

PGMEC

PROGRAMA FRANCISCO EDUARDO MOURÃO SABOYA DE
PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
ESCOLA DE ENGENHARIA
UNIVERSIDADE FEDERAL FLUMINENSE

Tese de Doutorado

SISTEMA INTELIGENTE DE
CLASSIFICAÇÃO DE IMAGENS DE
ROCHAS MACROSCÓPICAS PARA A
INDÚSTRIA DE PETRÓLEO E GÁS

LAERCIO BRITO GONÇALVES

AGOSTO DE 2010

LAERCIO BRITO GONÇALVES

SISTEMA INTELIGENTE DE CLASSIFICAÇÃO DE
IMAGENS DE ROCHAS MACROSCÓPICAS PARA A
INDÚSTRIA DE PETRÓLEO E GÁS

Tese de Doutorado apresentada ao Programa
Francisco Eduardo Mourão Saboya de Pós-
Graduação em Engenharia Mecânica da UFF
como parte dos requisitos para a obtenção do
título de Doutor em Ciências em Engenharia
Mecânica

Orientadora: Prof. Doutora Fabiana R. Leta (PGMEC/UFF)

UNIVERSIDADE FEDERAL FLUMINENSE
NITERÓI, 10 DE AGOSTO DE 2010

SISTEMA INTELIGENTE DE CLASSIFICAÇÃO DE IMAGENS DE ROCHAS MACROSCÓPICAS PARA A INDÚSTRIA DE PETRÓLEO E GÁS

Esta Tese é parte dos pré-requisitos para a obtenção do título de

DOUTOR EM ENGENHARIA MECÂNICA

Área de concentração: Termociências

Aprovada em sua forma final pela Banca Examinadora formada pelos professores:

Prof. Fabiana Rodrigues Leta (D.Sc.)
Universidade Federal Fluminense
(Orientadora)

Prof. Sérgio Souto Maior Tavares (D.Sc.)
Universidade Federal Fluminense

Prof. Juan Manuel Pardal (D.Sc.)
Universidade Federal Fluminense

Prof. Sérgio de Castro Valente (Ph. D.)
Universidade Federal Rural do Rio de Janeiro

Prof. Luiz Biondi Neto (D.Sc.)
Universidade do Estado do Rio de Janeiro

Aos Meus Pais

Agradecimentos

A Deus por ter me permitido existir e me guiado nessa jornada;

À Prof^ª. Doutora Fabiana Rodrigues Leta, orientadora desta tese, pelo apoio, carinho, incentivo e confiança depositada, com quem pude contar em todos os momentos durante a realização desse trabalho;

Ao Prof. Ph.D. Sergio Valente pelo apoio e ajuda com quem pude sempre contar;

Aos professores que participaram da comissão examinadora;

À minha mãe e meu pai por sempre estarem do meu lado me incentivando;

À minha esposa Daniela pela paciência, apoio e ajuda, durante todo o período em que estive envolvido com esta tese;

Ao meu amigo Anchizes que sempre torceu por mim;

A todos os amigos e familiares que me estimularam nessa jornada.

RESUMO

A descoberta de uma jazida de petróleo é uma tarefa que envolve um longo e dispendioso estudo e análise de dados geofísicos e geológicos das bacias sedimentares. Somente após exaustivo prognóstico do comportamento das diversas camadas do subsolo, os geólogos e geofísicos decidem propor a perfuração de um poço, que é a etapa que mais investimentos exige em todo processo de prospecção.

A primeira etapa de um programa exploratório é a realização de um estudo geológico, onde as rochas são classificadas e, dependendo dessa classificação, a área pode ser considerada favorável ou não a acumulações de petróleo. Assim, esse trabalho visa a construção de um sistema capaz de identificar e classificar rochas através de reconhecimento e classificação de imagens.

O trabalho consistiu, fundamentalmente, de sete partes: 1) estudo sobre a área de petrologia, especificamente em classificação de rochas; 2) análise das técnicas de identificação e descrição de texturas em imagens; 3) estudo sobre os principais métodos de classificação de padrões; 4) análise de sistemas neuro-fuzzy hierárquicos na tarefa de classificação; 5) definição e implementação de três sistemas hierárquicos híbridos específicos para classificação de classes macros e classificação de subclasses das classes macros; e 6) estudo de casos.

No estudo sobre rochas, foram investigados as três principais classes em petrologia: ígnea, sedimentar e metamórfica, juntamente com seus métodos de classificação.

Na investigação sobre os métodos de classificação, seleção de atributos e técnicas de identificação e descrição de textura, foi feito um levantamento bibliográfico das áreas, onde foram apresentadas as principais técnicas utilizadas para estas tarefas. Entre as principais técnicas para classificação destacaram-se: árvores de decisão, sistemas *fuzzy*, redes neurais, e os sistemas neuro-*fuzzy*. Para quantificação de texturas em imagens destacaram-se: os métodos estatísticos, texturais e espectrais.

Na análise dos sistemas neuro-*fuzzy* hierárquicos, em classificação de padrões, levou-se em consideração as peculiaridades do modelo, que possui: aprendizado da estrutura, particionamento recursivo do espaço de entrada, além de regras *fuzzy* recursivas.

Foram definidos três novos sistemas para classificação de classes macros e de subclasses das classes macros: NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass. O primeiro utiliza um modelo NFHB-Class, pai ou raiz, no topo da hierarquia, como classificador das classes macros e outros sistemas NFHB-Class, subordinados ao sistema classificador macro, para determinar as subclasses. O segundo e o terceiro utilizam uma rede neural, pai ou raiz, no topo da hierarquia, como classificador das classes macros e sistemas NFHB-Class e redes neurais, respectivamente, subordinados ao sistema classificador macro, para determinar as subclasses.

Realizou-se um amplo estudo de casos, abrangendo as classes de rochas gnaisse, basalto, diabásio e riolito, juntamente com suas subclasses, e foram feitas comparações com entre os modelos NFHB-Class, NFHB-SubClass, RN-NFHB-SubClass, RN-Hierárquico-SubClass e redes neurais.

Os resultados encontrados com o NFHB-Class em comparação aos encontrados com as redes neurais, mostraram-se ser melhores, em todos os casos. Quando se comparou os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, o primeiro apresentou melhores resultados em todos os estudos de casos.

O desempenho de todos os modelos testados em relação ao tempo de processamento também se mostrou muito bom. Em todos os testes, os modelos convergiram para uma ótima solução de classificação, em uma ordem de grandeza de tempo de processamento inferior a um minuto.

ABSTRACT

The discovery of a basin of petroleum is a task that involves a long and costly study and analysis of geophysical and geological data of the sedimentary basins. Only after exhausting prognostic of the behavior of the several underground layers, the geologists and geophysical decide to propose the perforation of a well, this is the most demanding stage in terms of investments in every search process.

The first stage of an exploratory program is the accomplishment of a geological study where the rocks are classified and depending on that classification, the area is considered favorable or not to accumulate petroleum. Because of that, this work seeks the construction of a system capable to identify and to classify rocks through recognition and classification of images.

The work consisted fundamentally in seven parts: 1) study on the petrology area, specifically in classification of rocks; 2) analysis the identification techniques and description of textures in images; 3) study on the main methods of patterns classification; 4) analysis the neuro-fuzzy hierarchical systems in the classification task; 5) definition and implementation of three hybrid hierarchical systems specific for classification of macro classes and classification of subclasses of the macro classes; and 6) case study.

In the study about rocks, were investigated the three principals study fields in petrology: igneous, sedimentary and metamorphic, jointly with them classification methods.

In the investigation about the classification methods, selection of attributes and identification techniques; and texture description, it was made a bibliographical rising of the areas, where the main techniques were presented. Among the main techniques for classification stood out: decision trees, fuzzy systems, neural nets, and the neural-fuzzy systems. For quantification of textures in images stood out: the statistical methods, textural and spectral.

In the analysis of the hierarchical neuro-fuzzy systems, in classification of patterns, it took into account the peculiarities of the model, which has: learning the structure, recursive partitioning of the input space, and recursive fuzzy rules.

Three new systems were defined for classification of macro classes and subclasses of the macros classes: NFHB-SubClass, RN-NFHB-SubClass and RN-Hierarchical-SubClass. The first uses a model NFHB-Class, root, at the top of the hierarchy, as the classifier classes macros and other systems NFHB-Class, subject to the macro classifier to determine the subclasses. The second and third use a neural network, root at the top of the hierarchy, as classifier of macros classes and NFHB-Class systems and neural networks, respectively, subject to the macro classifier to determine the subclasses.

An extensive study of cases was realized, covering the classes of gneiss rocks, basalt, diabase and rhyolites, jointly with its subclasses, and comparisons were made between models with NFHB-Class, SubClass-NFHB, RN-SubClass-NFHB, RN Hierarchical-SubClass and neural networks.

The results with the NFHB-Class compared to those found with the neural networks have shown to be better in all cases. When comparing the models NFHB-SubClass, RN- Hierarchical-SubClass and RN-NFHB-SubClass, the first showed better results in all the case studies.

The performance of all models tested in relation to the processing time was also very good. In all tests, the models converged to an optimal solution for the classification, in an order of magnitude of processing time less than one minute.

SUMÁRIO

| | |
|---|-----------|
| Lista de Figuras | VIII |
| Lista de Tabelas | XIV |
| Capítulo 1 Introdução | 1 |
| 1.1. Temática e Justificativas..... | 1 |
| 1.2. Objetivos..... | 5 |
| 1.3. Descrição do Trabalho..... | 7 |
| 1.4. Estrutura da Tese | 8 |
| Capítulo 2 Rochas..... | 10 |
| 2.1. Petrologia..... | 10 |
| 2.2. Rochas Ígneas | 11 |
| 2.2.1. Rochas Ígneas Plutônicas | 12 |
| 2.2.2. Rochas Ígneas Vulcânicas | 15 |
| 2.2.3. Rochas Ígneas Hipabissais | 18 |
| 2.3. Classificação das Rochas Ígneas | 20 |
| 2.4. Critérios de Classificação das Rochas Ígneas | 20 |
| 2.4.1. Critérios Texturais | 21 |
| 2.4.1.1. Cristalinidade..... | 21 |
| 2.4.1.2. Granulometria..... | 23 |
| 2.4.1.3. Interrelação Granulométrica..... | 27 |

| | | |
|----------|---|----|
| 2.5. | Rochas Sedimentares | 28 |
| 2.5.1. | Rochas Clásticas | 28 |
| 2.5.1.1. | Rochas Residuais | 29 |
| 2.5.1.2. | Rochas Epiclásticas | 29 |
| 2.5.1.3. | Rochas Piroclásticas | 30 |
| 2.5.2. | Rochas Químicas | 31 |
| 2.5.3. | Rochas Orgânicas | 31 |
| 2.6. | Rochas Metamórficas | 32 |
| 2.6.1. | Classificação das Rochas Metamórficas..... | 33 |
| 2.6.1.1. | Classificação com Critério Composicional Importante..... | 34 |
| | Termos Base | 34 |
| | Uso de nomes de minerais metamórficos antes do termo base | 41 |
| | Uso de nomes de minerais metamórficos após o termo base | 42 |
| 2.6.1.2. | Classificação com Critério “Tipo de Metamorfismo” Importante | 42 |
| | Rochas submetidas a metamorfismo dinâmico (isto é, onde o principal parâmetro do metamorfismo é a pressão dirigida) | 42 |
| | Rochas submetidas a metamorfismo de contato predominante..... | 44 |
| | Rochas submetidas a metamorfismo de impacto predominante..... | 44 |
| | Rochas submetidas a metamorfismo regional predominante | 45 |
| 2.6.1.3. | Classificação quanto a origem..... | 46 |
| | Uso do prefixo META (indicação do protólito) | 46 |
| | Uso do nome protólito com sufixo indicativo da rocha metamórfica | 47 |
| | Uso do prefixo ORTO e PARA..... | 47 |
| 2.7. | Resumo | 47 |

| | | |
|-------------------|---|-----------|
| Capítulo 3 | Textura | 48 |
| 3.1. | Trabalhos de textura em diversas aplicações..... | 49 |
| 3.2. | Trabalhos de Textura em Imagens de Rochas | 54 |
| 3.3. | Características de Textura | 55 |
| 3.3.1. | Abordagem Estatística..... | 56 |
| 3.3.1.1. | Matriz de Co-ocorrência..... | 59 |
| 3.3.1.2. | Histogramas de somas e diferenças | 65 |
| 3.3.1.3. | Métodos de Autocorrelação..... | 68 |
| 3.3.1.4. | Coefficiente de Variação Espacial..... | 70 |
| 3.3.1.5. | Coefficiente de Hurst..... | 72 |
| 3.3.1.6. | Entropia da Imagem..... | 75 |
| 3.4. | Resumo | 76 |
| Capítulo 4 | Sistemas de Classificação de Padrões | 77 |
| 4.1. | Introdução..... | 77 |
| 4.2. | Métodos de Classificação de Padrões..... | 79 |
| 4.2.1. | Árvores de Decisão..... | 79 |
| 4.2.2. | Redes Neurais | 83 |
| 4.2.3. | Sistemas Fuzzy | 90 |
| 4.2.3.1. | Modelo Fuzzy para Classificação de Padrões | 94 |
| 4.2.4. | Sistemas Neuro-Fuzzy..... | 100 |
| 4.2.4.1. | NEFCLASS | 101 |
| 4.2.4.2. | Modelo NFHQ..... | 108 |
| 4.2.4.3. | Modelo NFHB | 123 |
| 4.2.4.4. | Modelo NFHB-Invertido | 125 |

| | | |
|-------------------|---|------------|
| 4.2.4.5. | Modelo NFHB-Class | 137 |
| 4.2.4.6. | Seleção de Características dos Modelos NFHB | 146 |
| 4.3. | Resumo | 148 |
| Capítulo 5 | Extração de Regras Fuzzy | 149 |
| 5.1. | Introdução..... | 149 |
| 5.2. | Cálculo dos Graus de Pertinência..... | 150 |
| 5.3. | Visualização das Regras | 155 |
| 5.4. | Avaliação das Regras..... | 156 |
| 5.4.1. | Acurácia Fuzzy | 156 |
| 5.4.2. | Abrangência Fuzzy | 161 |
| 5.5. | Resumo | 164 |
| Capítulo 6 | Modelos Hierárquicos SubClass | 165 |
| 6.1. | Modelo NFHB-SubClass..... | 166 |
| 6.1.1. | Arquitetura NFHB-SubClass..... | 168 |
| 6.1.2. | Algoritmo de Aprendizado NFHB-SubClass | 169 |
| 6.2. | Modelo RN-NFHB-Subclass..... | 170 |
| 6.2.1. | Arquitetura RN-NFHB-SubClass..... | 171 |
| 6.2.2. | Algoritmo de Aprendizado RN-NFHB-SubClass | 172 |
| 6.3. | Modelo RN-Hierárquico-Subclass | 173 |
| 6.3.1. | Arquitetura RN-Hierárquico-Subclass | 174 |
| 6.3.2. | Algoritmo de Aprendizado RN-Hierárquico-Subclass..... | 175 |
| 6.4. | Resumo | 176 |
| Capítulo 7 | Estudo de Casos | 177 |
| 7.1. | Descrição | 178 |

| | | |
|-------------------|--|------------|
| 7.2. | Classificação das rochas através dos modelos NFHB-Class e Redes Neurais ... | 181 |
| 7.2.1. | Rocha Gnaiss | 181 |
| 7.2.2. | Rocha Basalto | 186 |
| 7.2.3. | Rocha Diabásio | 191 |
| 7.2.4. | Rocha Riólito | 195 |
| 7.2.5. | Rochas Gnaiss e Basalto | 200 |
| 7.2.6. | Rochas Diabásio e Riólito | 204 |
| 7.2.7. | Rochas Basalto, Diabásio e Riólito | 208 |
| 7.2.8. | Rochas Gnaiss, Basalto, Diabásio e Riólito | 212 |
| 7.3. | Classificação das rochas através dos modelos NFHB-SubClass, RN-NFHB-SubClass e RN-SubClass | 217 |
| 7.3.1. | Rochas Gnaiss e Basalto | 221 |
| 7.3.2. | Rochas Diabásio e Riólito | 222 |
| 7.3.3. | Rochas Basalto, Diabásio e Riólito | 222 |
| 7.3.4. | Rochas Gnaiss, Basalto, Diabásio e Riólito | 223 |
| 7.4. | Comparações com os modelos testados | 224 |
| 7.5. | Extração das Regras | 225 |
| 7.6. | Resumo | 229 |
| Capítulo 8 | Conclusões e Sugestões para Trabalhos Futuros | 230 |
| 8.1. | Conclusões | 230 |
| 8.2. | Trabalhos Futuros | 233 |
| | Referências Bibliográficas | 235 |
| | APÊNDICE: Imagens das Rochas Utilizadas para Classificação de Textura | 254 |

Lista de Figuras

| | |
|---|----|
| Figura 1.1 Parte de um testemunho de rocha extraído de um poço de exploração de petróleo, utilizado para análise macroscópica. | 4 |
| Figura 1.2. Imagem de uma seção delgada de rocha, vista sob um microscópio óptico de luz polarizada..... | 4 |
| Figura 2.1 Exemplos de granitos com diferentes texturas e cores [12], [13] e [14]...... | 12 |
| Figura 2.2 Exemplos da família do sienito [15] e [16]...... | 13 |
| Figura 2.3 Exemplos da família do diorito [17] e [18]...... | 13 |
| Figura 2.4 Exemplos da família do gabro [19], [20] e [21]...... | 14 |
| Figura 2.5 Exemplos da família do peridotito [22], [23] e [24]. | 14 |
| Figura 2.6 Exemplos da família do riolito [25] e [26]...... | 16 |
| Figura 2.7 Exemplos da família do traquito [27] e [28]. | 16 |
| Figura 2.8 Exemplos da família do andesito [29], [30] e [31]...... | 17 |
| Figura 2.9 Exemplos da família do basalto [32], [33] e [34]...... | 17 |
| Figura 2.10 Exemplo da família do lamprófiro. Os pontos escuros (piroxênios, olivinas e anfibólios) caracterizam a típica textura porfirítica dos lamprófiros [35]...... | 18 |
| Figura 2.11 Exemplos da família do diabásio [22] e [36]. | 19 |
| Figura 2.12 Ilustrações esquemáticas (A, B, C) e fotografias (D, E, F) relativas à cristalinidade de rochas ígneas: (A) granito, holocristalino; (B) basalto porfirítico com massa fundamental intersertal, hipocristalino; (C) riolito com esferulitos, vítreo; (D) Granito porfirítico, holocristalino; (E) basalto, hipocristalino; (F) Tufo soldado | |

| | |
|--|----|
| riolítico, vítreo []. Bi = biotita; Pl = plagioclásio, Kf = K-feldspato, Q = quartzo, V = vidro, Cpx = clinopiroxênio, Hb = hornblenda. | 23 |
| Figura 2.13 Ilustrações esquemáticas de granulometria grossa, média e fina de rochas ígneas, de acordo com os meios e instrumentos de observação. Nota-se que as escalas das observações microscópicas não são iguais [44]. | 24 |
| Figura 2.14 Relação entre a espessura e a granulometria das rochas ígneas finas: (A) microcristalina e (B) criptocristalina, com visão esquemática das respectivas imagens microscópicas. A escala é comum para ambas as rochas [44]. | 26 |
| Figura 2.15 Ilustração esquemática de visão macroscópica e microscópica de (A) textura equigranular grossa de granito e (B) textura porfirítica fina de basalto, junto com as fotografias de (C) textura equigranular grossa de nefelina sienito e (D) textura porfirítica fina de dacito adakítico [44]. Bi = biotita; Pl = plagioclásio, Kf = K-feldspato, Q = quartzo, V = vidro, Cpx = clinopiroxênio, Hb = hornblenda. | 27 |
| Figura 2.16 Tipos de Anfibolitos [46] e [47]. | 34 |
| Figura 2.17 Tipos de Ardósias [48] e [49]. | 35 |
| Figura 2.18 Tipos de Eclogitos [50] e [51]. | 35 |
| Figura 2.19 Tipos de Esteatitos [52] e [53]. | 36 |
| Figura 2.20 Tipos de Filitos [54] e [55]. | 36 |
| Figura 2.21 Tipo de Ganisse [22]. | 37 |
| Figura 2.22 Tipos de Gonditos [56]. | 37 |
| Figura 2.23 Tipo de Itabarito [57]. | 38 |
| Figura 2.24 Tipos de Mármore [22]. | 38 |
| Figura 2.25 Tipos de Quartzitos [58]. | 39 |
| Figura 2.26 Tipo de Serpentinito [59]. | 40 |

| | |
|---|----|
| Figura 2.27 Tipos de Xistos [60] e [61]. | 41 |
| Figura 2.28 Milonito [62]. | 43 |
| Figura 2.29 Hornfels [63]. | 44 |
| Figura 2.30 Impactito [22]. | 45 |
| Figura 2.31 Granulito [64]. | 46 |
| Figura 3.1 Exemplo de duas imagens diferentes que possuem o mesmo histograma de primeira ordem. | 57 |
| Figura 3.2 As quatro direções de θ : 0, 45, 90 e 135 graus a partir do pixel central X. | 59 |
| Figura 3.3 Diferentes combinações de δ e ângulos para distâncias $\delta = 1$ e $\delta = 2$ que podem ser usadas para construir as matrizes de co-ocorrência [101]. | 60 |
| Figura 3.4 (a) Uma imagem com 3 níveis de cinza, $z_1=0$, $z_2=1$ e $z_3=2$. (b) Matriz de co-ocorrência P da imagem, na direção 0° e distância 1. O valor $P(i, j)$ armazenado em uma linha i na coluna j consiste no número de vezes em que pixels de valor i possuem vizinho de valor j à esquerda ou à direita e a uma distância de 1 pixel. | 61 |
| Figura 3.5 Imagem de listras horizontais [103]. | 66 |
| Figura 3.6 Histogramas somas e diferenças da Figura 3.5 para $t_1 = 1$ e $t_2 = 0$ [103]. | 67 |
| Figura 3.7 Autocorrelação vertical e horizontal da Figura 3.5. | 69 |
| Figura 3.8 Imagem de tamanho 7x7 pixels para cálculo do coeficiente de Hurst[108]. | 73 |
| Figura 3.9 Oito grupos de pixels correspondentes às distâncias[103]. | 74 |
| Figura 4.1 Árvore de decisão obtida com os dados da Tabela 4.1. | 80 |
| Figura 4.2 Regras de Classificação obtidas através da árvore de decisão da Figura 4.1. | 81 |
| Figura 4.3 Modelo de neurônio artificial não linear. | 84 |

| | |
|--|-----|
| Figura 4.4 Funções de ativação: (a) tangente hiperbólica sigmóide (tansig) e (b) sigmóide logarítmica (logsig) a direita..... | 85 |
| Figura 4.5 Arquitetura de uma rede neural do tipo MLP com uma camada oculta..... | 86 |
| Figura 4.6 Uma topologia de uma rede neural utilizando bases estatísticas. | 89 |
| Figura 4.7 Exemplo de um conjunto fuzzy representando projetos de longa duração. O eixo vertical representa o grau de pertinência que os membros do conjunto (duração do projeto em meses) possui com relação ao conjunto de projetos longos. | 91 |
| Figura 4.8 Sistema Fuzzy. | 92 |
| Figura 4.9 Exemplo de dois conjuntos fuzzy, importado e nacional, que mapeiam a variável “% de peças”..... | 93 |
| Figura 4.10 Função de pertinência com formato trapezoidal. | 95 |
| Figura 4.11 Sistemas Fuzzy de Classificação com duas entradas e três classes de saída | 97 |
| Figura 4.12 Particionamento possíveis para o espaço de entrada..... | 99 |
| Figura 4.13 Sistema NEFCLASS com duas entradas, cinco regras e duas classes de saída. | 103 |
| Figura 4.14 Representação da imagem de um triângulo por particionamento <i>quadtree</i> [8]. | 108 |
| Figura 4.15 (a) Exemplo de um particionamento <i>Quadtree</i> . (b) Árvore <i>Quadtree</i> referente ao particionamento da Figura 4.15b. | 109 |
| Figura 4.16 (a) Célula Neuro-Fuzzy <i>Quadtree</i> . (b) Célula NFHQ simplificada. | 110 |
| Figura 4.17 Célula NFHQ representada sob o formato de rede neuro-fuzzy. | 110 |
| Figura 4.18 (a) Exemplo de uma arquitetura NFHB. (b) Partição do espaço de entrada realizado pela arquitetura da Figura 4.18 (a). | 114 |
| Figura 4.19 Algoritmo de Aprendizado do modelo NFHQ..... | 117 |

| | |
|---|-----|
| Figura 4.20 Decomposição das partições. | 121 |
| Figura 4.21 Célula Neuro-Fuzzy BSP. | 123 |
| Figura 4.22 Exemplo de um sistema NFHB. | 124 |
| Figura 4.23 Exemplo de perfil das funções de pertinência da célula BSP-Invertida. | 126 |
| Figura 4.24 Célula NFHB-Invertida. | 126 |
| Figura 4.25 Interior da Célula NFHB-Invertida. | 127 |
| Figura 4.26 Arquitetura <i>NFHB</i> | 129 |
| Figura 4.27 Particionamento do espaço de entrada do sistema NFHB. | 129 |
| Figura 4.28 Arquitetura NFHB – Invertida. | 130 |
| Figura 4.29 Arquitetura NFBH – Invertida com as tabelas de graus de ativação de todos os padrões para todos os caminhos. A coluna da esquerda de cada tabela representa o número do padrão, e a coluna da direita representa o grau de ativação do respectivo padrão para um dado caminho. | 133 |
| Figura 4.30 Arquitetura NFHB-Invertida mostrando os pesos das ligações das saídas y_2 e y_5 das células folhas com os neurônios <i>T-conorms</i> classe1, classe2 e classe3. | 137 |
| Figura 4.31 (a) Arquitetura NFHB–Class. (b) Particionamento do espaço de entrada do sistema NFHB-Class. | 139 |
| Figura 4.32 Algoritmo de aprendizado do modelo NFHB-Class. | 141 |
| Figura 4.33 Decomposição BSP. | 146 |
| Figura 4.34 (a) Sistema ANFIS simplificado (2 entradas) para seleção de características ANFIS. (b) Respectivo particionamento. | 147 |
| Figura 5.1 (a) Base de dados exemplo. (b) Particionamento encontrado para a base de dados mostrada em (a). (c) Árvore neuro-fuzzy BSP. | 151 |
| Figura 5.2 Árvore <i>Crisp</i> | 152 |

| | |
|--|-----|
| Figura 5.3 Árvore Fuzzy..... | 152 |
| Figura 5.4 Regras <i>Crisp</i> x Regras Fuzzy. | 153 |
| Figura 5.5 Grau de pertinência usando o <i>T-norm</i> produto. | 154 |
| Figura 6.1 Exemplo de Arquitetura NFHB-Subclass para classificação de 4 classes macros com subclasses..... | 169 |
| Figura 6.2 Algoritmo de aprendizado do modelo da arquitetura NFHB-Subclass..... | 170 |
| Figura 6.3 Exemplo de Arquitetura RN-NFHB-Subclass para classificação de 4 classes macros com subclasses. | 172 |
| Figura 6.4 Algoritmo de aprendizado do modelo da arquitetura RN-NFHB-Subclass..... | 173 |
| Figura 6.5 Exemplo de Arquitetura RN-Hierárquico-SubClass para classificação de 4 classes macros com subclasses. | 174 |
| Figura 6.6 Algoritmo de aprendizado do modelo da arquitetura RN-Hierárquico-SubClass. | 176 |
| Figura 7.1 Estrutura em árvore do modelo NFHB-Class, sem conexões T-conorms, com estratégia de seleção adaptativa para o teste realizado com a rocha gnaisse..... | 226 |
| Figura 7.2 Estrutura completa em árvore do modelo NFHB-Class com estratégia de seleção adaptativa para o teste realizado com a rocha gnaisse..... | 229 |
| Figura 8.1 Imagem de uma seção delgada de rocha, vista sob um microscópio óptico, e com particionamento recursivo. | 234 |

