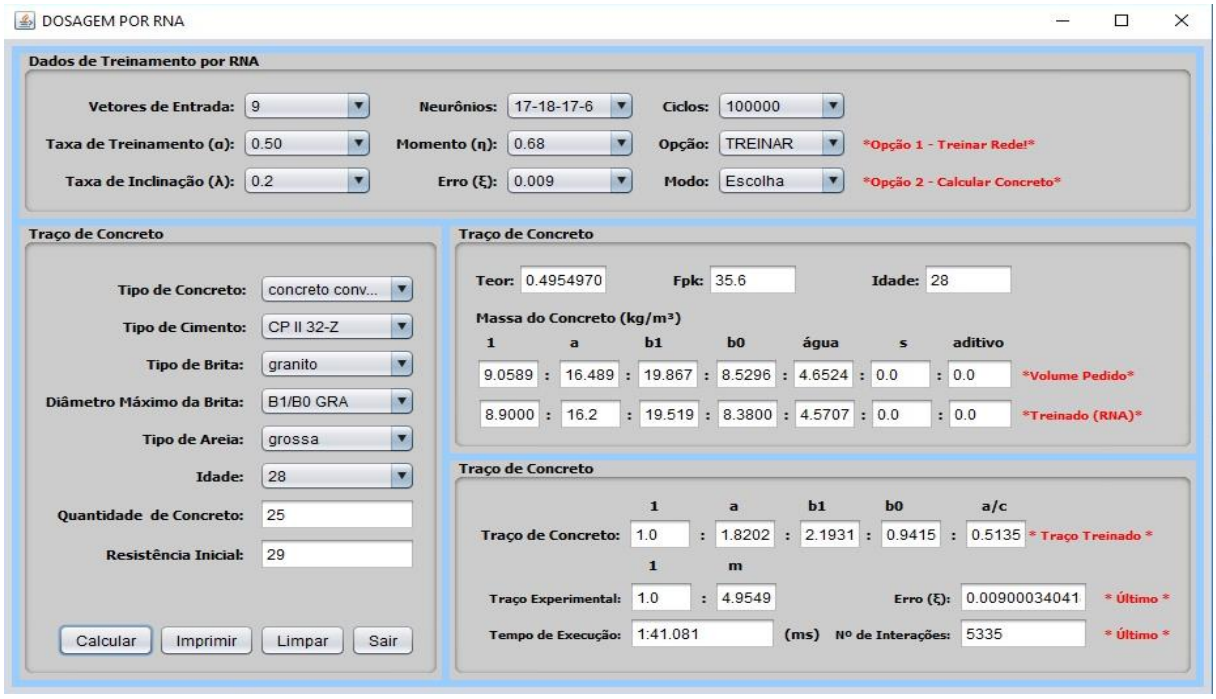

RNA com quatro camadas para concretos convencionais (CC), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de granito com diâmetros B1/B0, agregados miúdos e água.

RNA com quatro camadas para concretos convencionais (CC), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de seixo rolado com diâmetro B1, agregados miúdos e água.

ANEXO V - Treinamentos por redes neurais artificiais (RNA) do *software* DECCONCRETO para Concretos de Alta Resistência (CAR) aos 28 dias