Lista de Tabelas

| | |
|---|-----|
| <i>Tabela 2.1 Relação entre as expressões utilizadas para representar a granulometria de rochas ígneas.</i> | 22 |
| <i>Tabela 3.1 Descritores de textura baseados na matrizes de co-ocorrência</i> | 63 |
| <i>Tabela 3.2 Descritores de textura baseados nos histogramas de somas e diferenças</i> | 67 |
| <i>Tabela 4.1 Base de dados com os atributos preditivos: sexo, país e idade e com o atributo objetivo denominado comprar.</i> | 80 |
| <i>Tabela 5.1 Acurácias/α-cut</i> | 161 |
| <i>Tabela 7.1 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das subclasses das rochas gnaisse.</i> | 184 |
| <i>Tabela 7.2 Configurações das redes neurais utilizadas para as subclasses das rochas gnaisse.</i> | 185 |
| <i>Tabela 7.3 Desempenho das redes neurais, para as subclasses das rochas gnaisse.</i> | 185 |
| <i>Tabela 7.4 Melhor desempenho obtido pelos modelos, NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa) e redes neurais, para as subclasses das rochas gnaisse.</i> | 186 |
| <i>Tabela 7.5 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das subclasses das rochas basalto.</i> | 189 |
| <i>Tabela 7.6 Configurações das redes neurais utilizadas para as subclasses das rochas basalto.</i> | 190 |
| <i>Tabela 7.7 Desempenho das redes neurais, para a classe rocha basalto.</i> | 190 |

| | |
|---|-----|
| <i>Tabela 7.8 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para a classe rocha basalto.</i> | 191 |
| <i>Tabela 7.9 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das subclasses das rochas diabásio.</i> | 193 |
| <i>Tabela 7.10 Configurações das redes neurais utilizadas para as subclasses das rochas diabásio.</i> | 194 |
| <i>Tabela 7.11 Desempenho das redes neurais, para as subclasses das rochas diabásio.</i> | 194 |
| <i>Tabela 7.12 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para a classe rocha diabásio.</i> | 195 |
| <i>Tabela 7.13 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das subclasses das rochas riolito.</i> | 198 |
| <i>Tabela 7.14 Configurações das redes neurais utilizadas para as subclasses das rochas riolito.</i> | 199 |
| <i>Tabela 7.15 Desempenho das redes neurais para as subclasses das rochas riolito.</i> | 199 |
| <i>Tabela 7.16 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para a classe rocha riolito.</i> | 200 |
| <i>Tabela 7.17 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das classes das rochas gnaisse e basalto.</i> | 202 |
| <i>Tabela 7.18 Configurações das redes neurais utilizadas para as subclasses das rochas gnaisse e basalto.</i> | 203 |

| | |
|---|-----|
| <i>Tabela 7.19 Desempenho das redes neurais, para as subclasses das rochas gnaiss e basalto.</i> | 203 |
| <i>Tabela 7.20 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para as classes de rochas gnaiss e basalto.</i> | 204 |
| <i>Tabela 7.21 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das classes das rochas diabásio e riolito.</i> | 206 |
| <i>Tabela 7.22 Configurações das redes neurais utilizadas para as subclasses das rochas diabásio e riolito.</i> | 207 |
| <i>Tabela 7.23 Desempenho das redes neurais, para as subclasses das rochas diabásio e riolito.</i> | 207 |
| <i>Tabela 7.24 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para as classes de rochas diabásio e riolito.</i> | 208 |
| <i>Tabela 7.25 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das classes das rochas basalto, diabásio e riolito.</i> | 210 |
| <i>Tabela 7.26 Configurações das redes neurais utilizadas para as subclasses das rochas basalto, diabásio e riolito.</i> | 211 |
| <i>Tabela 7.27 Desempenho das redes neurais, para as subclasses das rochas basalto, diabásio e riolito.</i> | 211 |
| <i>Tabela 7.28 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para as classes de rochas basalto, diabásio e riolito.</i> | 212 |

| | |
|--|------------|
| <i>Tabela 7.29 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das classes das rochas gnaisse, basalto, diabásio e riolito.</i> | <i>214</i> |
| <i>Tabela 7.30 Configurações das redes neurais utilizadas para as subclasses das rochas gnaisse, basalto, diabásio e riolito.</i> | <i>215</i> |
| <i>Tabela 7.31 Desempenho das redes neurais para as subclasses das rochas gnaisse, basalto, diabásio e riolito.</i> | <i>216</i> |
| <i>Tabela 7.32 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para as classes de rochas gnaisse, basalto, diabásio e riolito.</i> | <i>217</i> |
| <i>Tabela 7.33 Configuração dos modelos NFHB-Class para os melhores resultados obtidos para classificação das classes macros das rochas gnaisse, basalto, diabásio e riolito.</i> | <i>219</i> |
| <i>Tabela 7.34 Configuração das redes neurais para os melhores resultados obtidos para classificação das classes macros das rochas gnaisse, basalto, diabásio e riolito.</i> | <i>220</i> |
| <i>Tabela 7.35 Configuração dos modelos NFHB-Class para os melhores resultados obtidos para classificação das subclasses das rochas gnaisse, basalto, diabásio e riolito. ..</i> | <i>220</i> |
| <i>Tabela 7.36 Configuração dos modelos RN-SubClass para os melhores resultados obtidos para classificação das subclasses das rochas gnaisse, basalto, diabásio e riolito. ..</i> | <i>221</i> |
| <i>Tabela 7.37 Resultados obtidos com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, para classificação das classes macro e subclasses das rochas gnaisse e basalto.</i> | <i>221</i> |
| <i>Tabela 7.38 Resultados obtidos com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, para classificação das classes macro e subclasses das rochas diabásio e riolito.</i> | <i>222</i> |

| | |
|---|------------|
| <i>Tabela 7.39 Resultados obtidos com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, para classificação das classes macro e subclasses das rochas basalto, diabásio e riolito.</i> | <i>223</i> |
| <i>Tabela 7.40 Resultados obtidos com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, para classificação das classes macro e subclasses das rochas gnaisse, basalto, diabásio e riolito.</i> | <i>224</i> |
| <i>Tabela 7.41 Comparação de desempenho entre vários sistemas para a classificação das subclasses das rochas gnaisse, basalto, diabásio e riolito.</i> | <i>225</i> |

Capítulo 1

Introdução

1.1. *Temática e Justificativas*

O petróleo é um recurso energético essencial à produção industrial. Ele é encontrado em uma variedade de ambientes geológicos.

A exploração de petróleo é uma das atividades humanas, em larga escala, na qual a aquisição, a distribuição e o uso de conhecimento especialista são críticos para a tomada de decisão. No Brasil, o elevado custo da exploração em águas profundas agrega um valor ainda maior ao conhecimento que suporta as decisões a respeito das áreas de perfuração.

O aprimoramento da tecnologia exploratória do petróleo primeiramente permitiu aos humanos escavar poços com pás e retirar o petróleo em baldes; depois veio o sistema de perfuração do solo até encontrar petróleo a 10 ou 20 pés (aproximadamente 3 ou 6 metros). Atualmente, o explorador pode procurar petróleo, mesmo que localizado em áreas

previamente inacessíveis, como a seis mil metros abaixo do fundo do mar. A inovação tecnológica também aperfeiçoou os tipos de petróleo que podem ser extraídos.

Dois conjuntos de informações são de fundamental importância na exploração de um novo campo petrolífero, sendo eles: a geometria do reservatório de petróleo e a descrição do tipo de rocha porosa que retém o petróleo.

A geometria externa do reservatório descreve a extensão e a forma da rocha que o contém. O conhecimento sobre a geometria dos depósitos é obtido por meio da investigação dos ambientes onde as rochas que compõem o reservatório foram geradas. Para isso, são feitos estudos de perfis elétricos, testemunhos e, principalmente, prospecção sísmica. Esses dados de geometria são fundamentais para a determinação da quantidade de petróleo do reservatório.

O segundo conjunto de informações descreve a rocha porosa que retém o petróleo, chamada rocha-reservatório. A qualidade de um reservatório é determinada pelas características originais dessa rocha, tais como: os minerais que a formam, o volume e forma dos poros (espaços que preservam fluidos dentro da rocha), as conexões entre esses poros e os processos físico-químicos que possam ter modificado essas características. Essas informações são associadas aos dados petrofísicos (porosidade e permeabilidade, por exemplo) do reservatório e às características do próprio petróleo, sendo utilizadas para calcular a vazão – ou produtividade – dos poços produtores de petróleo, bem como para determinar as técnicas possíveis de extração.

O estudo das rochas-reservatório é feito com descrições sistemáticas de amostras de rochas extraídas de poços de exploração de petróleo, ou seja, petrografia. A petrografia é uma atividade desenvolvida em laboratório, que integra os resultados de diferentes tipos de análises, que serão descritas a seguir.

Na análise macroscópica, as rochas são descritas à vista desarmada. As amostras são cilíndricas, devido ao corte pela broca de perfuração, e são chamadas de testemunhos. Amostras de calha, isto é, fragmentos de rochas de granulação variada, também podem ser descritas, sob escala macroscópica, utilizando-se, basicamente os mesmos critérios adotados para a descrição de testemunhos. A partir dessas amostras, são retiradas fatias de poucos centímetros, de onde são preparadas seções delgadas de 0,03mm de espessura, que serão, por sua vez, analisadas com o uso de microscópios ópticos de luz polarizada, gerando-se uma segunda descrição, petrográfica sob escala microscópica. No caso de amostras de calha, são selecionadas cerca de uma dúzia de fragmentos para a preparação de cada uma das seções delgadas para a microscopia.

Na análise macroscópica, são descritas cerca de uma dezena de características físicas tais como, por exemplo, a cor, estruturas, texturas, tamanho e orientação dos grãos e fósseis quando existentes. Na análise sob escala microscópica, realizada com o auxílio de um microscópio óptico, são descritas com maior detalhe feições mineralógicas, texturais e estruturais da rocha, com cerca de duas dezenas de características distintas. Além disso, são também descritos, individualmente, os constituintes que formam a rocha, incluindo minerais, fósseis e poros.

A Figura 1.1 mostra um trecho de testemunho utilizado para análise macroscópica e a Figura 1.2 ilustra uma seção delgada de rocha vista em uma análise microscópica [1].



Figura 1.1 Parte de um testemunho de rocha extraído de um poço de exploração de petróleo, utilizado para análise macroscópica.

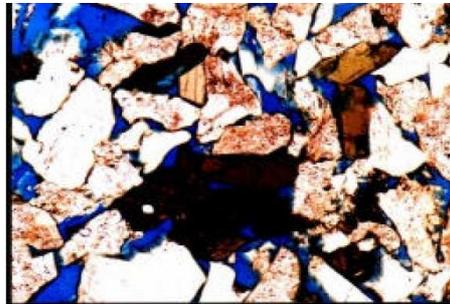


Figura 1.2. Imagem de uma seção delgada de rocha, vista sob um microscópio óptico de luz polarizada.

Existem muitas maneiras de classificar as rochas, sejam elas ígneas (ou magmáticas), sedimentares ou metamórficas.

As três classes de rochas citadas acima ainda podem ser subdivididas em subclasses.

A existência de um grande número de classes e subclasses torna difícil a tarefa de classificação das rochas, exigindo longo tempo de treinamento, uma vez que ela depende da identificação de feições baseadas em imagens.

Dessa forma, torna-se relevante e justificável o estudo de métodos capazes de apoiar e agilizar o trabalho de classificação de rochas, por meio da identificação e classificação de imagens que caracterizam essas rochas.

1.2. *Objetivos*

Esse trabalho tem por objetivo a criação de sistemas de identificação e classificação de imagens macroscópicas de rochas e de suas subclasses, de forma automática, usando técnicas de inteligência computacional, tais como: redes neurais e sistemas neuro-fuzzy hierárquicos.

O trabalho visa, então, apoiar a atividade de petrografia com a criação de sistemas capazes de classificar rochas e extrair regras que expliquem a classificação das classes e subclasses.

Este trabalho baseou-se no modelo Neuro-Fuzzy Hierárquico NFHB-Class [2], [3], [4], [5] com o intuito de realizar subclassificações, a partir de classificações macros.

O modelo NFHB-Class foi escolhido como referência, pois ele possui capacidade ilimitada de criação e expansão de sua estrutura, reduz a limitação quanto ao número de entradas (atributos da base de dados) e é capaz de extrair regras de conhecimento a partir de um conjunto de dados, além de ser específico para a tarefa de classificação de padrões.

O modelo NFHB-Class não é capaz de realizar classificações macros e subclassificações a partir das classes macros classificadas. Para eliminar essa limitação, criou-se nessa tese, o modelo NFHB-SubClass, que é capaz de classificar as classes macros e as suas subclasses. Esse modelo é composto de um modelo NFHB-Class, no topo da hierarquia, denominado de pai ou raiz, que executa a classificação macro. Em seguida, tendo realizado a classificação macro, irão existir outros sistemas NFHB-Class, subordinados ao sistema NFHB-Class pai, capazes de realizar a classificação das subclasses.

Os outros dois modelos criados nesta tese foram hibridizações de redes neurais com sistema NFHB-Class. São eles: sistema RN-NFHB-SubClass e sistema RN-Hierárquico-SubClass. O primeiro é constituído de uma rede neural no topo da hierarquia para realizar a classificação macro, sendo subordinados a ele, vários sistemas NFHB-Class para classificação das subclasses. O segundo também é formado por uma rede neural no topo da hierarquia para realizar a classificação macro, sendo subordinadas a ele, várias redes neurais para a classificação das subclasses.

Para validação dos três modelos Hierárquicos SubClass criados nessa tese, os mesmos serão implementados na plataforma Delphi 6.0, e serão realizados diversos testes com as classes e subclasses das rochas gnaisse, basalto, diabásio e riolito. A extração das características de textura das imagens das rochas gnaisse, basalto, diabásio e riolito serão realizadas pelo Matlab. Já implementação das redes neurais para os sistemas RN-NFHB-SubClass e sistema RN-Hierárquico-SubClass serão realizadas pelo software Qnet V2000 [7].

Por fim, vale resaltar que após a classificação das classes e subclasses das rochas, o modelo NFHB-SubClass consegue extrair regras de classificação das classes macros e das subclasses das rochas e o modelo RN-NFHB-SubClass consegue extrair regras somente para as subclasses das rochas, tendo em vista que o classificador da classe macro da rocha é uma rede neural.

1.3. *Descrição do Trabalho*

As principais etapas deste trabalho são:

- Estudo de conceitos básicos de petrografia, especificamente de classificação de rochas;
- Estudo das técnicas de identificação e descrição de texturas em imagens;
- Estudo de técnicas de seleção de variáveis relevantes em base de dados;
- Estudo dos métodos e modelos existentes para a tarefa de classificação de padrões;
- Estudo dos modelos neuro-fuzzy hierárquicos;
- Desenvolvimento de sistemas “inteligentes” capazes de classificar rochas e de um ambiente de testes para os modelos criados; e por fim,
- Análise dos resultados obtidos juntamente com as conclusões.

O estudo sobre as técnicas e identificação e descrição de texturas envolveu as abordagens estatística, espectral e estrutural. Foi feito um levantamento sobre os métodos mais utilizados para descrever texturas em imagens. Investigou-se em que ponto se encontram as pesquisas e trabalhos na área de classificação de imagens de rochas.

O estudo sobre os métodos de classificação de padrões envolveu as principais técnicas utilizadas para esta tarefa, tais como: métodos estatísticos, árvores de decisão, redes neurais, e sistemas híbridos neuro-fuzzy. Foi dado maior ênfase aos sistemas neuro-

fuzzy hierárquicos, especificamente ao sistema NFHB-Class, o qual proporcionou a criação dos Modelos Hierárquicos SubClass.

Foram feitos testes com o modelos NFHB-Class e utilizou-se um algoritmo de extração de regras baseado no caminhamento recursivo das células que compõem a estrutura do modelo [2], [3], [4], [5], [6]. Foram utilizadas as definições de abrangência fuzzy e acurácia fuzzy para validar a qualidade das regras geradas pelo modelo.

Foram criados os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, capazes de realizar a classificação das classes macros e das suas subclasses.

O ambiente para o desenvolvimento e testes dos modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass foi criado utilizando-se como ferramenta o Matlab, o Delphi 6.0 e Qnet V2000 [7].

1.4. *Estrutura da Tese*

A tese de doutorado possui mais oito capítulos, conforme listados a seguir.

O capítulo 2 apresenta uma descrição da área de petrografia. São abordadas as rochas ígneas, sedimentar e metamórficas e suas classificações.

No capítulo 3 são apresentadas as técnicas para identificação de texturas em imagens, além de apresentar o estado da arte de classificação de imagens de rochas.

O capítulo 4 faz um apanhado das principais técnicas de classificação de padrões. São apresentados métodos estatísticos e métodos baseados em inteligência computacional tais como redes neurais, sistemas fuzzy e sistemas neuro-fuzzy. São descritos de forma

detalhada os modelos neuro-fuzzy hierárquicos NFHQ, NFHB [8], NFHB-Invertido e NFHB-Class [2], [3], [4], [5].

O capítulo 5 descreve o processo de extração de regras, desenvolvido por Lanas [6] a partir da estrutura dos modelos NFHB-Invertido e NFHB-Class. São apresentados os conceitos de acurácia fuzzy e abrangência fuzzy para avaliar as regras geradas.

O capítulo 6 introduz os novos modelos hierárquicos desenvolvidos nessa teses: NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, capazes de realizar a classificação das classes macros das rochas e suas subclassificações, sem limitação quanto ao número de atributos de entrada, capazes de criar sua estrutura de forma automática, além de extrair regras que explicam a classificação.

No capítulo 7 são apresentados estudos de casos envolvendo a rocha metamórfica gnaisse, ígnea vulcânica basalto, ígnea hipabissal diabásio e ígnea vulcânica riolito, juntamente com suas subclasses, para avaliar os sistemas NFHB-Class, redes neurais, NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass.

No capítulo 8 serão apresentadas as conclusões deste trabalho e sugeridas novas propostas para trabalhos futuros.

Capítulo 2

Rochas

2.1. *Petrologia*

A petrologia, do grego *petros* (rocha) + *logos* (conhecimento), é o ramo da geologia que trata da origem, ocorrência, estrutura e história das rochas. Existem três campos de estudo principais em petrologia: ígnea, sedimentar e metamórfica [9], [10] e [11].

A petrologia ígnea foca a composição e textura de rochas ígneas (como o granito e o basalto, que cristalizam a partir de rocha fundida ou magma).

A petrologia sedimentar foca a composição e textura de rochas sedimentares (como o calcário e o arenito, compostas por partículas sedimentares agregadas por uma matriz de material mais fino, por vezes cimentadas, ou por material originado por decomposição química ou bioquímica).

A petrologia metamórfica foca a composição e textura de rochas metamórficas (como o gnaisse e o xisto), formados por alterações, mineralógicas e/ou texturais e/ou estruturais de rochas ígneas ou sedimentares devido à temperaturas e/ou pressões extremas.

A petrologia faz uso da mineralogia, da petrografia microscópica e das análises químicas para descrever a composição e textura das rochas.

2.2. Rochas Ígneas

Rocha ígnea ou rocha magmática é um tipo de rocha que resultou da consolidação do magma devido o resfriamento [9].

O processo de solidificação é complexo e nele podem distinguir-se a fase ortomagmática, a fase pegmatítica-pneumatolítica e a fase hidrotermal. Essas duas últimas dependem da composição original dos magmas, pressão e temperatura. As rochas ígneas são compostas, predominantemente, por compostos de feldspato, quartzo, olivina, piroxênios, anfibólios e micas. Ocupam cerca de 25% da superfície terrestre e 90% do volume terrestre [11].

O magma, ao solidificar-se, dependendo das condições - principalmente da pressão e temperatura - pode originar uma grande variedade de rochas, que se dividem em três grandes grupos [10], [11]:

- Rochas ígneas plutônicas, intrusivas ou abissais;
- Rochas ígneas vulcânicas, extrusivas ou efusivas;
- Rochas hipabissais.

2.2.1. Rochas Ígneas Plutônicas

As rochas ígneas plutônicas são formadas a partir do resfriamento do magma no interior da litosfera, sem contato com a superfície. Elas só apareceram à superfície depois de removido o material sedimentar ou metamórfico que a recobria. Em geral, o resfriamento é lento e ocorre a cristalização de minerais, não se formando vidro (material sólido não cristalino). Normalmente, as rochas plutônicas ou intrusivas apresentam uma estrutura maciça ou isotrópica. A sua textura mais corrente é granular ou fanerítica, isto é, os minerais apresentam-se visíveis à vista desarmada. A classificação detalhada das rochas magmáticas requer um estudo microscópico da mesma.

Em linhas gerais, podem considerar-se as seguintes famílias de rochas magmáticas, entre as quais existe toda uma série de outros tipos de rochas intermédias:

Família do granito: o granito é uma mistura de quartzo, feldspato e micas, além de outros minerais, que podem se encontrar em menores proporções e que recebem a denominação de minerais acessórios. Estes podem ser turmalinas, topázio, zircão e outros mais. O granito é uma rocha ácida (isto é, com $\text{SiO}_2 > 65\%$ peso) e pouco densa (2,65) que aparece abundantemente em grandes massas, formando regiões inteiras ou as zonas centrais de muitos acidentes montanhosos. O equivalente vulcânico do granito é o riolito. A Figura 2.1 mostra exemplos de granitos com diferentes texturas e cores [12], [13] e [14].



Figura 2.1 Exemplos de granitos com diferentes texturas e cores [12], [13] e [14].

Família do sienito: tem como minerais essenciais os feldspatos alcalinos, especialmente o ortoclásio, aos quais se associa a hornblenda, a augita e a biotita. O equivalente vulcânico do sienito é o traquito. A Figura 2.2 ilustra exemplos da família do sienito [15] e [16].



Figura 2.2 Exemplos da família do sienito [15] e [16].

Família do diorito: tem como minerais essenciais os plagioclásios (oligoclásio e andesina). A estes associam-se, em geral, a hornblenda, a augita e a biotita. O diorito é uma rocha intermediária ($55 < \text{SiO}_2 < 65$, em % peso) O equivalente vulcânico do diorito é o andesito. A Figura 2.3 ilustra exemplos da família do diorito [17] e [18].



Figura 2.3 Exemplos da família do diorito [17] e [18].

Família do gabro: são rochas escuras, verdes ou pretas, densas (3,0) sendo rochas básicas ($45\% < \text{SiO}_2 < 54\%$). Os seus minerais essenciais são os plagioclásios, labradorite e

anortite, acompanhados, geralmente, por augite e olivina. O equivalente vulcânico do gabro é o basalto. A Figura 2.4 ilustra exemplos da família do gabro [19], [20] e [21].



Figura 2.4 Exemplos da família do gabro [19], [20] e [21].

Família do peridotito: são rochas constituídas por piroxênios e, sobretudo, por olivina. São rochas ultrabásicas ($\text{SiO}_2 < 45\%$) muito densas (3,3) e escuras. O magma que as originou formou-se em grande profundidade, muitas vezes na parte superior do manto. Os peridotitos são rochas muito alteráveis por efeito dos agentes meteóricos, ou hidrotermais transformando-se em serpentinos, que são utilizados como pedras ornamentais, muito apreciada pela sua cor verde escura. O equivalente vulcânico da peridotito é uma rocha relativa rara chamada komatiíto. A ilustra exemplos da família do peridotito [22], [23] e [24].



Figura 2.5 Exemplos da família do peridotito [22], [23] e [24].

2.2.2. Rochas Ígneas Vulcânicas

São formadas a partir do resfriamento do material expelido pelas erupções vulcânicas atuais ou antigas. A consolidação do magma, então, acontece na superfície da crosta, em condições subaéreas ou subaquosas. O resfriamento é rápido, o que faz a que estas rochas, por vezes, apresentem vidro o que lhes confere uma textura vítrea. Logo a textura das rochas vulcânicas é afanítica, ou seja, não é possível observar seu material constituinte a olho nu. Há uma grande diversidade de rochas vulcânicas que se agrupam em alguns tipos gerais, quais sejam: riólitos, traquitos, andesitos e basaltos, entre os quais existe uma série de outras rochas, do mesmo modo que ocorre no caso das rochas plutônicas.

Família do riolito: riolito é uma rocha ígnea vulcânica; o correspondente extrusivo do granito. É pouco densa e possui uma granulação fina. A sua composição mineral inclui, geralmente quartzo, feldspatos alcalinos e plagiocláso. Os minerais acessórios mais comuns são a biotita e o piroxênio. Sua cor é cinza avermelhada, rosada, podendo ser até preta. A sua textura varia de afanítica a porfirítica, possuindo, em alguns casos, um certo arranjo orientado como consequência do movimento da lava. Dá-se a este aspecto o nome de estrutura fluidal. Os fenocristais são, normalmente, quartzo e feldspatos. Em relação aos basaltos, também rochas extrusivas, possuem uma ocorrência muito menor, não chegando a formar grandes corpos. A Figura 2.6 ilustra exemplos da família do riolito [25] e [26].



Figura 2.6 Exemplos da família do riolito [25] e [26].

Família do traquito: traquito é uma rocha com granulometria fina, constituída, principalmente, de feldspato alcalino, com pequena quantidade de minerais máficos (isto é, ricos em Fe e Mg), tais como anfibólio e biotita. As texturas e estruturas dos traquitos são semelhantes àquelas descritas para os riolitos. A Figura 2.7 ilustra exemplos da família do traquito [27] e [28].

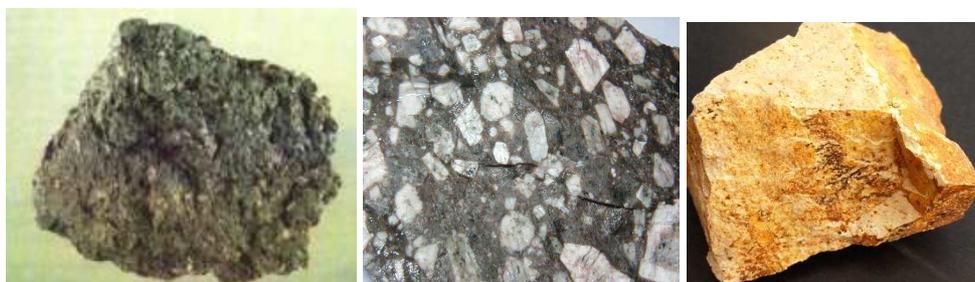


Figura 2.7 Exemplos da família do traquito [27] e [28].

Família do andesito: andesitos são compostos, essencialmente por feldspatos, dos quais mais de 66% devem ser plagioclásos ($10\% > Ca < 50\%$), e por minerais máficos tais como biotita, piroxênios e hornblenda. Nos andesitos leucocráticos (isto é, com até 30% de volume de minerais máficos), podem aparecer quantidades maiores de quartzo. O andesito é o equivalente vulcânico do diorito, sendo chamado dacito se a quantidade de quartzo ultrapassar 10% do volume total. Quando a quantidade de feldspato alcalino é superior a

30% do total de feldspatos, o andesito é chamado latito. Os andesitos podem ser classificados quanto ao índice de melanocráticos (isto é, com mais de 60% volume de minerais máficos) e leucocráticos. Outra classificação baseia-se na presença de fenocristais reconhecíveis entre os minerais acessórios, tais como a olivina (andesito olivínico), a zeólita (andesito zeolítico) ou a sanidina (andesito sanidínico). A ilustra exemplos da família do andesito [29], [30] e [31].



Figura 2.8 Exemplos da família do andesito [29], [30] e [31].

Família do basalto: O basalto é uma rocha ígnea vulcânica, de granulação fina afanítica, isto é, os cristais não são vistos à vista desarmada, podendo, ainda, conter grandes quantidades ou ser constituído integralmente de vidro. Esta rocha é constituída, principalmente, de plagioclásio e piroxênio e, em alguns casos, de olivina. Como minerais acessórios encontram-se, principalmente, óxidos de ferro, titânio e apactita. O basalto geralmente possui cor escura acentuada, sendo muito explorada para a construção civil. A Figura 2.9 ilustra exemplos da família do basalto [32], [33] e [34].



Figura 2.9 Exemplos da família do basalto [32], [33] e [34].

2.2.3. Rochas Ígneas Hipabissais

São as rochas que alguns autores consideram, de certo modo, transicionais entre as rochas vulcânicas e as rochas plutônicas. Sem atingir a superfície, aproximam-se muito dela e podem preencher as fissuras da crosta terrestre entre 1 Km e 5 Km de profundidade. Umas formam-se por resfriamento do magma numa fissura, em geral envolvendo também a ação de soluções hidrotermais. Todas as rochas filonianas se encontram em relação direta com o magma, isto é, com rochas intrusivas. São exemplos de rochas hipabissais, os lamprófiros e o diabásio.

Família do lamprófiro: lamprófiro é uma rocha ígnea metamórfica ultrapotássica, pouco comum, que ocorre em pequenos volumes sob a forma de diques, lopólitos, lacólitos ou pequenas intrusões. Os lamprófiros são as rochas escuras constituídas de olivina, piroxênios, anfibólios e micas, com textura tipicamente porfirítica. A Figura 2.10 ilustra um exemplo da família do lamprófiro [35].



Figura 2.10 Exemplo da família do lamprófiro. Os pontos escuros (piroxênios, olivinas e anfibólios) caracterizam a típica textura porfirítica dos lamprófiros [35].

Família do diabásio: diabásio ou dolerito (do grego *diábasis*, travessia e *diabaínein*, cruzar) é uma rocha magmática hipabissal, de textura ofítica (isto é, com grãos menores, chamados inclusões, totalmente inclusos num grão maior, chamado hospedeiro), constituída, essencialmente, por plagioclásios, piroxênio, magnetita e ilmenita. De cor preta, melanocrática, textura granular fina, mas possui muitas vezes textura granular mais grossa, sendo por isso fácil confundir-se com o gabro. É uma das rochas mais comuns. O diabásio se forma quando um magma de composição basáltica é injetado em fraturas de outras rochas, chamadas rochas encaixantes. Estas fraturas podem ser originadas pelo fraturamento hidráulico causado pelas intensas pressões do magma de uma câmara magmática. A rocha assim formada forma, comumente diques e soleiras, que podem variar de alguns centímetros de espessura até vários metros. Diques e soleiras são intrusões hipabissais tabulares, sendo discordantes e concordantes com a estrutura das rochas encaixantes. A Figura 2.11 ilustra exemplos da família do diabásio [36].



Figura 2.11 Exemplos da família do diabásio [36].

2.3. *Classificação das Rochas Ígneas*

Antes do século XIX, as rochas e os minerais eram distinguidos pelo modo de ocorrência geológica, idades relativas e cores predominantes, havendo mais de milhares de nomes. Para resolver este problema, foram realizados vários esforços para padronizar os nomes das rochas ígneas [37] e [38]. Até recentemente, a classificação de rochas ígneas não estava bem organizada [39]. Entretanto, propostas de classificação foram gradativamente organizadas, diminuindo acentuadamente a quantidade dos nomes das rochas.

2.4. *Critérios de Classificação das Rochas Ígneas*

Cada método de classificação tem sua vantagem e desvantagem e, portanto, é difícil apresentar um método adequado para classificar quaisquer rochas ígneas. Entre as tentativas de classificação organizada de rochas ígneas propostas até o presente, a recomendação da Subcomissão da Sistemática de Rochas Ígneas da IUGS (*Subcommission on the Systematics of Ingeous Rocks, Comission on Petrology, International Union of Geologicas Sciences*) é mais aceita pelos petrólogos [40], [41], [42]. A classificação de rochas ígneas é baseada na composição mineralógica quantitativa e, subordinadamente, na textura ou estrutura predominante, composição química, gênese e modo de ocorrência, dentre outros critérios complementares.

A granulometria é um critério textural importante para a classificação compelmentar, sendo representada pelas categorias grossa (> 3 mm), média (1-3mm) e fina (<1 mm). No entanto, há outros critérios texturais igualmente importantes, como exposto a seguir.

2.4.1. Critérios Texturais

Os critérios texturais importantes para classificação de rochas ígneas são: 1) **grau de cristalinidade**; 2) **granulometria**; 3) **interrelação granulométrica**. Estes aspectos de textura são intimamente relacionadas ao processo de resfriamento magmático, e a granulometria é a mais importante [43].

2.4.1.1. Cristalinidade

A cristalinidade corresponde ao grau de cristalização do magma, ou seja, a proporção de minerais e vidro que estão presentes nas rochas ígneas. Para ocorrer a cristalização dos minerais a partir do magma, precisa-se de um determinado tempo. Portanto, quando o resfriamento é relativamente lento, há tempo suficiente para formar uma rocha ígnea constituída totalmente de cristais. Por outro lado, quando o resfriamento é extremamente rápido, não há tempo suficiente, resultando uma rocha composta de vidro (Figura 2.12, Tabela 2.1). De acordo com a cristalinidade as rochas são classificadas em: 1) holocristalina; 2) hipocristalina; 3) vítrea.

Holocristalina: A rocha é composta inteiramente de cristais. A maioria das rochas ígneas se encaixa nessa categoria. Todas as rochas plutônicas são holocristalinas. As expressões rocha cristalina e embasamento cristalino, encontradas na literatura tradicional, correspondem respectivamente à rocha holocristalina e ao embasamento continental constituído por rochas holocristalinas, tais como granito e gnaisse, sobretudo de granulometria grossa e de idade precambriana. Entretanto, tais expressões tendem a ser

menos utilizadas nas publicações recentes. As rochas holocristalinas são formadas pelo resfriamento relativamente lento do magma.

Hipocristalina: É chamada também de **hialocristalina**: A rocha é constituída por uma mistura de cristais e vidro. As rochas hipocristalinas são formadas pelo resfriamento rápido do magma. Determinadas rochas constituintes de lavas são hipocristalinas.

Vítrea: É chamada também de **holohialina**. A rocha é composta quase inteiramente de vidro, o que significa resfriamento magmático extremamente rápido. Algumas rochas vulcânicas constituintes de lavas, tais como a obsidiana, são vítreas.

Tabela 2.1 Relação entre as expressões utilizadas para representar a granulometria de rochas ígneas.

| Expressão | Holocristalina | Resfriamento | Classificação | Exemplo |
|------------------|-----------------------|---------------------|----------------------|---|
| grossa | sim | muito lento | plutônica | gabro, granito, nefelina sienito |
| média | sim | meio lento | hipabissal | gânito pórfiro, tinguaito, diabásio ou dolerito |
| fina | sim | rápido | vulcânica | basalto, riolito, fonolito |
| microcristalina | sim | rápido | vulcânica | basalto, riolito, fonolito |
| criptocristalina | sim | muito rápido | vulcânica | basalto, riolito, fonolito |
| hialocristalina | não | super rápido | vulcânica | basalto, riolito, fonolito |
| vítrea | não | ultra rápido | vulcânica | obsidiana, riolito, fonolito |

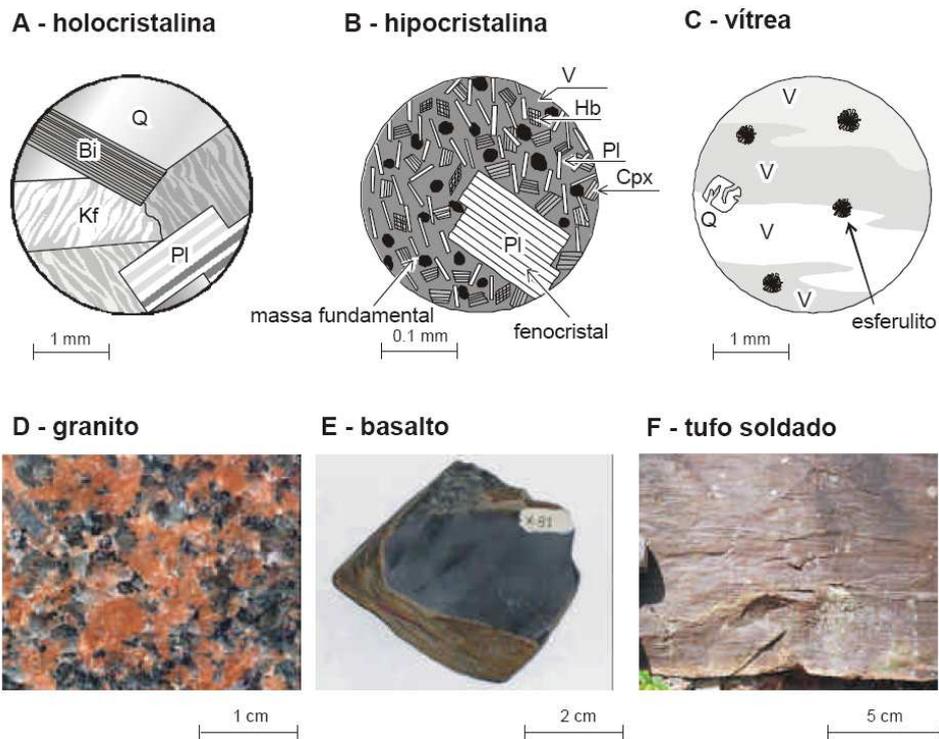


Figura 2.12 Ilustrações esquemáticas (A, B, C) e fotografias (D, E, F) relativas à cristalinidade de rochas ígneas: (A) granito, holocristalino; (B) basalto porfirítico com massa fundamental intersertal, hipocristalino; (C) riolito com esferulitos, vítreo; (D) Granito porfirítico, holocristalino; (E) basalto, hipocristalino; (F) Tufo soldado riolítico, vítreo [44]. Bi = biotita; Pl = plagioclásio, Kf = K-feldspato, Q = quartzo, V = vidro, Cpx = clinopiroxênio, Hb = hornblenda.

2.4.1.2. Granulometria

A granulometria representa a medida quantitativa do tamanho dos minerais constituintes de rochas ígneas, sobretudo as holocristalinas. Para um cristal formado a partir do magma tornar-se visível, necessita-se de um determinado tempo. Portanto, quando o resfriamento é lento, há tempo suficiente para formar uma rocha ígnea constituída por minerais de granulometria grossa. Por outro lado, quando o resfriamento é rápido, não há tempo para formar cristais grossos, resultando uma rocha com granulometria média a fina (Figura 2.13).

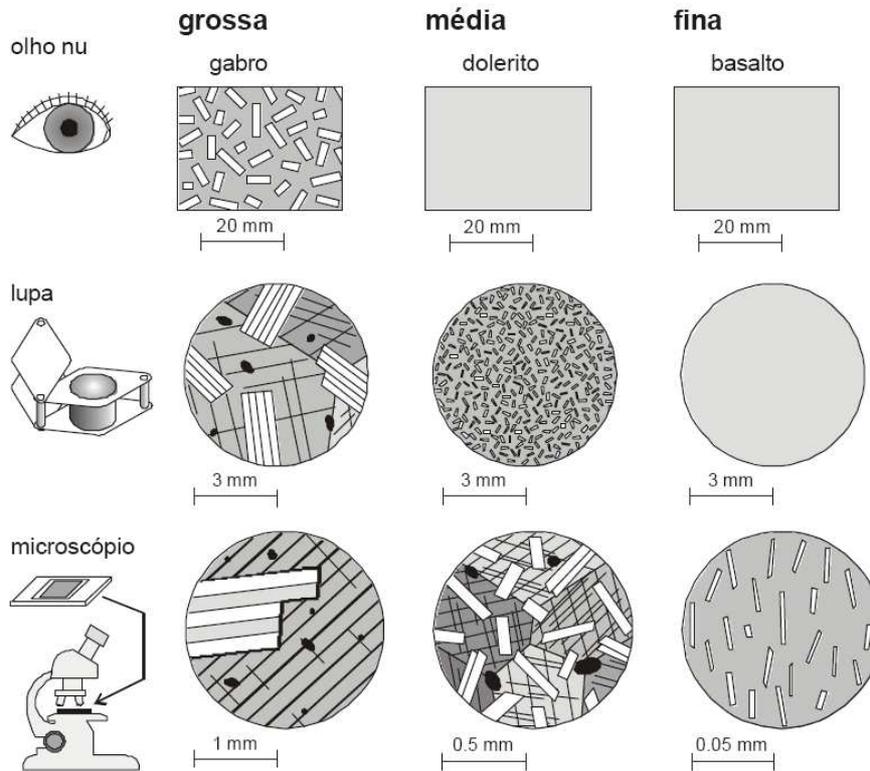


Figura 2.13 Ilustrações esquemáticas de granulometria grossa, média e fina de rochas ígneas, de acordo com os meios e instrumentos de observação. Nota-se que as escalas das observações microscópicas não são iguais [44].

A definição quantitativa das categorias de granulometria grossa, média e fina é variável de acordo com cada autor. Portanto, na descrição das rochas, é aconselhável referir à medida quantitativa, tal como milimétrica. A definição aqui apresentada é apenas um exemplo prático:

Grossa: Granulometria de 1 mm a 10 mm. Muitas rochas de natureza plutônica possuem granulometria em torno de 6 mm, se encaixando nesta categoria. As rochas ígneas com granulometria maior do que 10 mm são raras. A expressão rocha “grosseira” e de “granulação grosseira”, que se encontra em certas publicações nacionais como sinônimo de rocha de granulometria grossa, não deve ser utilizada. De fato, o termo “grosso” significa

rude, inconveniente ou de má qualidade. Normalmente, as rochas compostas de minerais com tamanho suficiente para serem identificados com facilidade a olho nu são descritas como de granulometria grossa. Granito, sienito, diorito e gabro são exemplos de rochas usualmente de granulometria grossa.

Média: Granulometria de 0,2 mm a 1 mm. Esta categoria granulométrica quantitativamente não é bem definida, sendo variável de acordo com cada autor. Na prática, muitas rochas descritas como de granulometria média são compostas de minerais de tamanho visível a olho nu ou à lupa. Porém geralmente, são um pouco difíceis de serem identificados. O diabásio é um exemplo de rochas com granulometria média.

Fina: Granulometria menor do que 0,2 mm. Normalmente, as rochas compostas de minerais com tamanho dos grãos imperceptíveis a olho nu ou à lupa são descritas como de granulometria fina. Tais rochas são estudadas em lâminas delgadas ao microscópio petrográfico. Riólito, fonólito, traquito, andesito e basalto são exemplos de rochas com granulometria fina.

Encontram-se os seguintes termos utilizados na literatura para representar as texturas macroscópicas de rochas ígneas:

Fanerítica: A rocha é constituída por minerais de tamanho distinguível à vista desarmada. Todas as rochas de granulometria grossa e uma parte das rochas de granulometria média se encaixam nesta categoria.

Afanítica: A rocha é composta de minerais de granulometria fina, sendo indistinguíveis à vista desarmada.

Nas observações das rochas naturais, a maioria das rochas ígneas se classifica em uma das duas categorias acima citadas.

Nas observações microscópicas de rochas com granulometria fina, são utilizados comumente, os seguintes termos (Figura 2.14).

Microcristalina: A rocha é constituída por minerais de tamanho distinguível, ou seja, identificáveis, somente sob o microscópio óptico.

Criptocristalina: A rocha é composta de minerais tão finos que não podem ser identificados nem mesmo sob o microscópio petrográfico, requerendo técnicas de difração de raios x ou microscopia eletrônica.

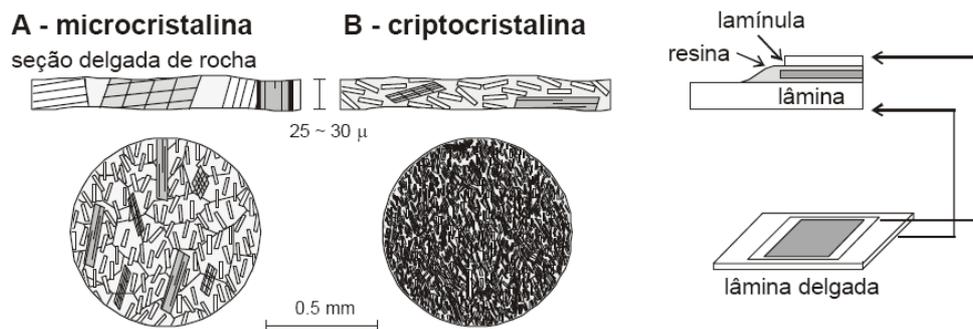


Figura 2.14 Relação entre a espessura e a granulometria das rochas ígneas finas: (A) microcristalina e (B) criptocristalina, com visão esquemática das respectivas imagens microscópicas. A escala é comum para ambas as rochas [44].

2.4.1.3. Interrelação Granulométrica

Existem rochas ígneas constituídas por minerais de tamanho aproximadamente igual cujas texturas são denominadas de equigranular. As rochas compostas de minerais de granulometria gradativamente variável são denominadas transgranulares sendo, porém, raras em rochas ígneas. Finalmente, as rochas com minerais de granulometria muito variável têm textura inequigranular. Nestes casos, comumente os minerais grossos são chamados de pórfiros e são circundados por uma matriz (ou massa fundamental) com minerais mais finos, resultando numa textura denominada porfirítica (Figura 2.15).

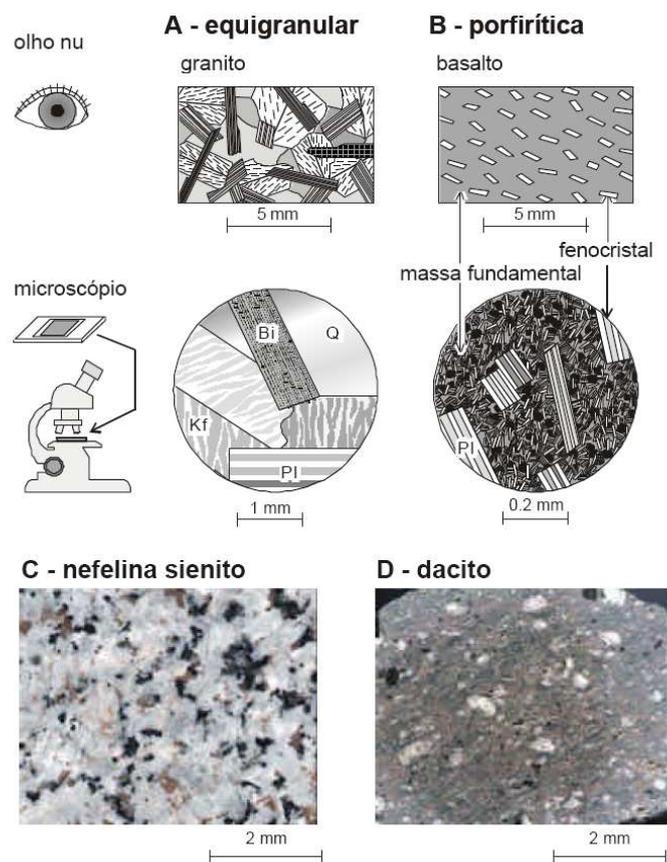


Figura 2.15 Ilustração esquemática de visão macroscópica e microscópica de (A) textura equigranular grossa de granito e (B) textura porfirítica fina de basalto, junto com as fotografias de (C) textura equigranular grossa de nefelina sienito e (D) textura porfirítica fina de dacito adakítico [44]. Bi = biotita; Pl = plagioclásio, Kf = K-feldspato, Q = quartzo, V = vidro, Cpx = clinopiroxênio, Hb = hornblenda.

2.5. Rochas Sedimentares

As rochas sedimentares são oriundas do acúmulo de materiais de outras rochas que lhes precederam ou da precipitação química ou bioquímica. Elas se formam, então, devido a destruição natural de todas as rochas na camada mais superficial da litosfera. O processo responsável por esta destruição chama-se intemperismo ou meteorização. O material assim originado pode ser transportado e depositado, seguindo-se a sua transformação em rocha pela consolidação dos sedimentos [45], um processo chamado diagênese.

A formação de uma rocha sedimentar decorre de uma sucessão de eventos, que constituem o chamado ciclo sedimentar. As etapas básicas do ciclo sedimentar são:

- Decomposição das rochas pré-existentes (intemperismo)
- Remoção e transporte dos produtos do intemperismo
- Deposição dos sedimentos
- Consolidação (endurecimento) dos sedimentos (diagênese)

Ao final do ciclo sedimentar, tem-se a formação das rochas sedimentares. Em função da característica do ciclo, há basicamente dois grandes grupos de sedimentos: os detriticos (fragmentos) e os químicos (solutos), que originam três grupos de rochas sedimentares: clásticas (ou siliciclásticas), químicas e orgânicas.

2.5.1. Rochas Clásticas

As rochas clásticas provêm de fragmentos (ou sedimentos) de rochas pré-existentes, também chamados de sedimentos detriticos, originários de processos predominantemente

físicos. Os sedimentos, assim considerados, podem variar em tamanho, desde partículas extremamente pequenas, até grandes blocos de rochas. Esses materiais estão sujeitos a serem transportados do local de intemperização até o ponto de acumulação através de águas, ventos e geleiras.

As rochas clásticas podem ser divididas em:

- Rochas Não Consolidadas ou Residuais
- Rochas Consolidadas ou Epiclásticas
- Rochas Piroclásticas

2.5.1.1. Rochas Residuais

São depósitos de material parcial/consolidado solto. Quando possuem textura grossa, não apresentam nenhuma coesão mas, quando existe mistura de material mais fino, apresentam alguma coesão.

Ex.: Areia Quartzífera, Cascalho Diamantífero, Argila Variegada, etc.

2.5.1.2. Rochas Epiclásticas

São depósitos de material detritico consolidado. A consolidação pode ser por simples compressão, em se tratando de partículas mais finas, ou por cimentação dos elementos texturais, quando são partículas mais grossas. A formação deste cimento é

natural e existem vários tipos, tais como: cimento argiloso, cimento calcário, cimento micáceo, cimento ferruginoso, cimento silicoso e sulfático.

Conforme o tamanho das partículas (elementos texturais) que as compõe, estas rochas podem ser divididas em:

- ***Psefitos*** – são também chamados de conglomerados. São formados por partículas maiores que 2 mm de diâmetro. As partículas são unidas por cimentação. Exemplos: Brechas e Conglomerados.

- ***Psamitos*** – são formados por partículas de 2 mm a 0,05 mm de diâmetro. Essa faixa de tamanho engloba todas as partículas componentes da fração areia. São também unidas por cimento. Exemplo: Arenito.

- ***Pelitos*** – formados por partículas menores que 0,05 mm de diâmetro e se consolidam apenas por compressão. Exemplos: siltitos (partículas de silte), argilitos (partículas de argila), folhelhos (partículas de argila e silte).