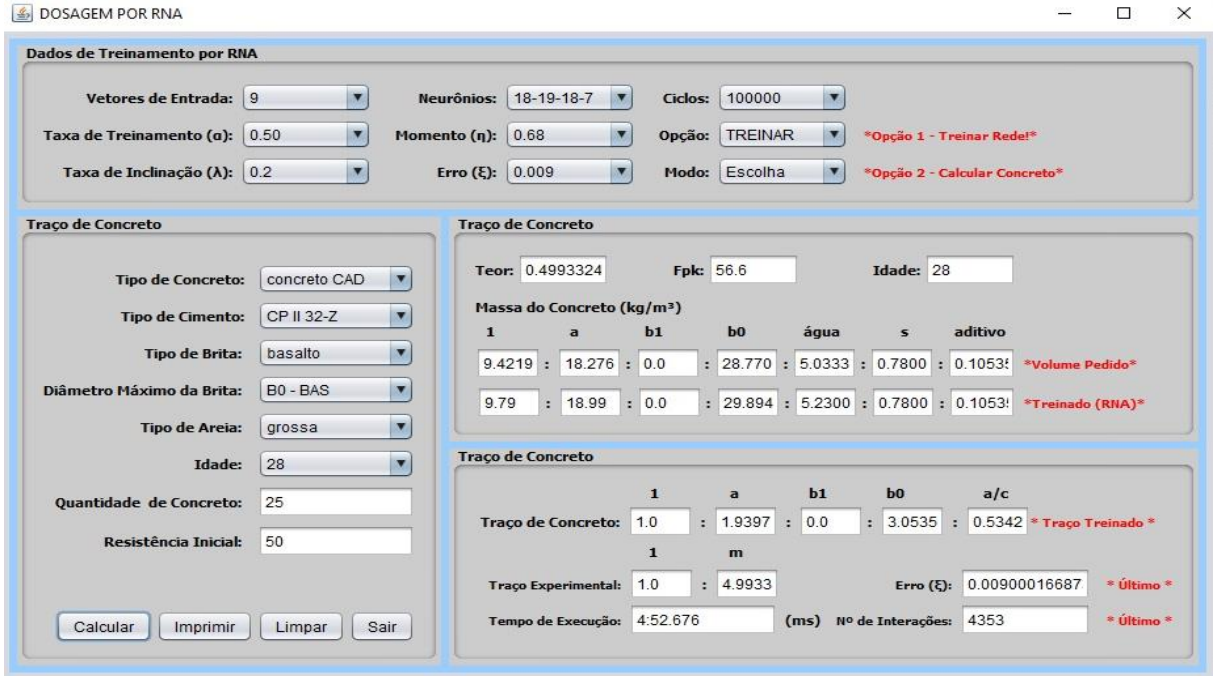

RNA com quatro camadas para concretos de alta resistência (CAR), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de basalto com diâmetro B0, agregados miúdos, água, microssílica e superplastificante.

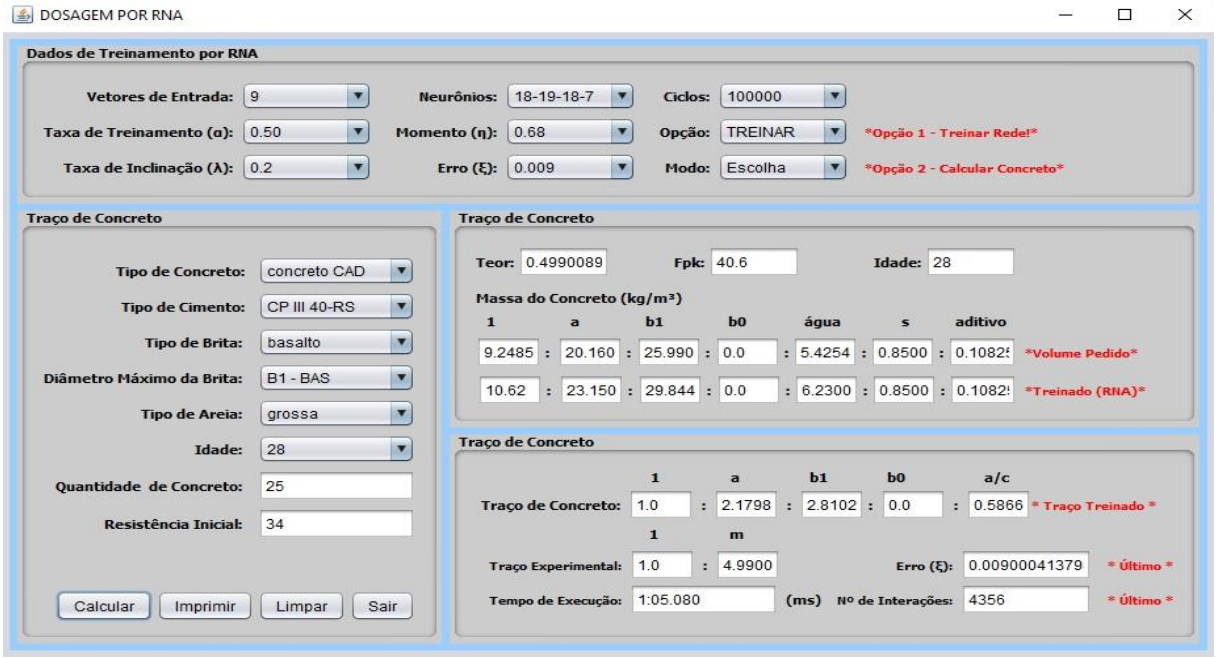

RNA com quatro camadas para concretos de alta resistência (CAR), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP III 40 – RS, agregados graúdos de basalto com diâmetro B1, agregados miúdos, água, microssílica e superplastificante.