2.5.1.3. Rochas Piroclásticas

Encontradas, comumente, em regiões vulcânicas. São rochas formadas pela consolidação de materiais piroclásticos, isto é, fragmentos lançados aos ares em virtudes de manifestações vulcânicas explosivas. Estas rochas podem ser divididas em:

- **Tufo vulcânico:** rochas formadas pela consolidação de lúpili (fragmentos entre 2 mm e 64 mm) ou cinzas (fragmentos menores que 2 mm). Também chamado tufitos.

- **Brecha vulcânica** formadas de blocos (fragmentos maiores que 64 mm) dentro de uma matriz de tuffítica.

2.5.2. Rochas Químicas

As rochas químicas se originam da precipitação de substâncias contidas em solução nas águas dos mares ou lagoas salgadas, ou por precipitação de substâncias solúveis transportadas pelas águas, após saturação.

Existem dois tipos de formação destas rochas:

- Rochas formadas pela evaporação da água e conseqüente precipitação dos sais contidos em solução. São chamadas de evaporitos.

Exemplos: Sal Gema, Anidrita, Gipsita e alguns tipos de Calcários.

- Rochas formadas pela atividade bioquímica de organismos vivos existentes nestas águas, que transformam os sais solúveis em sais insolúveis, propiciando, então, sua precipitação.

Exemplos: Alguns tipos de Calcários (> 50% vol. de calcita; CaCO_3) e Dolomitos (> 50% de dolomita; $(\text{Ca},\text{Mg})\text{CO}_3$).

2.5.3. Rochas Orgânicas

São rochas sedimentares derivadas de resíduos orgânicos de qualquer natureza. As rochas orgânicas são também chamadas de **Biólitos** e são divididas em:

- **Caustobiólitos**: são rochas orgânicas combustíveis.

Exemplos: Turfa, Lignita, Hulha, Antracito e Petróleo.

- **Acaustobiólitos**: rochas orgânicas não combustíveis.

Exemplo: calcários de recifes de corais.

2.6. Rochas Metamórficas

As rochas metamórficas (grego: *meta*=mudança; *morfos*=forma) correspondem a transformações *no estado sólido* de rochas pré-existentes, chamados de **PROTÓLITOS** (grego: *proto*=primeiro/anterior; *lithos*=rocha). Os protólitos podem ser ígneos, sedimentares ou, mesmo, metamórficos. Em casos mais raros e nem sempre fáceis de serem determinados, podem, ainda, corresponder a produtos de alteração intempérica (solos, paleossolos, lateritas, dentre outros) ou hidrotermal/metassomática (*greisen*, skarnitos e pegmatitos caulinizados, por exemplo).

As variáveis ou fatores fundamentais do metamorfismo das rochas são :

- temperatura
- pressão de carga ou litostática (resultante vetorial igual a zero)
- pressão dirigida (resultante vetorial diferente de zero)
- pressão de fluidos
- composição da rocha
- composição da fase fluida

A velocidade com que se realiza esta transformação (cinética) depende ainda de outros fatores intrínsecos e extrínsecos, tais como:

- textura e cristalinidade da rocha
- gradiente de modificação das condições
- tempo geológico em que persistem as novas condições.

2.6.1. Classificação das Rochas Metamórficas

As rochas metamórficas são designadas, em geral, por um **termo base** que podem, e em certos casos devem, ser antecidos ou sucedidos por **outros termos complementares**.

Na bibliografia não há consenso sobre regras para a designação das rochas metamórficas havendo, inclusive, controvérsias a respeito de certos termos. Isto é compreensível pois a designação/determinação das rochas metamórficas envolve conceitos poligenéticos, não só os da rocha original, com química, texturas e estruturas variavelmente preservados, como os da evolução propiciada pelos vários eventos metamórficos. Essa complexidade evolutiva pode levar mesmo à formação de rochas semelhantes a partir de protólitos completamente distintos – Assim, gnaisses podem ser originados de um pelito ou de um granito, enquanto que, por outro lado, rochas muito diferentes podem ser formadas a partir do mesmo protólito, dependendo dos fatores de metamorfismo, como ocorre, por exemplo, com o xisto azul, xisto verde, anfíbolito e eclogito, todos derivados de basalto.

As rochas metamórficas são classificadas e designadas de acordo com vários critérios, notadamente os que envolvem a **rocha de origem, a composição** (química ou mineral) da rocha, o **tipo e grau de metamorfismo** e **aspectos texturais/estruturais** metamórficos.

É importante ressaltar que as rochas metamórficas ocorrem sempre com variações laterais e verticais que podem ser bastante bruscas, seja devido às variações originais da composição do protólito seja devido à variabilidade de tensões e fluidos, por exemplo.

2.6.1.1. Classificação com Critério Composicional Importante

Termos Base

A seguir são relacionadas designações de várias rochas metamórficas em que o critério composicional é importante, mas não necessariamente o único:

ANFIBOLITO - derivado de rochas básicas ou de rochas sedimentares como calcários impuros; tem a hornblenda e o plagioclásio como paragênese (isto é, associação mineral sob equilíbrio termodinâmico) característica de grau metamórfico médio a alto. Pode se apresentar maciço, bandado ou, mais comumente, com lineação (isto é, um arranjo preferencialmente linear de seus constituintes minerais). A Figura 2.16 ilustra tipos de anfibolitos [46] e [47].



Figura 2.16 Tipos de Anfibolitos [46] e [47].

ARDÓSIA - rocha metamórfica de baixo grau (isto é, formada a temperaturas relativamente baixas); granulação muito fina, pouco brilho, cristalinidade baixa, clivagem ardosiana (ou seja, uma arranjo preferencialmente planar de seus constituintes minerais). O protólito geralmente é pelítico e a paragênese típica inclui quartzo, sericita/fengita, clorita e pirofilita. Com aumento de metamorfismo regional transforma-se em filito e xisto. A Figura 2.17 ilustra tipos de ardósia [48] e [49].



Figura 2.17 Tipos de Ardósias [48] e [49].

ECLOGITO - rocha básica, cujo protótipo (basalto ou gabro) foi submetido a metamorfismo sob alta razão P/T, típica de duplicação crustal, com pressões maiores do que 10 kbar (>30 km de crosta sobrejacente) e temperaturas variáveis que podem chegar aos 1.000° C. O eclogito é uma rocha geralmente granoblástica, cujos componentes são fases minerais estáveis às altas pressões e temperaturas quais sejam: piroxênio sódico (onfacita), e granada magnésica (piropo). A Figura 2.18 ilustra tipos de Eclogitos [50] e [51].



Figura 2.18 Tipos de Eclogitos [50] e [51].

ESTEATITO ou **PEDRA-SABÃO** - rocha composta, essencialmente, por talco ao qual podem se agregar magnesita e quartzo. É derivada principalmente de rochas ígneas ultramáficas. A Figura 2.19 ilustra tipos de esteatitos [52] e [53].

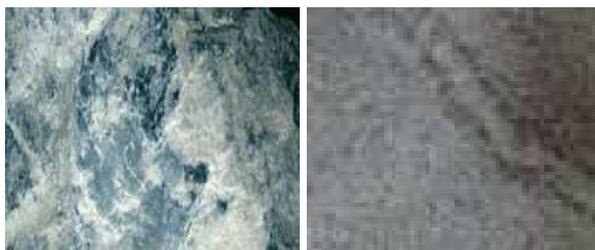


Figura 2.19 Tipos de Esteatitos [52] e [53].

FILITO - rocha intermediária entre ardósia e xisto na evolução metamórfica de pelitos. Diferentemente da ardósia, o plano de xistosidade é bem definido e brilhante, determinado pela disposição de mica. A Figura 2.20 ilustra tipos de filitos [54] e [55].



Figura 2.20 Tipos de Filitos [54] e [55].

GNAISSE - rocha cujos componentes mineralógicos essenciais são quartzo e feldspato, com estrutura planar maciça com estiramento dos grãos (lineação) ou em bandas quartzo-feldspáticas alternadas com bandas ricas em minerais máficos.



Figura 2.21 Tipo de Ganisse.

GONDITO - rocha metamórfica cujos componentes principais são a granada manganésifera (espessartita) e o quartzo. Deriva, fundamentalmente, de camadas de *chert* (rochas sedimentares químicas silicosas) associado com vulcanismo. A Figura 2.22 ilustra tipos de gondito [56].



Figura 2.22 Tipos de Gonditos [56].

ITABIRITO - descrita em Itabira, MG, o itabirito é uma rocha bandada, alternando níveis milimétricos a centimétricos de hematita (ou magnetita) com níveis silicáticos, geralmente de quartzo. A Figura 2.23 ilustra um tipo de itabirito [57].



Figura 2.23 Tipo de Itabarito [57].

MÁRMORE – tem o calcário como protólito sendo constituído por (>50%) um carbonato, geralmente, calcítico ou dolomítico. Ocorre com estruturas maciça, bandada, brechóide (isto é, de aspecto fragmentado).



Figura 2.24 Tipos de Mármore.

QUARTZITO – rocha metamórfica cujo componente principal é o quartzo (>75% volume). Pode derivar de arenitos quartzosos, riolitos silicosos, *chert*, ou veios de quartzo. A Figura 2.25 ilustra tipos de quartzitos [58].



Figura 2.25 Tipos de Quartzitos [58].

ROCHA CALCISILICÁTICA - rocha maciça ou bandada, composta por misturas de silicatos e carbonatos como **epidoto, diopsídio, granada grossulária e escapolita, por exemplo**. Derivada de calcários impuros (isto é, formados por carbonatos e margas argilominerais).

SERPENTINITO - rocha composta por serpentina predominante. Pode ser maciça ou xistosa, caso em que pode ser chamada de serpentina xisto. À semelhança do serpentinito, ocorrem várias rochas metamórficas maciças com tendência monominerálica em que o mineral predominante, metamórfico, dá o nome a rocha, como: clorito, actinolitito, tremolitito epidotito, dentre outras. No entanto, deve ser lembrado que há rochas monominerálicas ígneas, tais como hornblenditos piroxenitos e dunitos, por exemplo, e sedimentares, como arenitos ortoquarzíticos, argilitos e calcários, dentre outras. A Figura 2.26 ilustra um tipo de serpentinito [59].



Figura 2.26 Tipo de Serpentinito [59].

TACTITO ou SKARNITO - calcário ou margas submetida a metamorfismo e/ou metassomatismo de contato. O metamorfismo de contato é um processo isoquímico caracterizado por baixa razão P/T, enquanto o metassomatismo é o seu correspondente aloquímico.

XISTO - termo geral para qualquer rocha que apresenta xistosidade (isto é, uma estrutura planar bem definida mas não bandada). Como acontece com muitas outras rochas metamórficas, a este termo devem ser agregados termos antecedentes e/ou termos sucedentes que caracterizem, composicionalmente, a rocha. Por exemplo: granada biotita xisto grafítico. O xisto micáceo deriva, frequentemente, de pelitos (pode derivar de plutonitos e vulcanitos ácidos e aluminosos também) representando um grau mais elevado de metamorfismo do que a ardósia e o filito. O xisto é muito brilhante devido ao crescimento de micas metamórficas (muscovita e biotita, principalmente), xistosidade bem desenvolvida, muitas vezes crenulada (isto é, dobrada sob escala milimétrica) por deformações superimpostas. Pode haver segregação de quartzo (ou carbonatos, nos xistos calcíticos) em bandas ou charneiras (no “nariz”) de dobras formando lentes centimétricas a decimétricas no meio da massa micácea. A Figura 2.27 ilustra tipos de xistos [60] e [61].



Figura 2.27 Tipos de Xistos [60] e [61].

XISTO VERDE - termo especial para designar xisto derivado de rocha máfica, em condições de baixo grau metamórfico, formando minerais verdes como actinolita, epidoto e clorita, por exemplo, juntamente com albita e quartzo.

XISTO AZUL - termo especial para designar xisto derivado de rocha máfica, em condições de baixa temperatura e alta pressão, caracterizado por minerais azuis como o anfibólio sódico glaucofana além de lawsonita epidoto e clorita, por exemplo.

Uso de nomes de minerais metamórficos antes do termo base

A classificação de uma rocha metamórfica exige, muitas vezes, a utilização de **nomes de minerais**. Assim, por exemplo, uma rocha pode ter somente 1% de sillimanita, mas a importância do mineral como indicador de condições metamórficas exige o uso de seu nome antes do termo base (por exemplo: sillimanita gnaisse).

Vários nomes de minerais podem anteceder, assim, o nome da rocha para a sua classificação, seguindo-se como regra que os nomes dos minerais mais próximos do nome da rocha correspondem àqueles que ocorrem em maior abundância. Por exemplo: uma rocha classificada como cordierita granada biotita muscovita xisto contém mais muscovita

que biotita, mais biotita que granada e mais granada do que cordierita. Nomes de minerais em rochas que já os tem como característicos de sua composição não são usados, como por exemplo hornblenda e plagioclásio em anfibolito e quartzo, até 40 %, em xistos micáceos.

Uso de nomes de minerais metamórficos após o termo base

Não há regra rígida no uso destes termos que sucedem o nome principal da rocha. Entretanto, o seu uso retrata, muitas vezes, teores menores mas que devem ser realçados tanto para a caracterização mineralógico-petrográfica quanto química e que podem ter implicações genéticas. São exemplos: Metachert manganésífero, Gnaiss granodiorítico, Xisto máfico, Xisto feldspático, Micaxisto granatífero, Xisto calcítico, Xisto grafitoso.

2.6.1.2. Classificação com Critério “Tipo de Metamorfismo” Importante

Rochas submetidas a metamorfismo dinâmico (isto é, onde o principal parâmetro do metamorfismo é a pressão dirigida)

CATACLASITO - rocha de metamorfismo dinâmico ou cataclástico em que os componentes minerais se fragmentaram durante o metamorfismo, favorecendo a geração de textura com grãos minerais cominuídos e rotacionados, com crescimento metamórfico muito limitado ou inexistente.

FILONITO - filonito é um milonito com foliação minolítica conspícua.

MILONITO - (*to mill*= moer) - rocha com grãos recristalizados minúsculos (em oposição à triturados), com componentes minerais submetidos à “stress” em campo dúctil ou plástico. A deformação típica é o estiramento e/ou achatamento dos grãos, algumas vezes definindo uma *foliação milonítica*. A formação de cataclasito ou milonito é comandada pelas propriedades reológicas da rocha que varia, também, com a menor ou maior pressão de H₂O e/ou CO₂, sendo a rocha devolatilizada geralmente mais quebradiça. A Figura 2.28 ilustra um exemplo de milonito [62].



Figura 2.28 Milonito [62].

BLASTOMILONITO -rocha polimetamórfica que, já tendo sido um milonito, foi, posteriormente, recristalizada, em episódios metamórficos subsequentes.

Os prefixos **PROTO E ULTRA** para os termos **CATACLASITO** e **MILONITO** referem-se, respectivamente, a percentagem menor (10-50%) e maior (>90%) de matriz minúscula por trituração (ou cataclase) ou recristalização da rocha, respectivamente.

Rochas submetidas a metamorfismo de contato predominante

HORNFELS ou **CORNUBIANITO** - rocha sem orientação preferencial, de constituintes minerais, com textura fina, muitas vezes poiquiloblástica e que ocorre nos contatos metamorfizados por condução ou convecção térmica a partir de intrusões ricas em elementos voláteis (isto é, com um grão hospedeiro maior contendo inclusões de grãos menores). A Figura 2.29 ilustra exemplos de hornfels [63].



Figura 2.29 Hornfels [63].

Rochas submetidas a metamorfismo de impacto predominante

IMPACTITO - rocha formada pelo metamorfismo de impacto de meteoros com a crosta continental, texturas e estruturas típicas e com mineralogia característica de muito alta pressão, como coesita, stishovita, mullita e vidro. A Figura 2.30 ilustra exemplos de impactitos.



Figura 2.30 Impactito.

Rochas submetidas a metamorfismo regional predominante

Em termos de extensão, como o próprio nome diz, as rochas de metamorfismo regional são as mais importantes nas áreas continentais. Muitas das rochas citadas anteriormente são de metamorfismo regional. Uma série típica de evolução de graus mais baixos para mais altos neste tipo de metamorfismo é a das rochas pelíticas conforme indicada abaixo:

ardósia => filito => xisto => gnaisse => granulito

GRANULITO - rocha de alto grau metamórfico cuja designação é a mesma da fácies metamórfica regional de alta temperatura, elevado grau geotérmico (dT/dP) e condições anidras ($P_{carga} \gg P_{H_2O}$). A classificação da rocha pode vir acompanhada de sua caracterização composicional (Por exemplo: granulito ácido; granulito diorítico, granulito ultramáfico). Existem termos específicos para alguns granulitos, tais como leptinito, charnockito e enderbito, São rochas granoblásticas (isto é, com textura caracterizada pela geometria poligonizada dos grãos), maciças a foliadas, granulação

variável de muito fina (leptinitos, por exemplo) até muito grossa (alguns charnockitos, por exemplo). A Figura 2.31 ilustra um exemplo de granulito [64].



Figura 2.31 Granulito [64].

2.6.1.3. Classificação quanto a origem

Uso do prefixo META (indicação do protólito)

Quando se tem certeza da rocha de origem, pode-se usar o *prefixo META* para designar a rocha metamórfica. São exemplos: metabasalto, metagranito, metassedimento, metavulcanito, meta-arenito, metassiltito, metachert e metapelito.

Observar que o uso do prefixo meta não caracteriza o grau nem a textura e estrutura metamórficos da rocha. Este critério de designação é muito comum em terrenos anquimetamórfico (isto é de muito baixo grau metamórfico) nos quais as rochas originais estão mais bem preservadas.

Uso do nome protólito com sufixo indicativo da rocha metamórfica

Alem do prefixo meta, usa-se indicar o nome da rocha original sucedido por termos que indicam a rocha metamórfica atual. *Ex:* **granito gnaisseficado; gabro anfibolitizado.** Estas designações implicam em reconhecimento seguro do protólito, muitas vezes devido ao fato de que o metamorfismo não foi pervasivo ou foi parcial na rocha.

Uso do prefixo ORTO e PARA

Os prefixos ORTO e PARA antecedem o termo base que identifica a rocha metamórfica (*Ex.:* **ortoanfibolito e paragnaisse**) e o uso deles implica em uma identificação genética segura da rocha de origem com o seguinte critério:

orto - a rocha original é **ígnea**, plutônica, hipabissal ou vulcânica

para - a rocha original é **sedimentar**

2.7. Resumo

Neste capítulo foi apresentada uma descrição da área de petrografia e as principais abordagens texturais de classificação de rochas ígneas, sedimentares e metamórficas.

O próximo capítulo faz uma abordagem das técnicas para identificação de texturas em imagens, além de apresentar o estado da arte de classificação de imagens de rochas e em outras aplicações.

Capítulo 3

Textura

Segundo Turceyan e Jain [65], textura de uma imagem é uma combinação de semelhantes padrões com uma frequência regular. Para IEEE Standard [66] é um atributo que representa um arranjo espacial dos *pixels* em uma região. Jain [67] define textura como uma repetição de padrões básicos no espaço. Conci et All [103] referem-se a textura como um padrão visual que possui algumas propriedades de homogeneidade que não resulta simplesmente de uma cor ou intensidade, podendo ser definida como o aspecto visual de uma superfície.

Apesar de não existir uma definição precisa para textura, ela é facilmente perceptível pela visão humana devido ao seu conjunto de padrões visuais compostos por sub-padrões que apresentam propriedades destacáveis como, por exemplo, uniformidade, densidade, aspereza, regularidade, intensidade, etc [102].

Na área de processamento de imagens texturas podem ser definidas como padrões de repetição de determinados elementos formadores, os chamados *texels*. Um *texel* pode ser definido como a menor área da imagem digital que compõem um textura distinta. O tamanho da região de uma imagem analisada, não pode ser muito pequeno quando comparado ao elemento básico, o *texel*. Assim a textura pode ser caracterizada pela repetição de um modelo (*texton* ou *texel*) sobre uma região. Esse modelo pode ser repetido de forma precisa ou com variações (randômicas ou não) e ruídos sobre um mesmo tema. Tamanho, formato, cor e orientação dos elementos do modelo podem variar sobre as regiões, caracterizando a diversidade de padrões de uma textura [103].

A análise de textura das imagens vem sendo muito utilizada em diversas áreas de aplicação, tais como: automação industrial, análise de imagens de satélites, diagnósticos médicos e reconhecimento no campo da biometria, por exemplo.

3.1. *Trabalhos de textura em diversas aplicações*

O desenvolvimento de metodologias implementando atributos de textura no processo de classificação de imagens digitais vem sendo objeto de atenção da comunidade científica. Abordagens diversas vem sendo relatadas na literatura internacional, tais como: IEEE Transactions on Pattern Analysis and Machine Intelligence, IEEE Transactions on Image Processing, IEEE Transactions on Geoscience and Remote Sensing, Pattern Recognition, além de vários outros periódicos.

Em Muhamad e Deravi [68] é feito um amplo estudo da eficiência de atributos extraídos de matrizes de coocorrência e de seu uso direto com dados de entrada em um classificador de rede neural. A eficiência da rede neural é comprovada pela classificação superficial de textura de cinco tipos de partículas em suspensão encontradas em óleos lubrificantes utilizados em máquinas. Foram encontrados resultados de classificação na ordem de 96% de acerto.

Raghu et al. [69] apresentam uma estrutura de rede neural que combina as características de duas redes neurais: rede neural SOM – *Self Organizing Map* – e rede neural MLP – *Multilayer Perceptron* – para classificação de textura. As características texturais são obtidas através do uso de um banco de filtros de Gabor que tem tamanhos, orientações e frequências espaciais diferentes. A rede neural SOM age como um mecanismo de clusterização. As características geradas pela rede neural SOM são utilizadas para alimentar a rede neural MLP com finalidade de classificação.

Augusteijn et al. [70] fazem uma comparação entre as performances de vários métodos para extração de atributos para classificação de imagem terrestres obtidas por satélites. Os métodos considerados foram: matrizes de coocorrência, diferenças de nível de cinza, análise de textura-tom, transformada de Fourier e filtros de Gabor. Foi mostrado que os métodos de Fourier e filtros de Gabor foram mais eficientes quando uma única banda de frequência espacial foi utilizada na classificação.

Martins [71] desenvolveu um classificador de texturas para atuar no desenvolvimento de sistemas de administração de imagens de sensoriamento remoto através de busca e recuperação de imagens por quadrantes.

Shisong e Chih-Cheng [72] propuseram um novo método de representação da textura baseado no conceito de visões de um determinado padrão de textura. Basicamente o

conceito aplicado é que uma determinada classe possui inúmeros padrões de textura e ainda que cada um desses padrões possui algumas visões. Essas visões foram obtidas com dados de treinamento e através de uma série de parâmetros de textura. Foi desenvolvido então um algoritmo de classificação semelhante ao KNN, o *K-View*. Esse método em linhas gerais atribui o padrão analisado a classe que possui “visões” mais semelhantes. Esses métodos de extração de textura e de classificação foram aplicados a imagens de satélite de alta resolução resultando num incremento significativo da capacidade de discriminação de classes de cobertura de solo.

Lelong e Thong-Chane [73] aplicaram uma análise de textura em imagens IKONOS e QUICKBIRD para mapeamento de árvores, pomares e plantações de café em Uganda. Foram utilizados parâmetros de textura de Haralick, calculados com base na matriz de coocorrência de níveis de cinza ou GLCM (*gray-level cooccurrence matrix*). Os resultados relatados no trabalho foram muito positivos principalmente no que diz respeito ao reconhecimento de árvores e pomares. Porém o autor relata uma dificuldade para determinar a dimensão ideal da vizinhança em torno de cada pixel a ser usada no cálculo dos atributos de textura. Um outro trabalho [74] reafirma a importância da informação de textura no processo de classificação, e ressalta igualmente a necessidade de uma escolha adequada do tamanho dessas janelas de análise.

Jain e Farrokhnia [75] apresentaram a técnica de filtragem multi-canal para segmentação de textura que usa um banco de filtros simétricos de Gabor para caracterizar os canais. É proposto um esquema sistemático de seleção de filtros, o qual é baseado na reconstrução da imagem original a partir de suas imagens filtradas.

Além dos em textura trabalhos acima citados, uma grande área onde se encontra uma grande quantidade de pesquisa é a área médica. Em seguida estão listados uma série de trabalhos nesta área envolvendo técnicas de textura em imagens.

Chang e Kuo [76] propuseram um método para o desenvolvimento da Transformada *Wavelet* baseada em árvore estruturada, para classificar um conjunto de dados a partir da análise espaço/frequência incluindo informações significantes de imagens médicas. Método esse que inspirou Sachin et al. [77] para classificar melanoma e nevo displástico. O modelo da árvore estruturada utiliza uma representação semântica da informação de frequência espacial contida em imagens de lesões da pele incluindo informações de textura. Nos resultados experimentais o método apresentado foi eficiente em discriminar melanoma a partir de nevo displástico.

Zouridakis et al. [78] apresentaram uma técnica de segmentação e classificação automáticas de imagens de lesões da pele. Para cada lesão da pele duas imagens foram obtidas, uma em cada duas diferentes modalidades de microscopia epiluminescence (ELM).

Sikorski [79] desenvolveu um método diferente para classificar melanoma benigno e maligno da pele. As características usadas para classificação são coletadas a partir da formação dos coeficientes pela decomposição *wavelet*. A média e variância dos coeficientes *wavelets* são calculadas e usadas em uma rede neural para classificação. O melhor resultado obtido foi de 83% entre lesões benignas e malignas. Os autores alertam que devem ser adicionados outros atributos como medidas de borda e assimetria para melhorar o desempenho da classificação.

O trabalho de Bauer et al [80] apresentou um modelo de rede neural para identificar e classificar lesões de pele benigna e maligna. As características ocultas na imagem são extraídas com análise de componentes independentes (ICA – *Independent Component*

Analysis). Esses componentes são usados para distinguir lesões benignas de câncer de pele. Como estudo comparativo fez-se a classificação usando PCA (*Principal Components Analysis*) e a rede neural SOM (*Self-Organizing Map*).

Ercal et al. [81] descreveram uma técnica para diagnosticar melanoma em imagens coloridas usando rede neural artificial. Para este propósito, um conjunto de características para distinguir melanoma de três outros tipos de tumores benignos foi definido e descritos métodos para medir estas características de *slides* coloridos digitalizados.

Marquez e Wang [82] examinam várias características de textura de imagens de lesões da pele obtidas usando imagens de reflexão espectroscópicas difusa. As características foram extraídas baseada na matriz de coocorrência, decomposição *wavelet*, assinatura fractal e aproximação granulométrica. Os autores concluem, baseados no banco de imagens estudado, que os resultados obtidos com as características de textura fractal e *wavelet* foram efetivos na separação de classes pré-cancerosas e benignas.

Chang e Kuo [83] propuseram uma aproximação de multiresolução baseada na Transformada *wavelet* de Árvore Estruturada para classificação de textura. O desenvolvimento do algoritmo é motivado pela observação que textura são sinais quaseperiódico cujas frequências dominantes estão localizadas no meio do canal de frequência. Os autores também desenvolveram um algoritmo de classificação de textura progressiva que não só é computacionalmente atraente mas também tem excelente desempenho. Os autores concluíram que a Transformada *Wavelet* pode ser aplicada efetivamente para imagens comuns cuja energia é concentrada na região de baixa frequência. Já a Transformada *Wavelet* de Árvore Estruturada é mais efetiva na análise de textura, desde que as imagens tenham componentes dominantes nas regiões de frequência espacial média.

Yuan et al. [84] desenvolveram um algoritmo para detecção precoce de melanoma usando máquina de vetor de suporte (SVM) baseado na classificação de textura. O algoritmo foi testado para o problema de classificação de textura, em uma referência binária com o *kernel* polinomial, baseado na análise de desempenho da SVM. O experimento utilizou 22 pares de imagens de lesões cutâneas. A média de precisão da classificação foi de 70%.

3.2. *Trabalhos de Textura em Imagens de Rochas*

Lepistö et al. [85] mostraram um método de classificação baseado nas características estrutural e espectral das rochas. Para extração de características que pudessem identificar a textura, foi considerado como aspecto espectral (Launeau et al.) [86] alguns parâmetros de cor e para definir o aspecto estrutural foram utilizadas matrizes de co-ocorrência. Para a tarefa de classificação das rochas as imagens de textura não homogêneas foram divididas em blocos. Já em Lepistö et al. [87], utilizou filtro de Gabor em imagens de rochas coloridas nos sistemas de cores RGB e HSI para a tarefa de classificação de rochas.

Autio et al. [88] utilizou matrizes de co-ocorrência, em conjunto com a transformada de Hough para classificação de rochas. Lepistö et al. [89] utilizaram morfologia e parâmetros de cor para distinguir as imagens de rochas.

As técnicas de programação genética, juntamente com detectores de borda (Starkey e Samantary) [90] foram utilizadas por Ross et al. [91] em imagens microscópicas na área de petrografia, para que fosse possível realizar a separação dos grãos dentro da imagem.

Ross et al. [92] utilizaram a técnica de programação genética, juntamente com árvores de decisão para a separação dos grãos na imagem.

Em Thompson et al. [93] foi utilizado redes neurais de três camadas para a classificação de minerais. Foram utilizados imagens coloridas de 10 classes de minerais diferentes. Fueten e Mason [94] utilizaram redes neurais para detecção de bordas em imagens coloridas de petrografia para segmentar os grãos.

3.3. *Características de Textura*

As três principais abordagens usadas no processamento de imagens para descrever a textura de uma região segundo Gonzales e Wintz [95] são: estatística, estrutural e espectral. A abordagem estatística considera a distribuição dos tons de cinza e o inter-relacionamento entre eles. As técnicas estruturais, por outro lado, lidam com o arranjo espacial de primitivas de imagens regulares. A abordagem espectral é baseada em propriedades de espectros de frequência, obtidos através de transformadas tais como a de Fourier e a de Wavelets.

Neste trabalho foi utilizado a abordagem estatística para extração das características de textura.

3.3.1. Abordagem Estatística

A abordagem estatística baseia-se na análise de imagens e extração de suas características através da relação entre os seus níveis de cinza. São utilizados 256 níveis de cinza para extrair medidas estatísticas da imagem tais como: média, variância, desvio padrão, energia e entropia.

São definidas três abordagens principais para a análise estatística de textura: padrões de frequência (Chen) [96], estatísticas de primeira ordem (Hsu) [97], (Irons e Petersen) [98] e de segunda ordem (Haralick et al.) [102].

A análise estatística de primeira ordem avalia a distribuição de níveis de cinza na imagem utilizando o histograma de primeira ordem como base para a extração de características. De modo geral, o método computa as probabilidades $P(i)$ de ocorrência para cada característica na imagem, onde; $i=0,1,2...C$, onde C é o número de características. Exemplos mais utilizados para as características são: média, variância, desvio padrão, simetria, achatamento, energia e entropia. Essa abordagem não leva em consideração uma informação muito importante que é a relação do pixel com a sua vizinhança, ou seja, a sua distribuição espacial.

Para exemplificar melhor esse problema, temos na Figura 3.1, duas janelas de pixels 2x2 de uma imagem. Elas possuem nitidamente características visuais completamente diferentes, porém para ambas janelas, obviamente, o mesmo histograma de primeira ordem será encontrado, podendo assim serem classificadas pelo vetor de características como uma região pertencente a mesma classe. Tal distinção já é possível pela análise estatística de segunda ordem.

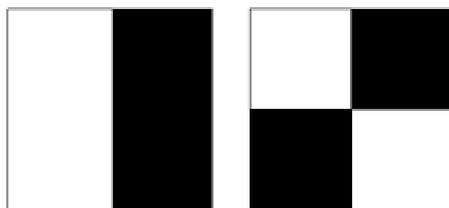


Figura 3.1 Exemplo de duas imagens diferentes que possuem o mesmo histograma de primeira ordem.

Outra forma possível de se fazer classificação de imagens é através da utilização do histograma diretamente. Desta forma, dado um histograma de uma amostra de imagem e de vários protótipos de comparação podemos classificar tal amostra como sendo de um dos protótipos simplesmente definindo alguma métrica que prove que tal amostragem está mais próxima deste ou daquele protótipo. Algumas métricas para comparação de histogramas podem ser: distância de *Minkowsky* Equação 3.1, *Chi-Square* Equação 3.2 e de *Bhattacharyya* Equação 3.3.

$$M = \sum_{i=0}^L |h_1[i] - h_2[i]|^f \quad \text{Equação 3.1}$$

Onde f é uma função a ser definida. Quando $f = 1$ temos a *Norma L1*, quando $f = 2$ temos a *Norma L2* também conhecida como distância Euclidiana.

$$\chi^2 = \sum_{i=0}^L \frac{(h_1[i] - h_2[i])^2}{h_1[i] + h_2[i]} \quad \text{Equação 3.2}$$

$$B = -\ln \sum_{i=0}^L \sqrt{h_1[i]h_2[i]} \quad \text{Equação 3.3}$$

Ainda de posse do histograma, pode-se obter um outro descrito de textura, denominado Momento de Histograma. O n-ésimo momento de um histograma pode ser calculado da seguinte forma:

$$\mu_n(z) = \sum_{i=1}^L (z_i - m)^n p(z_i)$$

$$m = \sum_{i=1}^L z_i p(z_i)$$

Equação 3.4

Existem basicamente três métodos que aplicam respectivamente a análise de estatísticas de segunda ordem, são eles: o Método de Dependência Espacial de Nível de Cinza – SGLDM (*Spatial Grey Level Dependence Level*), o Método da Diferença de Nível de Cinza - GLDM (*Grey Level Difference Method*) e o Método de Comprimento de Sequências de Níveis de Cinza – RLM (*Run Length Method*).

O método SGLDM calcula a probabilidade de ocorrer uma transição de nível de cinza entre dois pixels da imagem separados por uma dada orientação espacial. O método GLDM calcula a probabilidade de existência de uma dada diferença de nível de cinza entre dois pixels, separados por uma dada orientação espacial. Por fim, o método RLM calcula a probabilidade de existência de sequências de pixels idênticos, para um dado comprimento e, ao longo de uma dada orientação.

Os métodos acima foram comparados (Conners e Harlow) [99] em termos de eficiência para avaliar um conjunto de texturas. O resultado encontrado foi que o método

SGLDM é o que melhor caracteriza as texturas. Este método é também conhecido como Método das Matrizes de Co-ocorrência – GLCM (*Grey Level Co-Occurrence Matrix*).

A abordagem estatística tem sido a mais amplamente utilizada [100], gerando resultados satisfatórios com um custo computacional reduzido.

3.3.1.1. Matriz de Co-ocorrência

A estatística de segunda ordem é calculada pela probabilidade de um determinado par de níveis de cinza i e j , numa determinada distância δ e uma direção θ ocorrer, ou seja, a matriz de co-ocorrência pode ser denominada como sendo um histograma bidimensional que fornece a frequência de ocorrência $P(i, j, \delta, \theta)$.

A relação entre o par de níveis de cinza i e j é feita em quatro direções de θ : 0, 45, 90 e 135 graus a partir do pixel central X em relação aos seus oito vizinhos conforme observado na Figura 3.2.

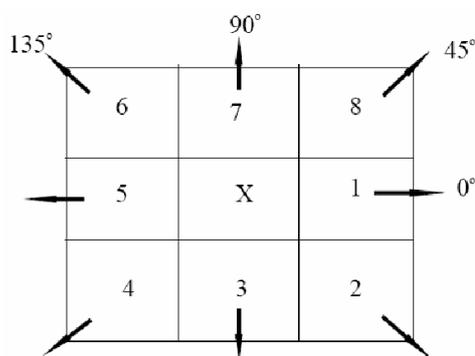


Figura 3.2 As quatro direções de θ : 0, 45, 90 e 135 graus a partir do pixel central X.

As distâncias são escolhidas de acordo com a granularidade das imagens manipuladas. A Figura 3.3 [101] mostra as direções de 0° , 45° , 90° e 135° para as distâncias $\delta=1$ e $\delta=2$.

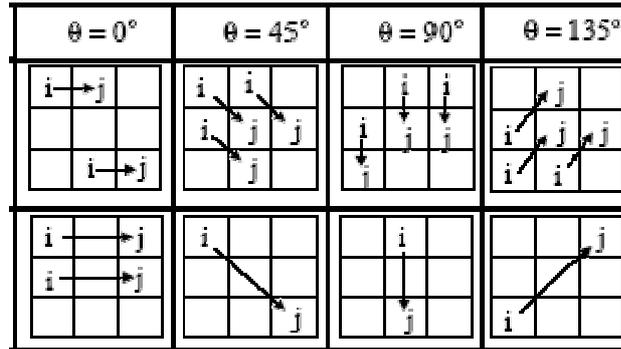


Figura 3.3 Diferentes combinações de e ângulos para distâncias $\delta = 1$ e $\delta = 2$ que podem ser usadas para construir as matrizes de co-ocorrência [101].

A matriz é formada por N_c linhas e N_c colunas, onde N_c é o número de níveis de cinza presente na imagem. A matriz é ordenada da menor nível de cinza até o maior tanto na linha como na coluna, ou seja, a posição $(0,0)$ da matriz corresponde à relação do nível de cinza 0 com ele mesmo. Portanto cada posição da matriz guarda a probabilidade de ocorrência $P(i, j, \delta, \theta)$ em relação a cor da linha i com a cor da coluna j .

Para cada direção e cada distância, gera-se uma matriz de co-ocorrência. Os índices das linhas e colunas representam os diferentes valores de níveis de cinza. Computando-se então a frequência com que os mesmos ocorrem dois a dois em uma certa direção e a uma certa distância. Como exemplo, suponhamos a imagem representada pela sua matriz de pontos da Figura 3.4.a. Para a direção de 0° e a distância 1, teremos a matriz de co-ocorrência mostrada na Figura 3.4.b.

| | | | | |
|---|---|---|---|---|
| 0 | 0 | 0 | 1 | 2 |
| 1 | 1 | 0 | 1 | 1 |
| 2 | 2 | 1 | 0 | 0 |
| 1 | 1 | 0 | 2 | 0 |
| 0 | 0 | 1 | 0 | 1 |

| | | |
|---|---|---|
| 8 | 8 | 2 |
| 8 | 6 | 2 |
| 2 | 2 | 2 |

(a)
(b)

Figura 3.4 (a) Uma imagem com 3 níveis de cinza, $z_1=0$, $z_2=1$ e $z_3=2$. (b) Matriz de co-ocorrência P da imagem, na direção 0° e distância 1. O valor $P(i, j)$ armazenado em uma linha i na coluna j consiste no número de vezes em que pixels de valor i possuem vizinho de valor j à esquerda ou à direita e a uma distância de 1 pixel.

Haralick demonstra que esses quatro direcionamentos, 0° , 45° , 90° e 135° , dão origem a quatro matrizes de co-ocorrência diferentes que devem ser combinadas através de uma média entre elas para formar a matriz final de co-ocorrência.

Generalizando, seja uma imagem I regular com N pixels na direção horizontal e M pixels na direção vertical, quantizada em G níveis de cinza. A imagem I pode ser representada como uma matriz $G \times G$ onde cada elemento é a função que designa a probabilidade de ocorrência simultânea de dois níveis de cinza $i, j = 0 \dots G-1$ para pares de pixels nas direções e distâncias especificadas. A informação textural é caracterizada pela matriz de frequência relativa $P(i, j, \delta, \theta)$, que indica a probabilidade de ocorrerem dois pixels, um com nível de cinza i e outro com j , separados pela distância δ e por uma relação angular θ na imagem [103].

A normalização de cada uma dessas matrizes de co-ocorrência é obtida dividindo-se cada elemento da matriz pelo número de pares de pontos na imagem que satisfaça $P(\delta, \theta)$. Dessa forma é possível obter a matriz final de probabilidades. A normalização é feita diferentemente para cada ângulo θ em questão, a constante de normalização N é calculada a seguir da seguinte forma:

$$N | \delta, 0^\circ = 2 * (N_c - 1) * N_c \quad \text{Equação 3.5}$$

$$N | \delta, 45^\circ = 2 * (N_c - 1) * (N_c - 1) \quad \text{Equação 3.6}$$

$$N | \delta, 90^\circ = 2 * N_c * (N_c - 1) \quad \text{Equação 3.7}$$

$$N | \delta, 135^\circ = 2 * (N_c - 1) * (N_c - 1) \quad \text{Equação 3.8}$$

A matriz de probabilidades final será então:

$$P(i, j, \delta, \theta) = M(i, j, \delta, \theta) / N | \delta, \theta \quad \text{Equação 3.9}$$

É importante salientar que o tamanho da matriz de co-ocorrência depende do número de tons de cinza da imagem. As matrizes de co-ocorrência sozinhas não caracterizam as texturas, é necessário a extração de algumas medidas, no intuito de identificar e classificar algum tipo de textura.

De forma geral, o problema consiste em analisar um conjunto de matrizes de co-ocorrência para se caracterizar a textura à qual elas se referem, utilizando-se um ou mais descritores. [102] propôs um conjunto de 14 descritores. A Tabela 3.1 [103] mostra os mais utilizados.

Normalmente, a escolha dos descritores a serem adotados baseia-se em testes empíricos sobre um domínio específico, verificando-se quais deles produzem resultados mais satisfatórios.

Tabela 3.1 Descritores de textura baseados na matrizes de co-ocorrência

| Característica | Descrição | Fórmula Matemática |
|--|---|---|
| Homogeneidade | Como o próprio nome sugere, mede a homogeneidade da imagem, ou seja, a distribuição de pixels na imagem. Retorna um valor que representa a proximidade da distribuição dos elementos em relação à diagonal da matriz de co-ocorrência dos tons de cinza. Faixa de valores possíveis: 0 a 1. Um valor de homogeneidade 1 representa uma matriz diagonal de co-ocorrência de tons de cinza. | $\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \frac{1}{1+ i-j } P(i, j, d, \theta)$ |
| Energia, uniformidade ou segundo momento angular | Avalia a uniformidade textural em uma imagem. Retorna a soma dos elementos elevados ao quadrado dentro da matriz de co-ocorrência de tons de cinza. Faixa de valores possíveis: 0 a 1. A energia possui valor 1 para uma imagem constante (mesmo tom de cinza em toda a sua extensão). | $\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} [P(i, j, d, \theta)]^2$ |
| Correlação | Retorna uma medida de quão correlacionado está um pixel com o seu vizinho. A comparação é realizada em todos os pixels da imagem. Faixa de valores possíveis: -1 a 1. A correlação é 1 para uma imagem totalmente correlacionada ou -1 para uma completamente descorrelacionada. | $\frac{1}{\sigma_x \sigma_y} \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} ijP(i, j, d, \theta) - \mu_x \mu_y$ <p>sendo:</p> $\mu_x = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} iP(i, j, d, \theta)$ $\mu_y = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} jP(i, j, d, \theta)$ $\sigma_x = \sqrt{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} i^2 P(i, j, d, \theta) - \mu_x^2}$ $\sigma_y = \sqrt{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} j^2 P(i, j, d, \theta) - \mu_y^2}$ <p>onde μ_x e μ_y representam as médias nas direções x e y, respectivamente e σ_x e σ_y representam os desvios padrão.</p> |
| Probabilidade máxima | Indica a direção mais importante da textura a ser examinada. É simplesmente o maior valor da matriz de co-ocorrência. | $\max_{i,j} P(i, j, d, \theta)$ |

| | | |
|--|---|--|
| Variância ou contraste | O contraste, ou variância, mede a presença de transição abrupta de níveis de cinza (bordas) na imagem, ou seja, retorna uma medida do contraste entre as intensidades de um pixel analisado e do pixel vizinho. A comparação é realizada em todos os pixels da imagem. Para uma imagem constante (mesmo tom de cinza em toda a extensão), o contraste é 0. O contraste da imagem corresponde ao momento de ordem 2. | $\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i-j)^2 P(i, j, d, \theta)$ |
| Variância inversa | Inverso do contraste. | $\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \frac{P(i, j, d, \theta)}{(i-j)^2}, i \neq j$ |
| Entropia | A entropia mede a desordem em uma imagem, ou seja, o grau de dispersão de níveis de cinza. | $\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} P(i, j, d, \theta) \log_2 [P(i, j, d, \theta)]$ |
| Momento de diferenças de ordem k | Distorção da imagem. Este descritor apresenta valores pequenos se p tiver valores maiores na diagonal principal. | $\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i-j)^k P(i, j, d, \theta)$ |
| Momento inverso de diferenças de ordem k | Inverso do contraste. Este descritor apresenta valores maiores se p tiver valores pequenos na diagonal principal. | $\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \frac{P(i, j, d, \theta)}{(i-j)^k}$ |

Vários trabalhos têm utilizado a abordagem estatística com resultados satisfatórios. Especificamente em imagens médicas, verifica-se uma concentração de pesquisas no estudo de mamografias, as quais também têm gerado bons resultados. Em [104] encontra-se um levantamento abrangente desses trabalhos.

As matrizes de co-ocorrência são uma poderosa ferramenta na classificação de imagens, pois elas carregam informação sobre a posição relativa dos pixels em relação uns aos outros. No entanto, elas são de custo muito alto para a computação. Para uma imagem

de 256 tons de cinza, por exemplo, a matriz de co-ocorrência é composta por $256 \times 256 = 65536$ elementos.

3.3.1.2. Histogramas de somas e diferenças

O histograma de uma imagem digital, representa, para cada nível de intensidade (cinza), o número de *pixels* com aquele nível. O histograma indica se a imagem está distribuída adequadamente dentro dos possíveis níveis. De forma geral, o histograma H pode ser definido como:

$$H_g(k) = \frac{n.k}{M.N} \quad \text{Equação 3.10}$$

onde $n.k$ é o número de vezes que o *pixel* k aparece na imagem e M e N são as dimensões da imagem.

O histograma pode ser muito útil na classificação de imagens uma vez que ele representa uma função de distribuição de probabilidades. De acordo com [105], [106] pode-se utilizar o histograma das somas e diferenças de uma dada amostragem para descrever texturas ao invés da tradicional utilização de matrizes de co-ocorrência. Os ganhos computacionais são relevantes. Para imagens com 256 tons de cinza, o vetor diferença possui valores possíveis de tons entre -255 a 255 e o vetor soma valores entre 0 e 510. Defina-se I como a imagem sendo analisada, h_s como sendo o histograma das somas e h_d

como sendo o histograma das diferenças. Desta forma, temos cada tom do histograma definido por:

$$hs[I(i, j) + I(i + t_1, j + t_2)] = hs[I(i, j) - I(i + t_1, j + t_2)] + 1 \quad \text{Equação 3.11}$$

$$hd[I(i, j) - I(i + t_1, j + t_2)] = hd[I(i, j) + I(i + t_1, j + t_2)] + 1 \quad \text{Equação 3.12}$$

Onde (t_1, t_2) representa o vetor direção no espaço Z^2 que está sendo levado em consideração. A primitiva $I(i, j)$ acessa o pixel localizado na linha i e na coluna j da imagem. Para que os histogramas gerados expressem probabilidades, é necessário normalizá-los no final do processo.

Com o objetivo de ilustrar a construção dos histogramas, sejam $t_1 = 1$ e $t_2 = 0$ o vetor direção aplicado na Figura 3.5. Os histogramas soma e diferença para essa imagem são apresentados na Figura 3.6.

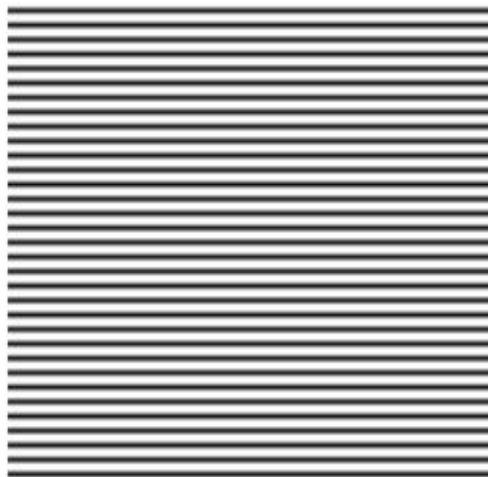


Figura 3.5 Imagem de listras horizontais [103].

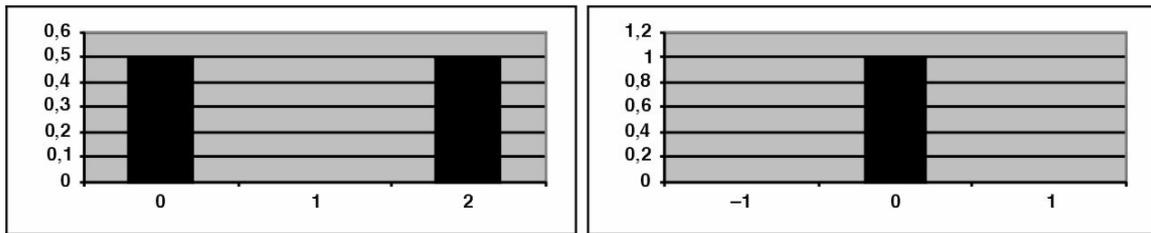


Figura 3.6 Histogramas somas e diferenças da Figura 3.5 para $t_1 = 1$ e $t_2 = 0$ [103].

Como já foi mencionando anteriormente, a classificação correta de qualquer textura depende muito dos descritores utilizados para caracterizá-la da melhor forma possível. Na

Tabela 3.2 estão listados os descritores: média, contraste, homogeneidade, energia, variância, correlação e entropia.

Tabela 3.2 Descritores de textura baseados nos histogramas de somas e diferenças

| Característica | Fórmula Matemática |
|----------------|--|
| Média | $\mu = \sum_{i=0}^{2+(L-1)} h_s[z]$ |
| Contraste | $C = \sum_{j=-L}^L j^2 h_d[j]$ |
| Homogeneidade | $H = \sum_{j=-L}^L \frac{1}{1+j^2} h_d[j]$ |

| | |
|------------|---|
| Energia | $En = \sum_{i=0}^{2L-1} hs[i] \sum_{j=-(L-1)}^{L-1} hd[j]$ |
| Variância | $\sigma^2 = \frac{1}{2} \sum_{i=0}^{2L-1} (i - 2\mu)^2 hs[i] + \sum_{j=-(L-1)}^{L-1} j^2 hd[j]$ |
| Correlação | $Cr = \frac{1}{2} \sum_{i=0}^{2L-1} (i - 2\mu)^2 hs[i] - \sum_{j=-(L-1)}^{L-1} j^2 hd[j]$ |
| Entropia | $Et = - \sum_{i=0}^{2L-1} hs[i] \log hs[i] - \sum_{j=-(L-1)}^{L-1} hd[j] \log(hd[j])$ |

3.3.1.3. Métodos de Autocorrelação

A função de autocorrelação de uma imagem pode ser utilizada para detectar padrões repetitivos nos elementos de uma textura. Quanto maior for o valor do coeficiente de correlação, mais forte é a associação entre as variáveis. A autocorrelação $\rho(dr, dc)$ de uma imagem I de tamanho $N + 1 \times N + 1$ deslocadas em linhas e colunas por (dr, dc) é dada por[103]:

$$\rho(dr, dc) = \frac{\sum_{r=0}^N \sum_{c=0}^N I(r, c) I(r + dr, c + dc)}{\sum_{r=0}^N \sum_{c=0}^N I^2(r, c)} = \frac{I(r, c) I_d(r, c)}{I(r, c) I(r, c)} \quad \text{Equação 3.13}$$

Em outras palavras, a função de autocorrelação da imagem representa a correlação de uma imagem com versões dela mesma, ou seja, faz o produto escalar de uma imagem por ela mesma deslocando-a horizontalmente. O vetor resultante da autocorrelação preserva as características espectrais da janela ou sub imagem, descartando, porém, a informação de fase. A Figura 3.7 mostra a autocorrelação horizontal e vertical da imagem de listras representada pela Figura 3.5.