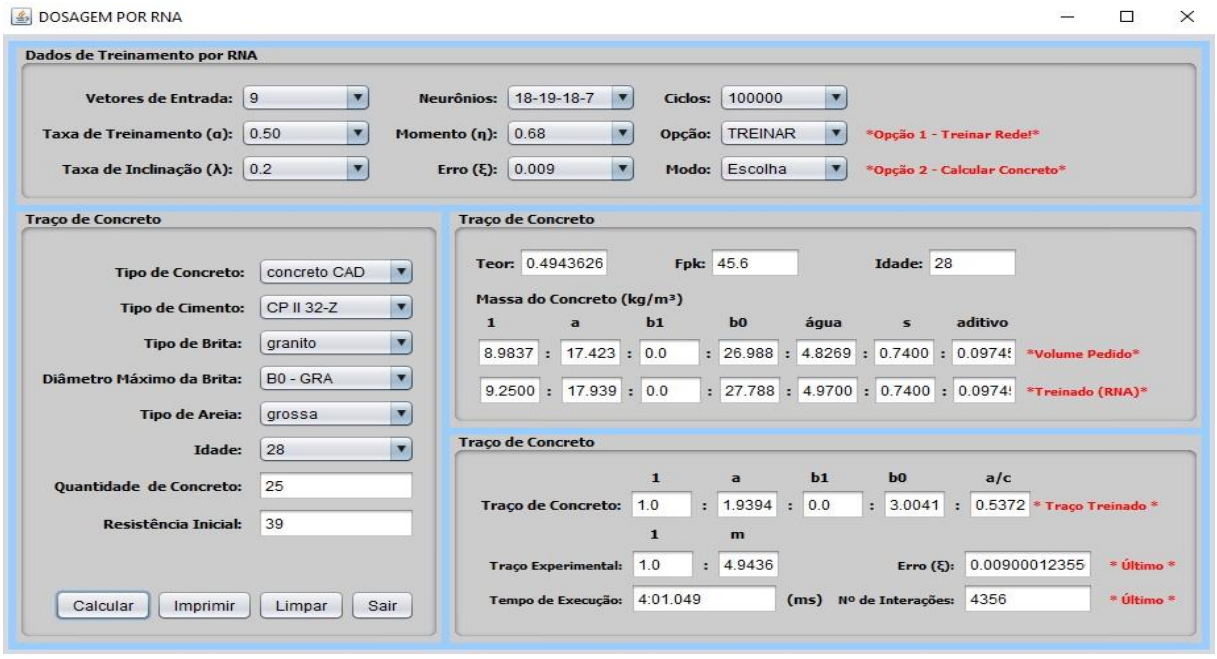

RNA com quatro camadas para concretos de alta resistência (CAR), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de granito com diâmetro B0, agregados miúdos, água, microssílica e superplastificante.