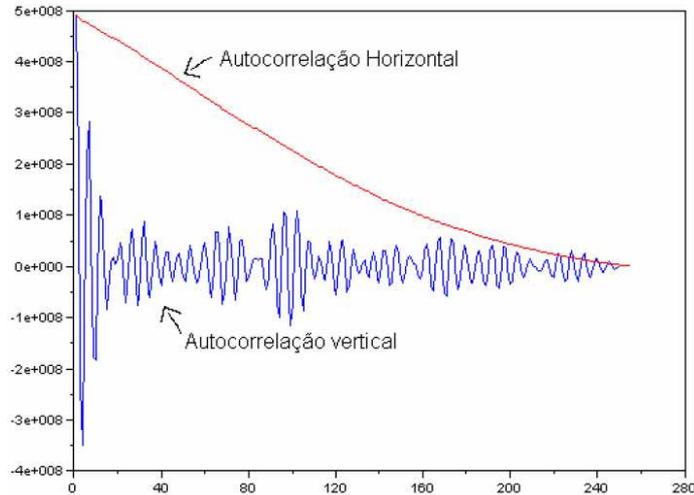


Figura 3.7 Autocorrelação vertical e horizontal da Figura 3.5.

3.3.1.4. Coeficiente de Variação Espacial

O coeficiente de variação espacial quantifica a característica de textura por meio de medidas estatísticas que descrevem as variações espaciais de intensidade ou cor. Duas medidas dos pixels pertencentes à região da imagem são empregadas: uma medida de posição (média) e uma medida de dispersão (desvio padrão) [107], [103].

As medidas de posição constituem uma forma mais sintética de apresentar os resultados contidos nos dados observados, pois representam um valor central, em torno do qual os dados se concentram. Mas, a utilização de uma medida de posição para substituir um conjunto de dados é insuficiente para sintetizar a informação nele contida, portanto, para sintetizarmos eficientemente a informação de um conjunto de dados, é necessário associar uma medida de posição a uma medida de dispersão, que vai informar como esses dados se comportam em torno da medida de posição empregada.

Para obter um único número que represente a dispersão dos dados, pode-se usar a variância ou o desvio padrão, que é uma medida quantitativa da dispersão de um conjunto de dados ao redor da sua média. Sendo a variância calculada a partir dos quadrados dos desvios, sua unidade é o quadrado da unidade da variável em análise, o que sob o ponto de vista prático é inconveniente. O desvio padrão, definido na Equação 3.14, evita esse inconveniente, pois é definido como a raiz quadrada da variância.

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}$$

Equação 3.14

Como já foi visto anteriormente, as avaliações de textura calculadas apenas com base em seu histograma sofrem a limitação por não carregarem informação sobre a posição de uns pixels em relação aos outros. Isso porque a textura além da tonalidade dos pixels se caracteriza pelos relacionamentos espaciais entre eles [95]. Assim, o CVE leva em consideração não apenas a distribuição de intensidades, mas também sua distribuição espacial por meio do uso das classes de distâncias.

O cálculo do CVE inicia com a definição de um conjunto de amostras de treinamento para cada região de interesse. Essas amostras são extraídas da imagem, através de janelas de tamanho $M \times M$ (3×3 , 5×5 , ..., 21×21), definido pelo usuário. Para cada amostra de tamanho $M \times M$, determina-se o conjunto de intensidades dos pixels por classe de distância e por canal considerado.

Para caracterizar melhor a dispersão dos dados em termos relativos ao seu valor médio, utiliza-se o conceito de coeficiente de variação dado pela Equação 3.15.

$$CV = \frac{\sigma}{x} . 100 \quad \text{Equação 3.15}$$

Após obter a média e o coeficiente de variação para cada classe de distância, as medidas de posição e dispersão são combinadas através da Equação 3.16, cujo valor único (CVE da classe) preserva a informação de ambas as medidas obtidas.

$$CVE = \frac{\arctg\left(\frac{\bar{x}}{CV}\right)\pi}{180} \sqrt{\bar{x} + CV^2} \quad \text{Equação 3.16}$$

No caso de imagens coloridas, deve-se obter a média e o coeficiente de variação para os CVE de cada classe de distâncias relativas. Finalmente, a média e o coeficiente de variação dos CVE de cada classe são novamente combinados pela Equação 3.16, para cada banda (R, G, B), resultando no CVE da região colorida de textura. Maiores detalhes podem ser encontrados em [103] e [107].

3.3.1.5. Coeficiente de Hurst

O coeficiente de Hurst é utilizado por alguns autores como sendo uma aproximação da dimensão fractal para imagens em tons de cinza [108]. Sua utilização para caracterização de texturas permite associar um valor, a dimensão fractal, para posterior identificação e classificação com grande simplicidade e eficiência. A Equação 3.17 define o coeficiente de Hurst. A intensidade de um conjunto de pixels de uma imagem I dividida em N partes idênticas não coincidentes e escalonada por um fator de escala r , é usada na Equação 3.17.

$$D = \frac{\ln N}{\ln\left(\frac{1}{r}\right)} \quad \text{Equação 3.17}$$

A exemplifica o cálculo do coeficiente de Hurst, para uma Imagem em tons de cinza de tamanho 7 x 7 pixels.

| | 0 | 1 | 2 | 3 | 4 | 5 | 6 |
|---|-----|----|-----|-----|----|-----|-----|
| 0 | 85 | 70 | 86 | 92 | 60 | 102 | 202 |
| 1 | 91 | 81 | 98 | 113 | 86 | 119 | 189 |
| 2 | 96 | 86 | 102 | 107 | 74 | 107 | 194 |
| 3 | 101 | 91 | 113 | 107 | 83 | 118 | 198 |
| 4 | 99 | 68 | 107 | 107 | 76 | 118 | 194 |
| 5 | 107 | 94 | 93 | 115 | 83 | 115 | 198 |
| 6 | 94 | 98 | 98 | 107 | 81 | 115 | 194 |

Figura 3.8 Imagem de tamanho 7x7 pixles para cálculo do coeficiente de Hurst[108].

A Figura 3.9 representa a distância euclidiana da cada pixel (x_i, y_i) em relação ao pixel central (x_c, y_c) , calculada por meio da equação:

$$d(x_c, y_c; x_i, y_i) = \sqrt{(x_c - x_i)^2 + (y_c - y_i)^2} \quad \text{Equação 3.18}$$

Para esse texton 7x7, existem oito grupos de pixels, correspondendo às oito diferentes distâncias possíveis Figura 3.9.

| | | | | | | |
|-------------|-------------|-------------|---|-------------|-------------|-------------|
| $\sqrt{18}$ | $\sqrt{13}$ | $\sqrt{10}$ | 3 | $\sqrt{10}$ | $\sqrt{13}$ | $\sqrt{18}$ |
| $\sqrt{13}$ | $\sqrt{8}$ | $\sqrt{5}$ | 2 | $\sqrt{5}$ | $\sqrt{8}$ | $\sqrt{13}$ |
| $\sqrt{10}$ | $\sqrt{5}$ | $\sqrt{2}$ | 1 | $\sqrt{2}$ | $\sqrt{5}$ | $\sqrt{10}$ |
| 3 | 2 | 1 | 0 | 1 | 2 | 3 |
| $\sqrt{10}$ | $\sqrt{5}$ | $\sqrt{2}$ | 1 | $\sqrt{2}$ | $\sqrt{5}$ | $\sqrt{10}$ |
| $\sqrt{13}$ | $\sqrt{8}$ | $\sqrt{5}$ | 2 | $\sqrt{5}$ | $\sqrt{8}$ | $\sqrt{13}$ |
| $\sqrt{18}$ | $\sqrt{13}$ | $\sqrt{10}$ | 3 | $\sqrt{10}$ | $\sqrt{13}$ | $\sqrt{18}$ |

Figura 3.9 Oito grupos de pixels correspondentes às distâncias[103].

O primeiro passo no cálculo do coeficiente de Hurst é determinar a maior diferença de nível de cinza (Δg) para cada classe de distância dos pixels. A maior diferença será obtida depois da busca do maior e do menor tom da região. Neste exemplo, começando com os pixels com distância de um pixel do centro, o nível de cinza máximo é 113 e o mínimo é 83, ocorrendo uma diferença de 30. A próxima classe (distância = $\sqrt{2}$) tem o nível mínimo de 74, permanecendo o nível máximo em 113; portanto a maior diferença será igual a 39. A terceira classe (distância = 2) possui nível máximo igual a 118 e nível mínimo permanecendo em 74; logo a maior diferença de nível de intensidade é igual a 44. Esse processo deve ser realizado sucessivamente para todas as classes de distâncias. Em seguida, deve-se obter o logaritmo das distâncias e das diferenças de nível de cinza. De posse desses dados, é possível plotar os pontos definidos pelo logaritmo das distâncias e pelo logaritmo das diferenças de nível em um gráfico de Richardson [103].

O passo final consiste em realizar o ajuste da reta ($y=bx+a$) definida pelos pontos de coordenadas $(\ln d; \ln \Delta g)$. Através do método dos mínimos quadrados calculam-se os parâmetros b e a da reta que minimiza as distâncias ou diferenças entre y e y' . Esta reta pode ser entendida como uma regressão linear.

3.3.1.6. Entropia da Imagem

A entropia de uma imagem pode ser definida como uma característica de textura que mede a sua aleatoriedade, ou seja, quanto maior for este número, mais irregular, atípica ou não padronizada será a imagem analisada. O cálculo da entropia de uma textura é dada pela Equação 3.19.

$$E = \sum_{i=0}^{M-1} \left(p_i \log_2 \left(\frac{1}{p_i} \right) \right) \quad \text{Equação 3.19}$$

onde M é o número total de texturas diferentes presentes na imagem e p_i é a probabilidade de que a i -ésima textura armazenada seja utilizada novamente.

3.4. *Resumo*

Neste capítulo foram apresentadas as principais técnicas estatísticas utilizadas para descrever textura, tais como métodos com histograma, matriz de co-ocorrência, autocorrelção, e coeficiente de variação espacial. Apesar da existência de vários métodos, não existe um eficiente para todos os tipos de textura.

O próximo capítulo faz uma abordagem dos principais métodos de classificação de padrões.

Capítulo 4

Sistemas de Classificação de Padrões

4.1. *Introdução*

Na tarefa de classificação de padrões cada registro ou tupla de uma base de dados pertence a uma classe entre um conjunto pré-definido de classes. A classe de uma tupla é indicada por um valor especificado pelo usuário em um atributo meta ou atributo objetivo. As tuplas consistem de atributos preditivos e um atributo objetivo, esse último indicando a que classe essa tupla pertence.

O princípio da tarefa de classificação é descobrir algum tipo de relacionamento entre os atributos preditivos e o atributo objetivo, de modo a descobrir um conhecimento que possa ser utilizado para prever a classe de uma tupla desconhecida, ou seja, que ainda não possui nenhuma classe definida.

A maioria dos problemas de classificação de padrões de interesse real possui duas fases distintas. A primeira, em geral chamada de *in sample* ou de treinamento (aprendizado), é executada a partir do banco de dados existentes. A segunda fase, conhecida como *out sample* ou generalização, é executada para os dados que não foram utilizados no treinamento. Esta segunda fase permite a avaliação com os dados ‘novos’, do modelo produzido (explicitamente ou não) na primeira fase. O que se deseja, fundamentalmente, é extrair as características gerais do ambiente, para posteriormente utilizá-las na tomada de decisão em dados novos, ainda não vistos pelo sistema.

Diversas condições são necessárias para que a fase de generalização seja bem sucedida. Entre as mais importantes estão a escolha adequada das características e a existência de um banco de dados representativo do ambiente. Evidentemente, o sistema só estará em condições de uso quando a sua capacidade de generalização for devidamente testada. Na prática reserva-se, em geral, uma pequena parte dos dados disponíveis para que seja possível testar de modo independente o desempenho *out of sample* do sistema.

O conhecimento da base de dados pode ser extraído utilizando-se um algoritmo de classificação para analisar os dados. O princípio da tarefa de classificação é descobrir algum tipo de conhecimento que possa ser utilizado para prever a classe de um padrão desconhecido [5]. O conhecimento descoberto é freqüentemente representado na forma de regras **SE-ENTÃO**. Essas regras são interpretadas da seguinte maneira: “**SE** as características que descrevem um determinado padrão satisfazem as condições do antecedente da regra, **ENTÃO** o padrão tem a classe indicada no conseqüente da regra”.

Mais informações sobre a tarefa de classificação de padrões podem ser encontradas em [109], [110], [111] e [112].

4.2. *Métodos de Classificação de Padrões*

Existem inúmeras técnicas [113], [114], [115], [116], [117], [118] e [119] para utilização em aplicações de classificação de padrões, dentre as quais podemos destacar: métodos estatísticos, árvores de decisão, redes neurais, sistemas fuzzy e os sistemas híbridos que combinam mais de um método, assim como os sistemas neuro-fuzzy.

Cada tipo de técnica tem suas próprias características, apresentando vantagens e desvantagens. Nas próximas seções serão apresentadas, de forma sucinta, algumas dessas técnicas, para aplicações de classificação de padrões e em alguns casos extração de regras que explicam a classificação.

4.2.1. *Árvores de Decisão*

Uma árvore de decisão é uma estrutura ramificada onde cada nó interno é rotulado com um dos atributos preditivos. Cada seta que sai do nó interno é rotulado com valores dos atributos de cada nó, e todo nó folha é rotulado com uma classe (valor do atributo objetivo).

A Figura 4.1 possui um exemplo de uma árvore de decisão para a base de dados mostrada na Tabela 4.1 [120], e a Figura 4.2 mostra a base de regras de classificação descobertas da árvore de decisão da Figura 4.1. Cada caminho da árvore pode ser convertido numa regra. O nó interno e os valores das setas são convertidos no antecedente da regra (SE). Já o nó folha é convertido no conseqüente da regra (ENTÃO). Uma árvore de decisão classifica uma nova tupla de maneira *top-down*. Inicialmente a nova tupla é

passada para o nó raiz da árvore, o qual testa que valor a tupla tem no atributo rotulado no nó. Depois a tupla é testada nos nós inferiores seguindo o caminho das setas em função do valor da tupla no atributo rotulado no nó corrente. Esse processo é recursivamente repetido até que a tupla chegue à folha.

Tabela 4.1 Base de dados com os atributos preditivos: sexo, país e idade e com o atributo objetivo denominado comprar.

| SEXO | PAÍS | IDADE | COMPRAR |
|-----------|------------|-------|---------|
| masculino | França | 25 | Sim |
| masculino | Inglaterra | 21 | Sim |
| feminino | França | 23 | Sim |
| feminino | Inglaterra | 34 | Sim |
| feminino | França | 30 | Não |
| masculino | Alemanha | 21 | Não |
| masculino | Alemanha | 20 | Não |
| feminino | Alemanha | 18 | Não |
| feminino | França | 34 | Não |
| masculino | França | 55 | Não |

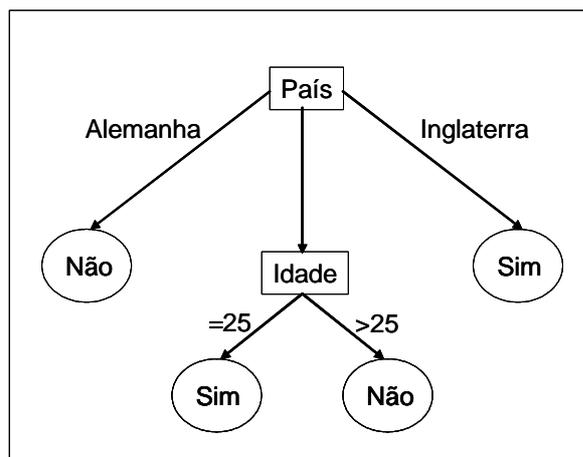


Figura 4.1 Árvore de decisão obtida com os dados da Tabela 4.1.

| |
|--|
| Se (PAÍS = Alemanha) então COMPRAR = Não |
| Se (PAÍS = Inglaterra) então COMPRAR = Sim |
| Se (PAÍS = França e IDADE \leq 25) então COMPRAR = Sim |
| Se (PAÍS = França e IDADE $>$ 25) então COMPRAR = Não |

Figura 4.2 Regras de Classificação obtidas através da árvore de decisão da Figura 4.1.

A tupla < “masculino”, “França”, “23”, “?” > identifica um cliente. A “?” representa o valor a que o atributo objetivo, nesse exemplo, o atributo COMPRAR, deverá ter. Esse atributo informa se o cliente irá ou não comprar. Ao percorrer essa tupla na árvore da Figura 4.1, pode-se classificá-la como “sim” no atributo COMPRAR. O nó raiz da árvore representa o atributo PAÍS, onde a tupla consta “França”, direcionando então a classificação para o nó representando o atributo IDADE. Verificando a tupla, esse atributo possui o valor “23”, que é menor ou igual a 25, novamente o algoritmo direciona a classificação do atributo COMPRAR, sendo que dessa vez para o nó folha rotulado por “Sim”.

Uma árvore de decisão é geralmente construída de maneira *top-down*, utilizando um algoritmo baseado na aproximação “dividir para conquistar” [121]. O algoritmo ID3, desenvolvido em 1983 por Ross Quinlan, da Universidade de Sydney, Austrália, deu origem às árvores de decisão. O ID3 e suas evoluções (ID4, ID6, C4.5, C5.0) [122] [121] converteram-se numa das metodologias mais comuns nas tarefas de descoberta de conhecimento. Recentemente, tem sido propostas novas abordagens para utilização de árvores de decisão fuzzy [123], [124], [125] em tarefas de classificação e descoberta de conhecimento. A seguir serão apresentados os algoritmos de árvore de decisão fuzzy mais utilizados.

ID3 e C4.5 [122] [121]: são os algoritmos mais populares, desenvolvidos por Quinlan, para tarefas de classificação. O algoritmo ID3 gera uma árvore de decisão a partir de informações contidas na base de dados, começando pelo atributo mais relevante do ponto de vista da informação contida nele, e continuando com os atributos seguintes segundo a avaliação da entropia de cada atributo. O algoritmo ID3 não trabalha com atributos de tipo contínuo, mas sucessivas atualizações do algoritmo adaptaram-se para lidar com este tipo de atributos, como o algoritmo C4.5 [121]. Este algoritmo introduz algumas modificações para lidar com atributos contínuos e valores desconhecidos.

CART [126], [127]: O algoritmo CART (*Classification And Regression Trees*), gera uma árvore de decisão realizando de forma recursiva subdivisões binárias na base de dados de treinamento. As subdivisões podem ser feitas sobre variáveis individuais (classificação) ou sobre uma combinação destas variáveis (regressão). A construção de uma árvore CART é realizada a partir dos exemplos contidos na base de treinamento. O algoritmo CART pode lidar com bases de dados incompletas, diferentes formatos numéricos (inteiro, flutuante,...) e atributos contínuos ou divididos em classes (a,b,c,...). O algoritmo CART gera uma estrutura de árvore binária da qual podem ser extraídas regras que são facilmente interpretáveis.

FID3.1 [128]: O algoritmo FID3.1 constrói árvores de decisão fuzzy [123], [124] e [125]. As árvores de decisão fuzzy estão ultimamente sob intensa pesquisa devido aos bons resultados obtidos nas tarefas de classificação de padrões. As árvores fuzzy fornecem uma melhor generalização do que as obtidas mediante as árvores ‘*crisp*’.

As duas principais diferenças entre as árvores de decisão tradicionais ‘*crisp*’ e as árvores de decisão fuzzy segundo são:

- O particionamento baseado em critérios fuzzy (distribuição dos padrões nas partições sem descontinuidades);
- A inferência das regras obtidas (Se x_1 é baixo e x_2 é médio então...).

O algoritmo FID3.1 realiza automaticamente o particionamento do espaço construindo as partições fuzzy. O FID3.1 pode lidar com atributos descritos em diferentes formatos (contínuos, discretos, fuzzy,...), tanto nos atributos não categóricos (Idade, Peso,...) quanto nos atributos categóricos (classe alta, classe média, classe baixa,...).

O algoritmo FID3.1 demonstrou um melhor desempenho que os algoritmos ID3 e C4.5 em aplicações “*benchmark*” utilizando as bases de dados *Íris Dataset*, *Bupa Liver Disorders* e *Pima Indians Diabetes Database* [128].]

4.2.2. Redes Neurais

Uma rede neural é uma técnica computacional que constrói um modelo matemático, emulado por computador, de um sistema neural biológico simplificado, com capacidade de aprendizado, generalização, associação, classificação, etc. As redes neurais tentam “aprender” as características de padrões através de um processo de repetidas apresentações dos dados à rede. Dessa forma, uma rede neural procura por relacionamentos, constrói modelos de forma automática e os corrige de modo a minimizar seu erro.

O cérebro humano pode ser visto como um processador de informações altamente complexo, não-linear e paralelo [129]. Por causa dessa capacidade de aprendizado e generalização o funcionamento dos neurônios tem sido estudado e com o objetivo de reproduzi-los em ambientes computacionais.

O neurônio artificial é uma unidade de processamento de informação fundamental para a operação das chamadas Redes Neurais.

O modelo de um neurônio artificial é apresentado na Figura 4.3. O neurônio artificial consiste de m entradas ponderadas pelos pesos $w_{k1..m}$ e então somadas numa junção aditiva. Esses pesos são conhecidos como pesos sinápticos e são responsáveis pela capacidade de modelar e aprender de uma rede neural. Uma função de ativação é colocada em seguida ao somador, essa função é dita como restritiva segundo [129], o que em linhas gerais significa que ela limita o intervalo permissivo de saída do neurônio a que se referencia. O modelo prevê ainda um ajuste denominado *bias* que tem o efeito de aumentar ou diminuir o valor aplicado à função de ativação [129].

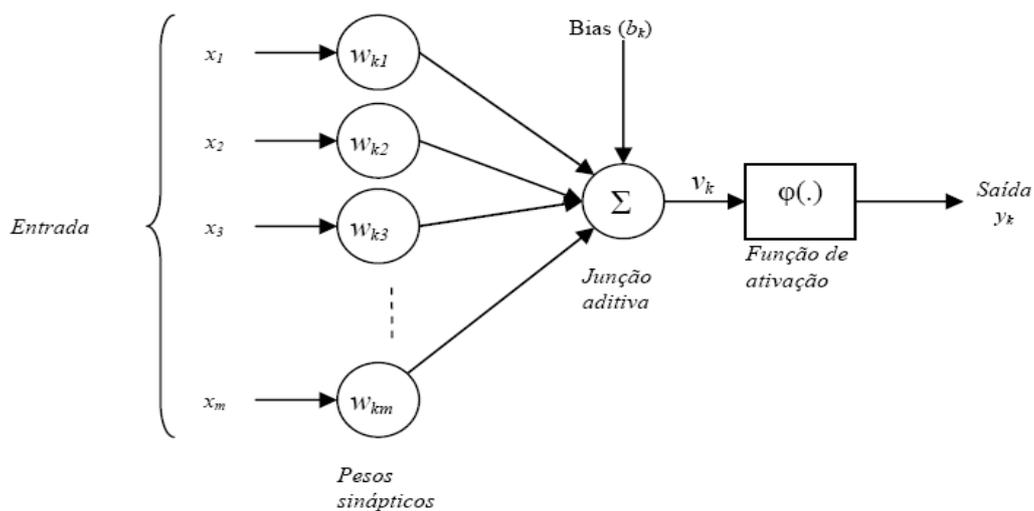


Figura 4.3 Modelo de neurônio artificial não linear.

Em termos matemáticos pode-se definir a operação no neurônio k da Figura 4.3, que possui as entradas j ($j=1,2,\dots,m$) através das seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad \text{Equação 4.1}$$

$$v_k = u_k + b_k \quad \text{Equação 4.2}$$

$$y_k = \varphi(v_k) \quad \text{Equação 4.3}$$

A função de ativação $\varphi(\cdot)$ é responsável pela definição da saída de um neurônio em termos de uma entrada v . Essas funções podem ser representadas de inúmeras maneiras. Mais comumente, e nesse trabalho, utilizam-se funções sigmóides (Figura 4.4).

Basicamente o tipo de funções de ativação limita o comportamento no intervalo de saída. A função tangente hiperbólica sigmóide (*tansig*) por exemplo pode ter uma saída variando entre -1 e 1, enquanto a sigmóide logarítmica (*logsig*) tem uma saída sempre entre 0 e 1.

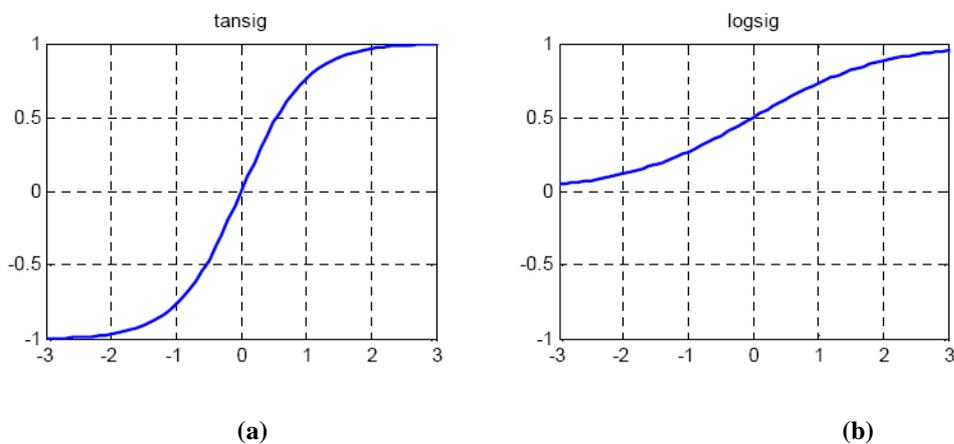


Figura 4.4 Funções de ativação: (a) tangente hiperbólica sigmóide (*tansig*) e (b) sigmóide logarítmica (*logsig*) a direita.

Uma vez definida a característica de um neurônio pode-se definir a arquitetura de uma rede neural ligando neurônios entre si através dos pesos sinápticos. A configuração apresentada neste trabalho é a de uma rede neural de múltiplas camadas conhecida como “*Perceptrons* de múltiplas camadas” ou MLP (*multilayer perceptrons*). Essa configuração é ilustrada na Figura 4.5.

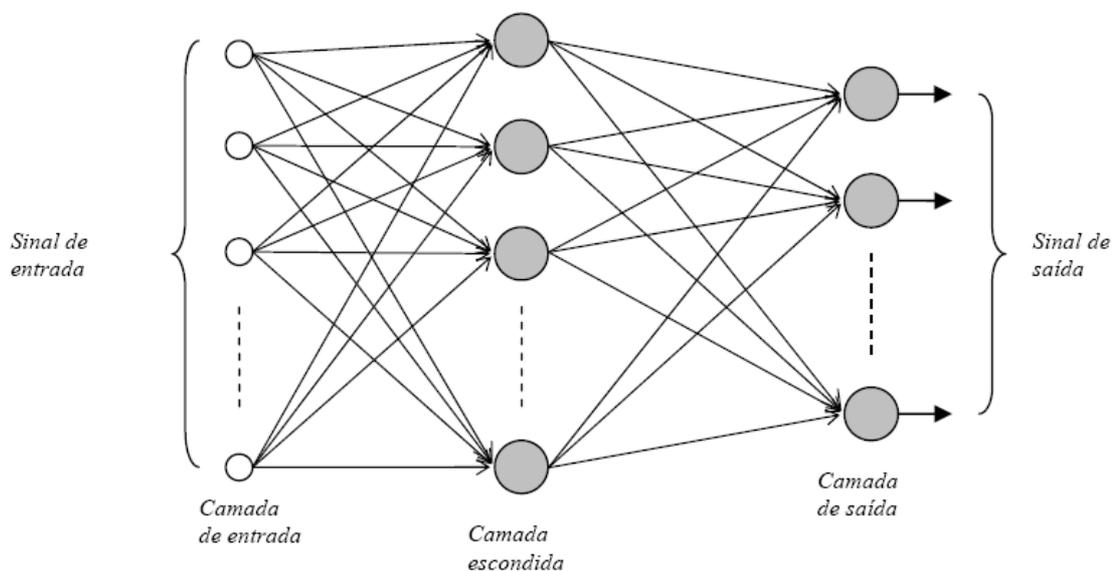


Figura 4.5 Arquitetura de uma rede neural do tipo MLP com uma camada oculta.

As redes MLPs consistem de um conjunto de unidades sensoriais, ou neurônios, arrumados em camadas, conforme o apresentado na Figura 4.5. Tem-se uma camada de entrada com nós não computacionais, uma ou mais camadas ocultas com nós computacionais e ainda uma camada de saída com nós também computacionais. Nesse trabalho exploram-se apenas redes neurais do tipo MLP com uma ou duas camadas ocultas. Os nós chamados computacionais realizam algum tipo de processamento, conforme o

modelo do neurônio apresentado anteriormente. Os nós não computacionais são apenas entradas ou saídas de dados e não realizam qualquer processamento.

Cada arco que liga um neurônio a outro em uma rede MLP possui um peso sináptico associado denotado por w_{ji} . Esse peso pode ser entendido como um peso que associa à entrada do neurônio j a saída do neurônio i . Em uma rede neural do tipo MLP existe um grande número de pesos a serem definidos ou estimados. O algoritmo de retropropagação, ou BP (*backpropagation*), é um processo supervisionado de aprendizado baseado no gradiente descendente que estima os valores dos pesos sinápticos a partir de padrões de treinamento. Nesse algoritmo o erro de previsão se propaga da camada de saída para a camada oculta, procurando assim o melhor conjunto de valores para os pesos de toda a rede. Esse procedimento pode ser encontrado com mais detalhes de implementação em [129] e [130].

De um modo geral, na tarefa de classificação de padrões, a arquitetura da rede neural recebe uma tupla como entrada (atributos preditivos) como entrada da primeira camada da rede neural. Os atributos objetivos (classes) são modelados pela camada de saída da rede neural. Desse modo o algoritmo pode estimar o quanto a saída desejada está distante da saída real. Tomando como exemplo a Figura 4.5, a camada de entrada pode ser tal que cada nó representa um determinado atributo preditivo de uma tupla e a camada de saída decodifica a que classe essa tupla pertence, ativando um único nó. Maiores detalhes podem ser encontrados em [131].

Para a tarefa de classificação de padrões também são utilizadas as redes neurais probabilísticas, baseadas em classificadores bayesianos e as redes RBF (*Radio- Basis Function*), baseadas em funções *gaussianas*. Esses algoritmos geram curvas de densidade de probabilidade, fornecendo resultados com bases estatísticas. Esses resultados indicam o

grau de evidência sobre o qual se baseia a decisão. Entretanto, essa metodologia só funciona bem se existir um número suficiente de exemplos de dados. A Figura 4.6 se enquadra como arquitetura desses algoritmos. A principal diferença está na interpretação do resultado, pois cada nó da camada de saída gera um valor que indica a probabilidade da tupla inserida na camada de entrada pertencer a uma determinada classe. Na topologia das redes RBF, (Figura 4.6) o número de neurônios da camada escondida é exatamente igual ao número de tuplas apresentadas para treinamento.

Embora as redes neurais apresentem um alto poder de classificação de padrões, muitos analistas de negócio não fazem uso delas por considerá-las “caixas pretas” [129]. Existe um grande número de pesos e parâmetros que realizam um mapeamento entre os espaços de entrada e saída, tornando difícil o processo de interpretação e decodificação da estrutura criada.

Na última década têm-se desenvolvido diferentes algoritmos capazes de extrair regras de redes neurais previamente treinadas. Estes algoritmos convertem as redes neurais em sistemas interpretáveis, capazes de serem aplicados com sucesso em aplicações de descoberta de conhecimento.

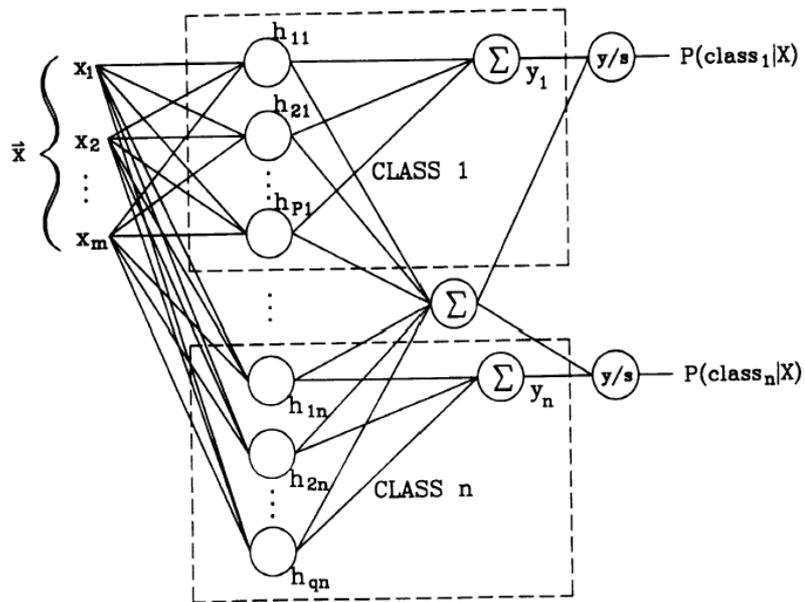


Figura 4.6 Uma topologia de uma rede neural utilizando bases estatísticas.

Os algoritmos podem ser agrupados em três grandes categorias segundo Andrews [132]:

Algoritmos de Decomposição: consideram a estrutura interna da rede. As regras são extraídas da análise direta dos valores numéricos da rede, como pesos e funções de ativação das camadas escondidas. Alguns exemplos desses sistemas que utilizam esses algoritmos são: **VIA** (*Validity Internal Analysis*) [133]; **Relevance Information** [134]; **BIO-RE** (*Binarised Input-Output Rule Extraction*) [135], [136]; **RULENEG** [137] e [138].

Algoritmos Black-Box: não levam em consideração a estrutura interna da rede. Estes algoritmos realizam o processo de extração de regras baseado na correlação entre o espaço de entrada e saída da rede. Alguns exemplos deste tipo de algoritmos: **REASC** (*Rule Extraction using Activation Space Clustering*) [139] e [140]; **NeuroLinear** [141]; **Partial Rule Extraction** [135]; **M-of-N Algorithm** [TOWE91]; **Full Rule Extraction** [135],

[136]; **RULEX** [142]; **RuleNet** [143] e [144]; **Extracting DFA from Recurrent ANN** [145].

Algoritmos Ecléticos: incorporam princípios dos dois algoritmos anteriormente apresentados (*Black-Box* e *Decomposição*). Alguns exemplos de algoritmos ecléticos: ***Rule Extraction as Learning*** [146]; **DEDEC** [147].

Exemplos de ferramentas: *SPSS Neural Connection*, *IBM neural Network Utility*, *NeuralWare* e *NeuralWorks Predict*.

4.2.3. Sistemas Fuzzy

Um sistema fuzzy é um sistema não-linear de mapeamento de um vetor de entrada em uma saída escalar, capaz de incorporar tanto o conhecimento objetivo, usado na formulação de problemas de engenharia e modelos matemáticos, quanto o conhecimento subjetivo que representa a informação lingüística, que é geralmente impossível de quantificar usando matemática tradicional.

De acordo com [148], o princípio da incompatibilidade diz que: “Conforme a complexidade de um sistema aumenta, a nossa habilidade de fazer declarações precisas e significativas sobre o comportamento do sistema diminui, até alcançar um limite além do qual precisão e relevância se tornam características mutuamente exclusivas”. A lógica fuzzy fornece um método para reduzir e explicar a complexidade do sistema.

A idéia básica de um sistema fuzzy está focada nos conjuntos fuzzy, que são funções que mapeiam um valor escalar em um número entre 0 e 1, o qual indica o seu grau

de pertinência, ou grau de certeza, a esse conjunto. A Figura 4.7 mostra um conjunto fuzzy definido por uma função de pertinência, representando o conjunto de projetos longa duração. O mapeamento funciona da seguinte maneira: verifica-se qual é a duração do projeto em meses e então verifica-se qual é o seu valor correspondente no eixo vertical, que significa o grau de pertinência que esse mês tem com o conjunto de projetos longos. Por exemplo tomando a duração do projeto como 20 meses, pode-se verificar que essa quantidade de meses têm-se grau de pertinência 1 para o conjunto de projetos de longa duração, em outras palavras, 20 meses indica com certeza de 100% que essa duração em meses pertence ao conjunto de projetos de longa duração.

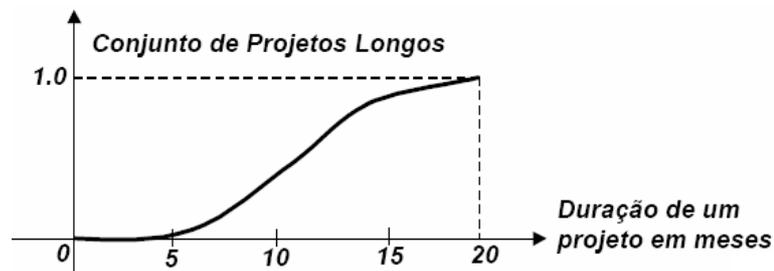


Figura 4.7 Exemplo de um conjunto fuzzy representando projetos de longa duração. O eixo vertical representa o grau de pertinência que os membros do conjunto (duração do projeto em meses) possui com relação ao conjunto de projetos longos.

A Figura 4.8 ilustra um sistema fuzzy identificando cada um dos seus módulos separadamente.

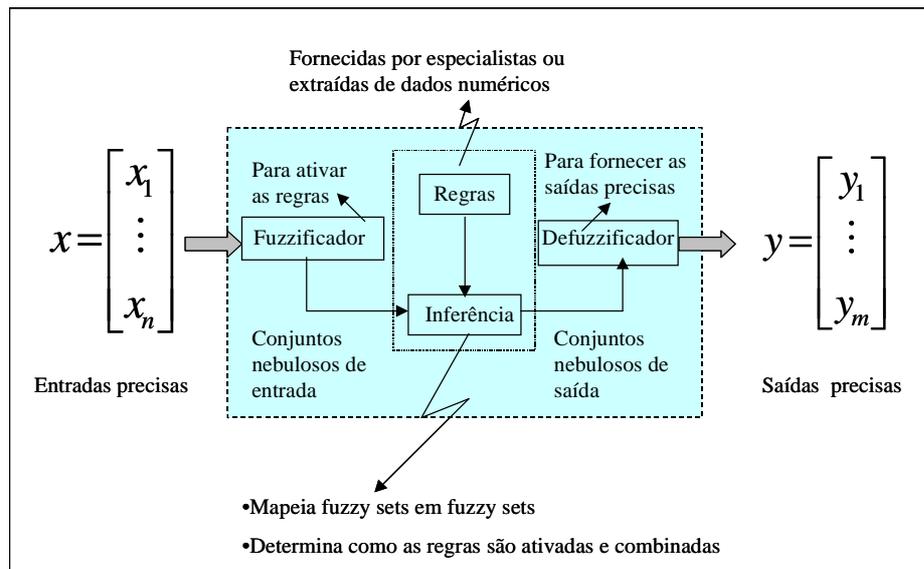


Figura 4.8 Sistema Fuzzy.

Fuzzificador:

É o responsável por transformar os valores *crisps* das variáveis de entrada em conjuntos fuzzy, que serão utilizados juntamente com as regras para realizar a inferência do valor de saída. Um valor *crisp* é definido como pertencente ou não pertencente a um conjunto. Já um valor fuzzy pode pertencer simultaneamente a vários conjuntos com diferentes graus de pertinência para cada conjunto. O *fuzzificador* mais utilizado é o *fuzzy singleton*, que define um conjunto fuzzy em que apenas um elemento (o valor da variável de entrada *crisp*) tem valor de pertinência unitário, e os demais têm pertinência zero. Quando existe uma incerteza em relação aos dados, devido principalmente a ruído, pode-se utilizar um *fuzzificador não-singleton*, como por exemplo o *fuzzy number*.

A Figura 4.9 ilustra um caso onde estão sendo analisados todos os automóveis do Rio de Janeiro. Dois conjuntos fuzzy foram definidos, o conjunto das peças importadas e o conjunto das peças nacionais. A variável em questão é a “% de peças” nacionais ou importadas que os automóveis do Rio de Janeiro possuem. Pode-se verificar que utilizando

o conceito de conjuntos fuzzy, uma determinada variável pode pertencer a mais de um conjunto ao mesmo tempo, com diferentes graus de pertinência. Exemplo: 75% das peças tem grau de pertinência 0.9 para o conjunto de peças nacionais ao mesmo tempo que possuem grau de pertinência de 0.25 para o conjunto de peças importadas.

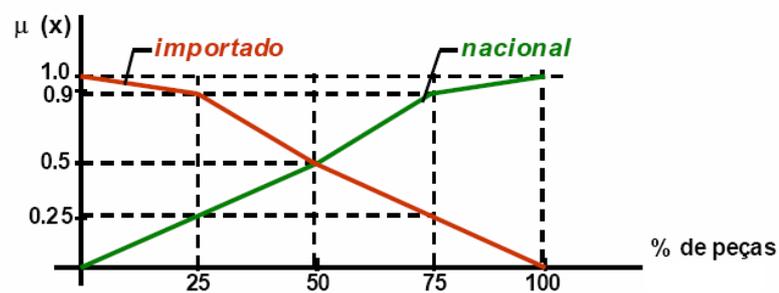


Figura 4.9 Exemplo de dois conjuntos fuzzy, importado e nacional, que mapeiam a variável “% de peças”.

Regras:

As regras são o “coração” de um sistema fuzzy. Podem ser fornecidas por especialistas no sistema específico que está sendo utilizado, ou extraídas a partir de dados numéricos, utilizando algoritmos específicos. Tem-se um conjunto de regras definidas na forma *SE..ENTÃO*, que serão utilizadas pela inferência, juntamente com os conjuntos de entrada (fornecidos pelo *fuzzificador*).

Inferência:

A inferência, ou máquina de inferência, mapeia, a partir das regras definidas para o sistema, os conjuntos fuzzy de entrada em conjuntos fuzzy de saída. Têm-se diversas

maneiras diferentes de realizar a inferência, as mais utilizadas são: **max-min** e **max-produto**.

Defuzzificador:

Realiza a função inversa do *fuzzificador*, isto é, transforma os conjuntos fuzzy de saída, determinados pela inferência, em valores *crisp* atribuídos às variáveis de saída do sistema.

4.2.3.1. Modelo Fuzzy para Classificação de Padrões

As regras fuzzy formam a parte fundamental da estrutura de conhecimento em um sistema fuzzy de inferência. O formato da regra fuzzy para um sistema de classificação segue o seguinte modelo:

Regra : Se x é A e y é B Então o padrão (x,y) pertence a classe i .

Por simplicidade, somente modelos de regras com duas entradas e uma saída são usados nos exemplos.

Os conjuntos fuzzy são definidos pelas funções de pertinências. Vários perfis de funções de pertinências são encontrados na implementação de sistemas fuzzy, triangular, trapezoidal, gaussiana, sino, sigmoidal, singleton, etc.. Abaixo será apresentados o perfil trapezoidal [149].

O perfil trapezoidal pode ser descrito por três variáveis: ‘u’, ‘v’ e ‘d’ que regula a inclinação das bordas da função de pertinência trapezoidal (mais *crisp* ou mais *fuzzy*). As expressões mostradas na Equação 4.4 definem este perfil.

| | |
|---|-------------|
| $\mu(x) = [1 - g(x - v, d) - g(u - x, d)]$ <p>onde, $g(s, d) = \begin{cases} 1 & , \text{se } s, d > 1 \\ s, d & , \text{se } 0 \leq s, d \leq 1 \\ 0 & , \text{se } s, d < 0 \end{cases}$</p> | Equação 4.4 |
|---|-------------|

A Figura 4.10, ilustra uma função de pertinência de formato trapezoidal como descrito na Equação 4.4 acima.

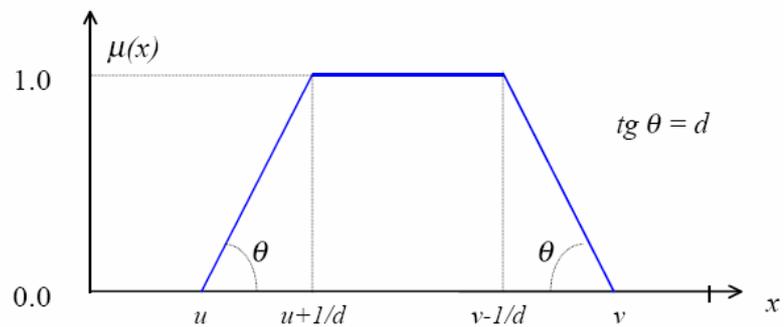


Figura 4.10 Função de pertinência com formato trapezoidal.

As variáveis de entrada e saída dos sistemas de inferência fuzzy são divididas em vários termos lingüísticos (por ex. *baixo*, *médio* e *alto*) que são utilizados pelas regras fuzzy.

A Figura 4.11 ilustra um exemplo de um sistema fuzzy para classificação com duas entradas e três classes de saída, utilizando funções de pertinências trapezoidais. As regras são expressas por um especialista da seguinte maneira:

Regra 1: Se A é A1 e B é B2 então (A,B) pertence a classe 1.

Regra 2: Se A é A1 e B é B1 então (A,B) pertence a classe 1.

Regra 3: Se A é A2 e B é B2 então (A,B) pertence a classe 2.

Regra 4: Se A é A2 e B é B3 então (A,B) pertence a classe 2.

Regra 5: Se A é A3 e B é B1 então (A,B) pertence a classe 3.

Regra 6: Se A é A3 e B é B3 então (A,B) pertence a classe 3.

Tomando por exemplo as regra 3e regra 4, verifica-se:

- Para a regra 3 qual é o grau de pertinência de A para o conjunto A2 e o grau de pertinência de B para o conjunto B2. Em seguida obtém-se o menor grau de pertinência entre as duas variáveis antecedentes denominado na Figura 4.11 de w_3 .
- Para a regra 4 qual é o grau de pertinência de A para o conjunto A2 e o grau de pertinência de B para o conjunto B3. Em seguida obtém-se o menor grau de pertinência entre as duas variáveis antecedentes denominado na Figura 4.11 de w_4 .

Essa operação de mínimo entre os antecedentes de uma regra é denominada como uma operação do tipo *t-norm*. Em seguida combinam-se as duas regras utilizando um operador de máximo, que irá determinar a que classe o padrão pertence. No exemplo em

questão então toma-se o valor máximo entre w_3 e w_4 , que é w_3 indicando quem é a classe vencedora. Essa operação de máximo entre os mínimos é denominada como uma operação do tipo *t-conorm*. Neste caso não há procedimento de *defuzzificação*.

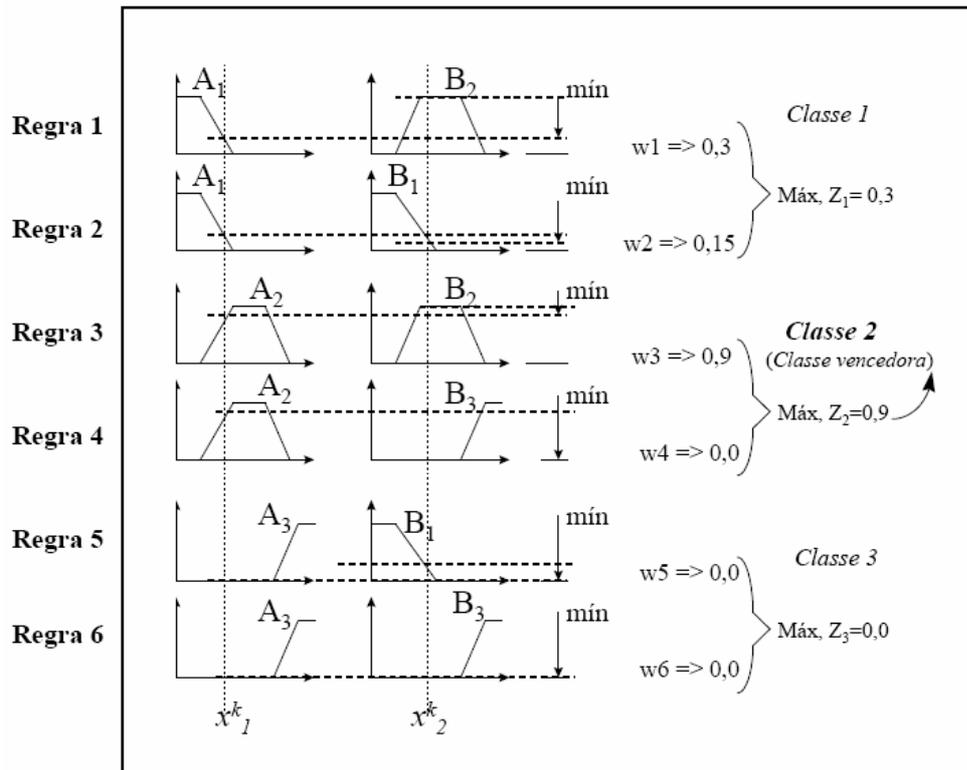


Figura 4.11 Sistemas Fuzzy de Classificação com duas entradas e três classes de saída

O particionamento do espaço de entrada indica a forma como as regras fuzzy estão relacionadas com este espaço. O particionamento do espaço de saída costuma ser mais simples e está associado aos consequentes das regras.

A Figura 4.12 mostra vários tipos de particionamentos possíveis para o espaço de entrada. Os exemplos ilustrados nesta figura referem-se a sistemas com duas variáveis de

entrada, mas podem ser generalizados. Desta forma, as variáveis do espaço de entrada correspondem à dimensão horizontal e vertical de cada figura.

O particionamento *Fuzzy Grid* da Figura 4.12.a é fixo, não permitindo ajustes nas funções de pertinência. Os sistemas que o utilizam ajustam apenas os parâmetros dos consequentes.

Na Figura 4.12.b, o particionamento *Adaptive Fuzzy Grid*, como o próprio nome diz, é adaptativo, e permite ajustes nos perfis das funções de pertinência [150]. Os particionamentos *Fuzzy Grid* são simples e intuitivos, porém, à medida que o número de variáveis de entrada e saída aumenta, o número de partições cresce combinatorialmente. Em alguns casos isto pode levar a situações em que o tamanho da memória torna-se impraticavelmente grande.

As Figura 4.12.c e Figura 4.12.d mostram os particionamentos *Fuzzy Box* e *Fuzzy Cluster*, respectivamente. O primeiro (Figura 4.12.c) aparece em sistemas [149] que utilizam a versão fuzzy das redes neurais ART, como fuzzy ART de Carpenter et al. [151],[152], ou no SNF chamado *Fuzzy Self-Organized Map* - FSOM - de Vuorimaa [153]. O segundo (Figura 4.12.d) é gerado por redes neurais do tipo das Redes de funções de Bases Radiais (*Radial Basis Function* - RBFs), que para alguns pesquisadores da área podem ser encaradas também como um Sistema Neuro-Fuzzy [154]. Tanto o FSOM quanto as RBFs usam alguma medida de similaridade entre padrões para o cálculo dos centros de suas funções de pertinência.

Os particionamentos das Figura 4.12.e (BSP – *Binary Space Partinioning*) e Figura 4.12.f (*Quadtree*) são flexíveis e minimizam, um pouco, o problema do crescimento exponencial do número de regras pois só criam novas regras localmente, conforme o

conjunto de treinamento. Sua vantagem principal é permitir a criação de sistemas que constroem sua própria estrutura de forma automática [5], [8], [155]. Os particionamentos *Quadtree* e *BSP* serão discutidos em mais detalhes nas próximas seções sobre sistemas neuro-fuzzy.