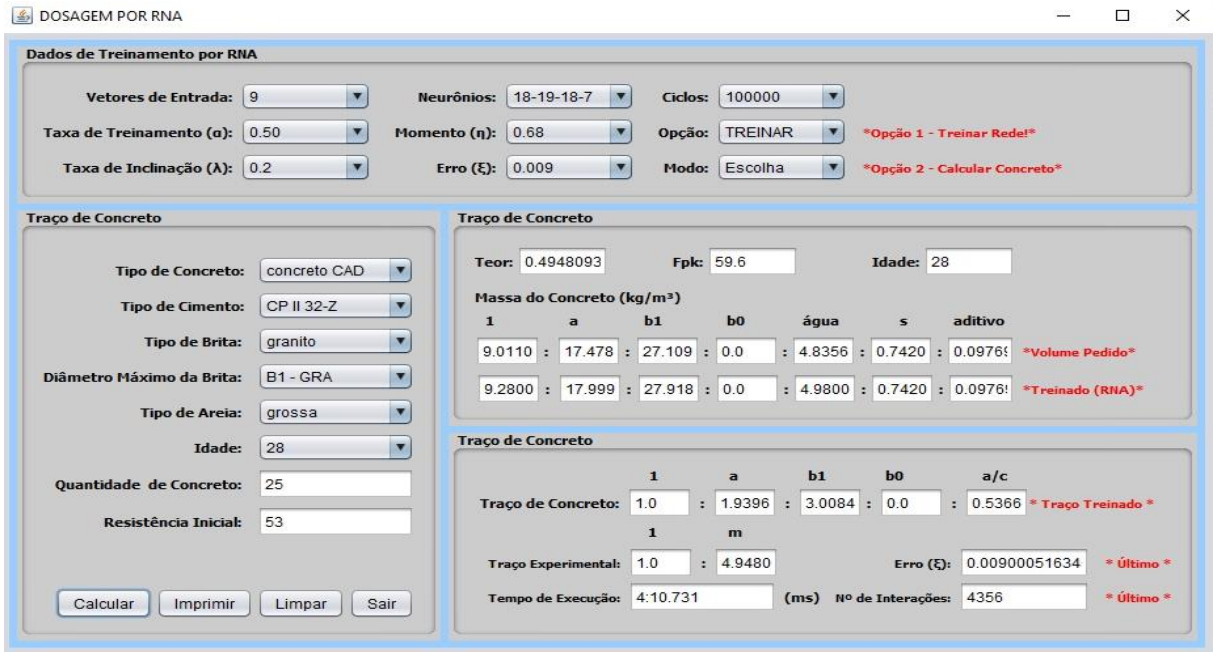

RNA com quatro camadas para concretos de alta resistência (CAR), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de granito com diâmetro B1, agregados miúdos, água, microssílica e superplastificante.

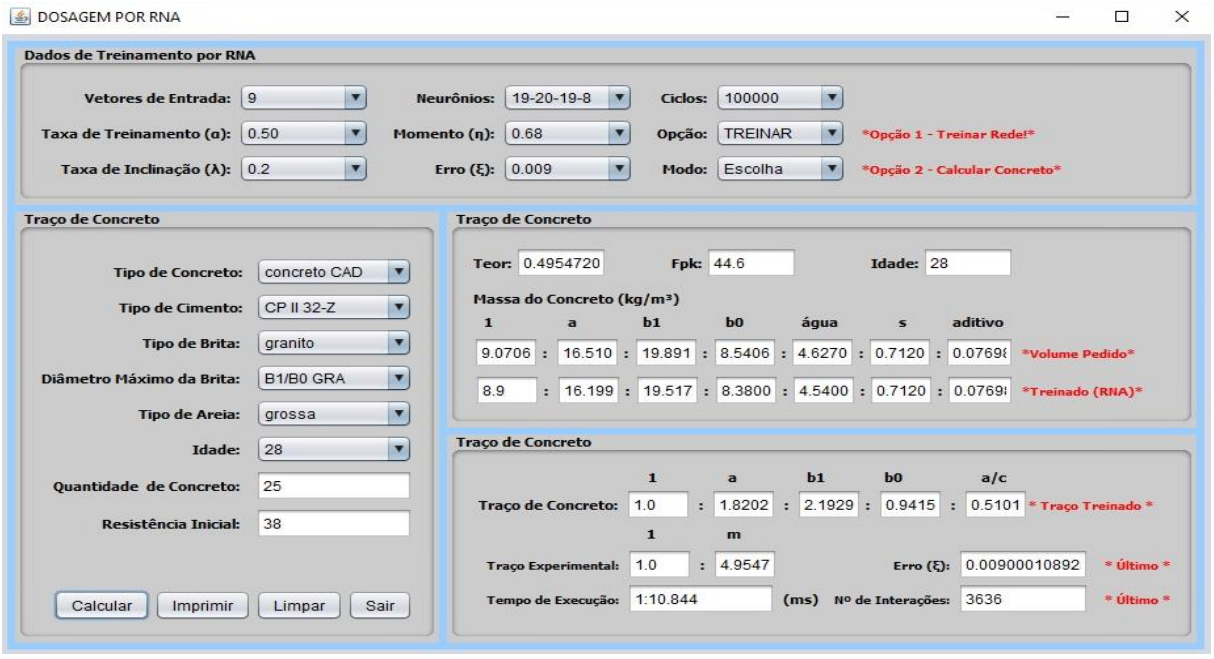

RNA com quatro camadas para concretos de alta resistência (CAR), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP II 32 – Z, agregados graúdos de granito com diâmetros B1/B0, agregados miúdos, água, microssílica e superplastificante.

RNA com quatro camadas para concretos de alta resistência (CAR), onde foi realizado o treinamento composto pelos materiais: cimento Portland CP III 40 – 40, agregados graúdos de seixo rolado com diâmetros B1, agregados miúdos, água, microssílica e superplastificante.