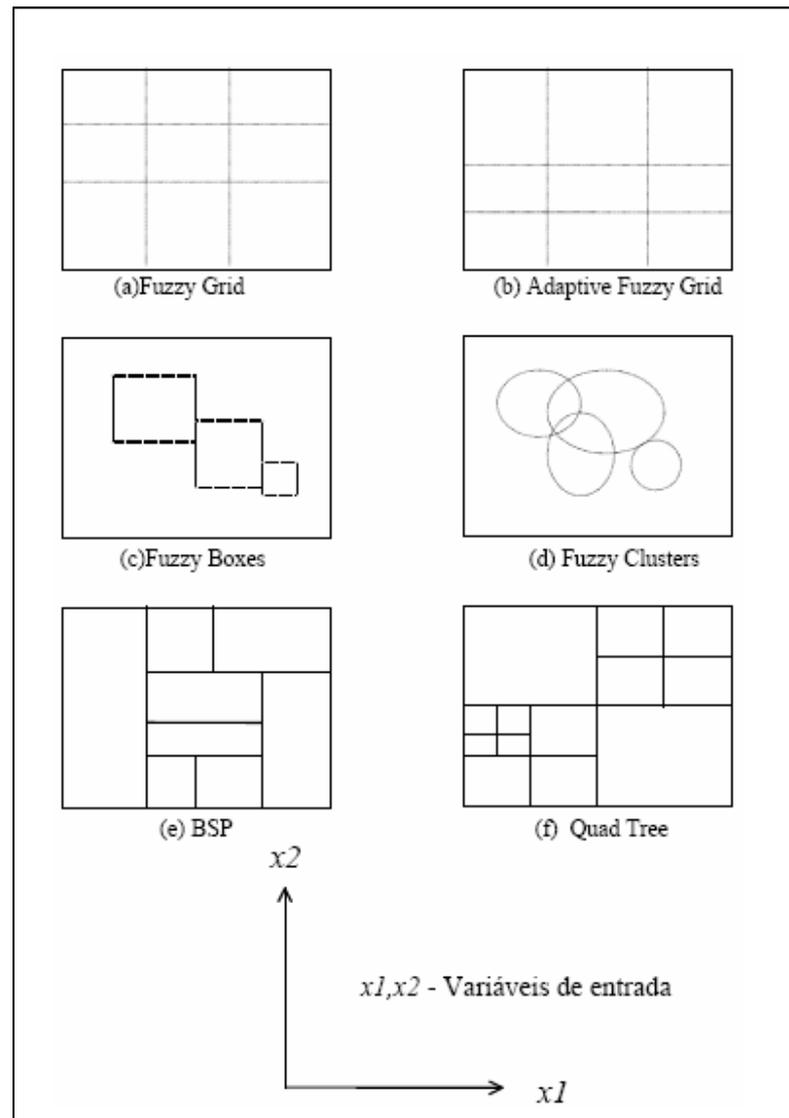


Figura 4.12 Particionamento possíveis para o espaço de entrada.

A apresentação dos padrões de treinamento é realizada *off-line*, ou seja, a atualização dos parâmetros e estrutura acontece somente após a apresentação de todo o

conjunto de treinamento, isto é, após uma época ou varredura. Esta forma requer um conjunto de dados de treinamento disponível antes da identificação da estrutura e dos parâmetros.

O conhecimento prévio é explícito e proveniente de especialista(s). A criação das regras e o esboço preliminar das funções de pertinências envolve um domínio de conhecimento de interesse específico, o apoio de um ou mais especialistas neste domínio e um engenheiro do conhecimento capaz de extrair este conhecimento do especialista e expressá-lo em termos de proposições fuzzy e variáveis lingüísticas.

4.2.4. Sistemas Neuro-Fuzzy

Os sistemas Neuro-Fuzzy estão entre os sistemas híbridos mais pesquisados na atualidade, por associarem as vantagens de duas técnicas de modelagem muito populares como as Redes Neurais e a Lógica Fuzzy. Estes sistemas combinam a capacidade de aprendizado das Redes Neurais com o poder de interpretação lingüístico dos sistemas que utilizam Lógica Fuzzy [8].

Nesta seção serão descritos de forma sucinta, os principais sistemas híbridos neuro-fuzzy para a tarefa de classificação de padrões.

4.2.4.1. NEFCLASS

O sistema neuro-fuzzy NEFCLASS [156] foi desenvolvido por Nauck e Kruse e sua aplicação básica é em sistemas de classificação. Nauck desenvolveu também dois outros sistemas neuro-fuzzy, um para aplicações em controle – NEFCON [157] e outro para aplicações em previsão e aproximação de funções – NEFPROX [158].

Este sistema possui uma arquitetura formada por quatro camadas que são descritas a seguir [8]:

Camada de Entrada - Esta camada tem apenas a função de direcionar os valores das entradas x_1, x_2, \dots, x_n para as entradas das funções de pertinência dos antecedentes das regras.

Camada de Antecedentes - Esta camada gera os graus de pertinência dos antecedentes das regras. O universo de discurso de cada variável de entrada está dividido em três conjuntos fuzzy (baixo, médio e alto). O particionamento do espaço de entrada implementado por esta camada é o “*adaptive fuzzy-grid*”.

Camada de Regras - Esta camada gera o nível de disparo de cada regra através da operação T-norm realizada entre os graus de pertinência dos conjuntos fuzzy que antecedem cada elemento desta camada.

Camada de Saída - Esta camada gera cada uma das saídas do classificador. As saídas são obtidas pela operação de *T-conorm* entre os níveis de disparo da camada de

regra. Os pesos que interligam a camada de regras e a camada de saída (todos iguais a 1, no caso do NEFCLASS) indicam que cada regra tem um mesmo grau de importância entre si.

As regras fuzzy que descrevem os dados têm a forma:

Se $x_1 \in \mu_1$ e $x_2 \in \mu_2$ e ... e $x_n \in \mu_n$ então padrão (x_1, x_2, \dots, x_n) pertence a classe i .

onde μ_i são conjuntos fuzzy.

O modelo NEFCLASS descobre regras e ajusta o perfil das funções de pertinência dos antecedentes. O aprendizado deste sistema é realizado em duas etapas separadas. A primeira utiliza um algoritmo para criar a camada de regras. Esta camada pode ser inicializada a partir de um conhecimento prévio ou ser inicializada com um conjunto vazio de regras e crescer com aprendizado incremental de regras. A segunda etapa utiliza um algoritmo supervisionado de “*Gradient Descent*” para ajustar os perfis das funções de pertinência dos antecedentes das regras.

Um exemplo de arquitetura do sistema NEFCLASS é ilustrado na Figura 4.13.

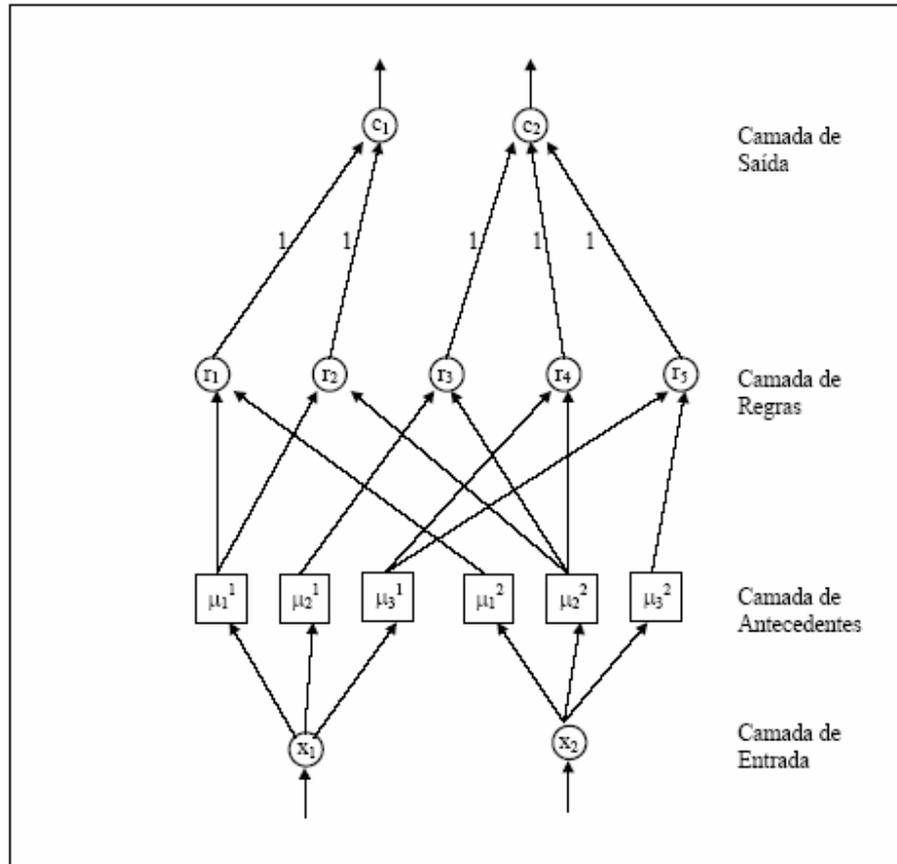


Figura 4.13 Sistema NEFCLASS com duas entradas, cinco regras e duas classes de saída.

O algoritmo de aprendizado do sistema NEFCLASS pode ser visto a seguir:

Seja:

n : número de entradas (Atributos – x_1, \dots, x_n)

K_{max} : número de regras (R_1, \dots, R_k)

m : número de classes dos padrões (c_1, \dots, c_m)

$\tilde{L} = \{(\mathbf{p}_1, t_1), \dots, (\mathbf{p}_s, t_s)\}$ a base de dados contendo s padrões

onde:

\mathbf{p}_i : vetor de atributos do padrão \mathbf{p}_i

t_i : classe do padrão \mathbf{p}_i

(i) Selecionar o próximo (\mathbf{p}, t) de \tilde{L}

(ii) Para cada variável de entrada (atributo), encontrar o conjunto fuzzy que possui maior grau de pertinência

$$\mu_{ji}^{(i)}(p_i) = \max_{j \in \{1, \dots, q_i\}} \{\mu_j^{(i)}(p_i)\}$$

(iii) Se o número de regras $K < Kmax$ e não existe nenhuma regra R com:

$$W(x_1, R) = \mu_{j_1}^{(1)}, \dots, W(x_n, R) = \mu_{j_n}^{(n)} \quad (\text{mesmo antecedente})$$

então crie um novo nó R e conecte com o nó de saída (classe)

(iv) Se ainda existem padrões na base de dados que não foram processados e se o número de regras $K < Kmax$, então volta ao passo (i), senão fim.

(v) Determinação da base de regras (3 maneiras):

“Simple” rule learning (padrões devem ser selecionados aleatoriamente da base de dados)

Mantenha os K primeiras regras criadas (parar o algoritmo quando $Kmax = K$ regras)

“Best” rule learning (quando existem classes que necessitam de um número maior de regras para ser representada do que outras classes)

Processe \tilde{L} novamente

Acumule a ativação de cada regra para cada uma das classes dos padrões

Se a ativação acumulada de uma regra R para uma classe C_j for maior do que para a classe CR (conclusão da regra), então conecte R com a saída C_j .

Processe \tilde{L} novamente e calcule para cada regra VR

$$V_R = \sum_{p \in \tilde{L}} a_R^{(p)} \cdot e_p$$

$$e_p = \begin{cases} 1 \\ -1 \end{cases}$$

Mantenha as K regras que tiverem os maiores valores para VR

Remova as outras regras do sistema NEFCLASS

“Best per Class” rule learning (quando o número de padrões está distribuído de maneira uniforme por classes)

O procedimento é igual ao **“Best” rule learning**, porém mantem-se para cada classe C_j as k/m melhores regras cuja conclusão representa a classe C_j .

Algoritmo de aprendizado dos conjuntos fuzzy do sistema NEFCLASS:

(i) Selecione o próximo padrão (\mathbf{p}, t) da base de dados

 Apresente-o para o sistema NEFCLASS

 Determine a saída do sistema a_{C_i}

(ii) Para cada saída C_i , determine δ_{C_i} através de $\delta_{C_i} = t_i - a_{C_i}$

onde: t_i é a saída desejada e a_{C_i} é a saída obtida.

(iii) Para cada regra R com $a_R > 0$

(a) Determine δ_R

$$\delta_R = a_R \cdot (1 - a_R) \cdot W(R, c) \cdot \delta_c$$

(b) Encontre x' tal que:

$$W(x', R)(a_{x'}) = \min\{W(x, R)(a_x)\}$$

(c) Para o conjunto fuzzy $W(x', R)$ determine δ_a , δ_b e δ_c usando uma taxa de aprendizado $\sigma > 0$. Aplique as mudanças para $W(x', R)$

Obs: O peso $W(x', R)$ pode estar sendo utilizado por outras conexões, logo ele deve ser atualizado em todas as conexões.

$$\delta_b = \sigma \cdot \delta_R \cdot (c - a) \cdot \text{sgn}(a_{x'} - b)$$

$$\delta_a = -\sigma \cdot \delta_R \cdot (c - a) + \delta_b$$

$$\delta_c = \sigma \cdot \delta_R \cdot (c - a) + \delta_b$$

(iv) Se um ciclo for completado e um critério de parada alcançado então fim; caso contrário volta ao passo (i).

De forma geral pode-se atribuir ao sistema NEFCLASS, assim como os sistemas neuro-fuzzy tais como NEFCON [157], NEFPROX [158], ANFIS[150] e FSOM[153], duas limitações:

- número reduzido de entradas com que eles trabalham;
- forma limitada (em alguns casos inexistentes) destes criarem sua própria estrutura e regras.

A primeira limitação ocorre em função da chamada explosão combinatorial das regras. Por exemplo, suponha que um determinado sistema neuro-fuzzy tenha cinco variáveis de entrada e cada uma delas tenha seu universo de discurso subdividido em quatro conjuntos fuzzy. Com esse sistema, pode-se chegar a um total de 1024 (4^5) regras. Suponha agora que se tenha 20 entradas. Usando-se a mesma divisão nos universos de discurso para cada variável de entrada, chega-se a um total impraticável de 1.099.511.627.776 (4^{20}) regras.

A segunda limitação é o fato de que eles exibem (quando tal) uma capacidade limitada de criar sua estrutura. Alguns têm estrutura fixa, arbitrada a priori e não permite que ela varie. Outros sistemas neuro-fuzzy, mais flexíveis, têm alguma capacidade de alterar a sua estrutura, permitindo que se altere o número de divisões no universo de discurso de algumas de suas variáveis de entrada e, conseqüentemente, o número de regras. Entretanto, esta habilidade é reduzida e ainda mantém refém o primeiro tipo de limitação.

Uma solução para essas limitações é o uso de formas de particionamento recursivos, que permitem a criação de sistemas neuro-fuzzy com uma capacidade ilimitada de crescimento em suas estruturas. Os sistemas neuro-fuzzy NFHQ [8], NFHB [8], NFHB-Invertido e NFHB-Class [2], [3], [4], [5] utilizam este tipo de particionamento evitando assim a explosão combinatorial de regras. Esses sistemas geram automaticamente sua própria estrutura e criam sua própria base de regras. A criação da própria estrutura pode também ser encarada como um aprendizado. Assim estes modelos apresentam um diferencial significativo sobre os sistemas neuro-fuzzy atuais que suportam apenas o aprendizado dos parâmetros.

4.2.4.2. Modelo NFHQ

O sistema NFHQ – Neuro-Fuzzy Hierárquico *Quadtree* – é um sistema que utiliza o particionamento recursivo *Quadtree* para o espaço de entrada.

O particionamento *Quadtree* foi usado originariamente na representação de imagens [159],[160],[161]. A figura 3.3, abaixo, ilustra uma figura geométrica sendo representada através de uma aproximação dessa forma de particionar uma imagem. Sua versão tri-dimensional é chamada ‘Oct-tree’ e funciona de forma análoga ao *Quadtree*. Nesse particionamento, o espaço bi-dimensional é subdividido sucessivamente em quadrantes que, por sua vez, podem ser subdivididos novamente em quatro partições (quadrantes) numa operação recursiva.

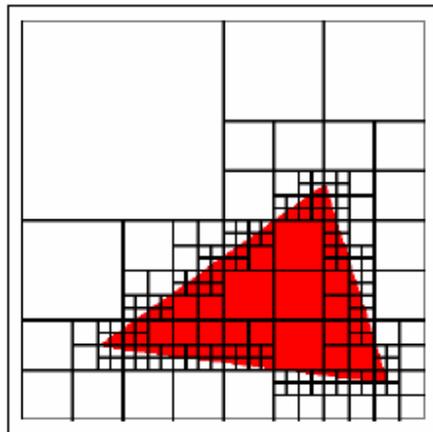


Figura 4.14 Representação da imagem de um triângulo por particionamento *quadtree* [8].

A Figura 4.15.a ilustra um exemplo deste tipo de particionamento para o caso bidimensional, e a Figura 4.15.b mostra a sua árvore *Quadtree* representativa.

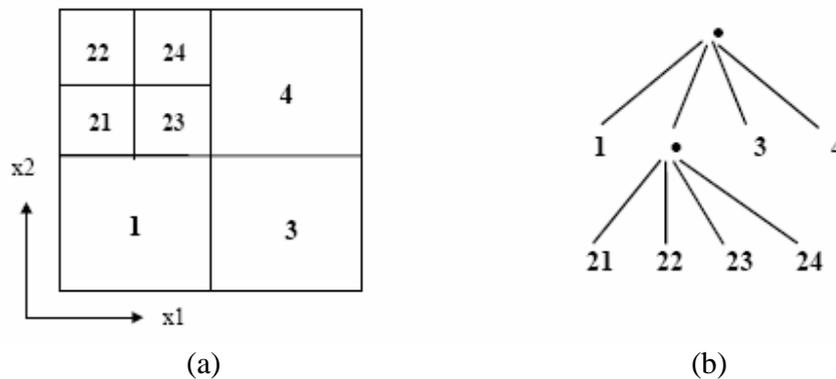


Figura 4.15 (a) Exemplo de um particionamento *Quadtree*. (b) Árvore *Quadtree* referente ao particionamento da Figura 4.15b.

O sistema NFHQ é composto de uma ou várias células padrão chamadas *células neuro-fuzzy quadtree*. Estas células são dispostas numa estrutura hierárquica de árvore quaternária. A célula de maior hierarquia gera a saída. As de menor hierarquia trabalham como conseqüentes das células de maior hierarquia.

Célula Neuro-Fuzzy Quadtree

Uma célula NFHQ é um mini-sistema neuro-fuzzy que realiza um particionamento *quadtree* em um determinado espaço, segundo as funções de pertinência. A célula NFHQ gera uma saída exata após um processo de *defuzzificação*, conforme será mostrado posteriormente.

A Figura 4.16.a, mostra o processo de *defuzzificação* da célula e o encadeamento dos conseqüentes. Nesta célula, as entradas x_h (entrada horizontal) e x_v (entrada vertical) geram os antecedentes das quatro regras fuzzy após serem computados os graus de pertinência $\rho_h(x_h)$, $\mu_h(x_h)$, $\rho_v(x_v)$ e $\mu_v(x_v)$, onde: ρ_h é o conjunto nebuloso *baixo horizontal*; μ_h é o conjunto nebuloso *alto horizontal*; ρ_v conjunto nebuloso *baixo vertical* e

μ_v é o conjunto nebuloso *alto vertical*. A Figura 4.16.b ilustra a representação desta célula de forma simplificada e a Figura 4.17 apresenta-a sob o formato de rede neuro-fuzzy. Na Figura 4.17 estão sendo mostradas as camadas de entrada, de *fuzzificação*, de regras, e de *defuzzificação*.

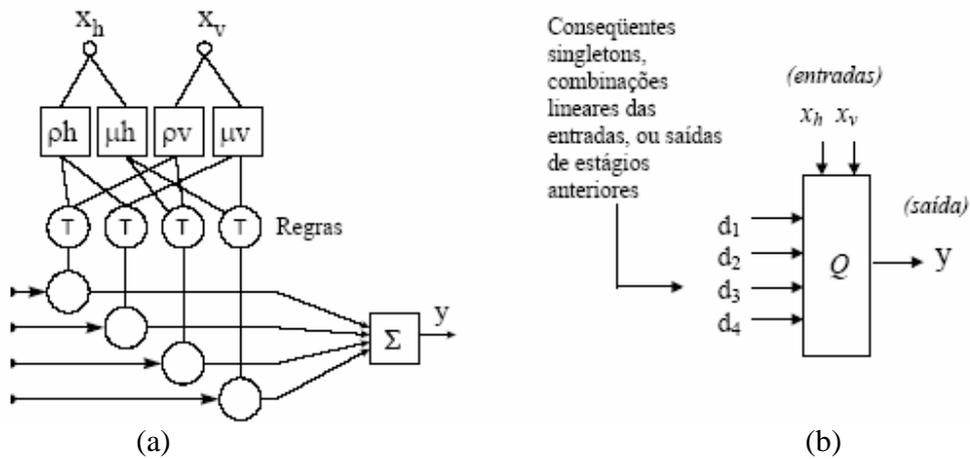


Figura 4.16 (a) Célula Neuro-Fuzzy *Quadtree*. (b) Célula NFHQ simplificada.

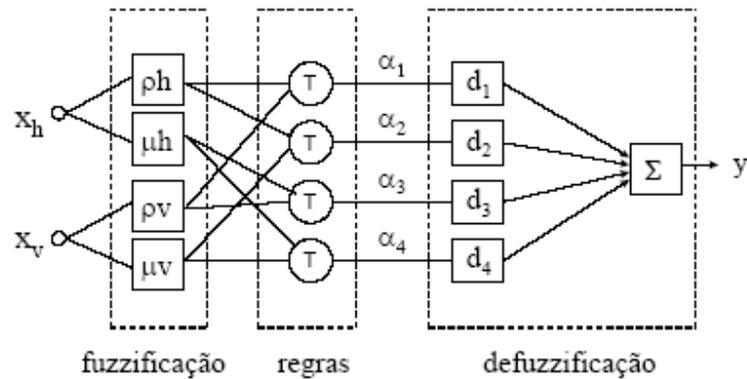


Figura 4.17 Célula NFHQ representada sob o formato de rede neuro-fuzzy.

A interpretação lingüística do mapeamento implementado pela célula NFHQ da figura 4.1 é dada pelo seguinte conjunto de regras:

Se $x_h \in \rho_h$ e $x_v \in \rho_v$ então $y = d_1$, regra1;

Se $x_h \in \rho_h$ e $x_v \in \mu_v$ então $y = d_2$, regra2;

Se $x_h \in \mu_h$ e $x_v \in \rho_v$ então $y = d_3$, regra3;

Se $x_h \in \mu_h$ e $x_v \in \mu_v$ então $y = d_4$, regra4;

Cada regra corresponde a um quadrante da Figura 4.15.b. Quando as entradas incidem sobre o quadrante 1, é a regra 1 que tem maior nível de disparo. Quando a incidência é sobre o quadrante 2, é a regra 2 que tem maior nível de disparo. No caso das entradas caírem no quadrante 3, é a regra 3 que tem maior nível de disparo e, finalmente, quando a incidência é sobre o quadrante 4, é a regra 4 que tem maior nível de disparo. Cada quadrante por sua vez pode ser sub-dividido em quatro partes, através de uma outra célula NFHQ.

Na Figura 4.17, os α_i simbolizam os níveis de disparo das regras. Estes níveis de disparo são calculados usando-se uma operação “e” nebulosa (*T-norm*) sobre os graus de pertinência de ρ_h, μ_h, ρ_v e μ_v , conforme descrito a seguir:

$$\alpha_1 = \rho_h(x_h) * \rho_v(x_v);$$

$$\alpha_2 = \rho_h(x_h) * \mu_v(x_v);$$

$$\alpha_3 = \mu_h(x_h) * \rho_v(x_v);$$

$$\alpha_4 = \mu_h(x_h) * \mu_v(x_v).$$

onde o símbolo “*” representa a operação “e” nebulosa, que pode ser realizada pela multiplicação ou a operação de mínimo entre os dois valores.

A saída 'y' da célula NFHQ da Figura 4.17 é dada pela média ponderada mostrada na Equação 4.5:

$$y = \frac{\sum_{i=1}^4 \alpha_i \times d_i}{\sum_{i=1}^4 \alpha_i} \quad \text{Equação 4.5}$$

onde cada d_i corresponde a um dos três conseqüentes possíveis abaixo:

- **um singleton** (conseqüente fuzzy *singleton*, ou Sugeno de ordem zero), caso em que $d_i = \text{constante}$;
- **uma combinação linear** das entradas (conseqüente de Sugeno de 1a. ordem),

$$\text{caso em que } d_i = \sum_{k=0}^n w_k \cdot x_k$$

onde: x_k é a k-ésima entrada do sistema; os w_k representam os pesos da combinação linear; e 'n' é igual ao número total de entradas. O peso w_0 , sem entrada, corresponde a um valor constante (bias).

à saída de um estágio de nível anterior, caso em que $d_i = y_j$ onde y_j representa a saída de uma célula genérica 'j', cujo valor é calculado, também, pela Equação 4.5.

Na célula NFHQ básica, as funções de pertinência são implementadas por sigmóides (μ_h e μ_v) e por seu complemento a um $[1 - \mu(x)]$, (ρ_h e ρ_v). A utilização dos complementos a um leva a uma simplificação no procedimento de *defuzzificação* realizado

pelo processo de média ponderada (Equação 4.5), pois o somatório dado pela Equação 4.6 , abaixo, é igual a 1 para quaisquer valores de x_h e x_v .

$$\sum_{i=1}^4 \alpha_i = 1 \quad \text{Equação 4.6}$$

Isto pode ser facilmente observado considerando-se a multiplicação a seguir:

$$\begin{array}{r} \rho_v + \mu_v \quad (=1) \\ \times \quad \rho_h + \mu_h \quad (=1) \\ \hline \rho_h \cdot \rho_v + \rho_h \cdot \mu_v + \mu_h \cdot \rho_v + \mu_h \cdot \mu_v = \alpha_1 + \alpha_2 + \alpha_3 + \alpha_4 = 1 \end{array}$$

Como as somas $\rho_h + \mu_h$ e $\rho_v + \mu_v$ são sempre iguais a 1 (funções de pertinência complementares), seu produto será também sempre igual a 1. Por outro lado, o produto também é igual à soma $\alpha_1 + \alpha_2 + \alpha_3 + \alpha_4$.

Desta forma, a saída da célula básica (Equação 4.5) fica simplificada, como mostra a Equação 4.7, a seguir. Esta simplificação facilita a obtenção das equações de ajuste dos parâmetros devido ao fato da derivada parcial da saída “y” em relação a um parâmetro qualquer ficar, analiticamente, mais simples.

$$y = \sum_{i=1}^4 \alpha_i \times d_i \quad \text{Equação 4.7}$$

Arquitetura NFHQ

O modelo NFHQ é criado a partir da interligação das células NFHB. Isto é exemplificado na Figura 4.18.a, abaixo. O particionamento realizado pelo pequeno sistema ilustrado na Figura 4.18.a é mostrado na Figura 4.18.b. Cada partição não subdividida é chamada de *quad-partição*.

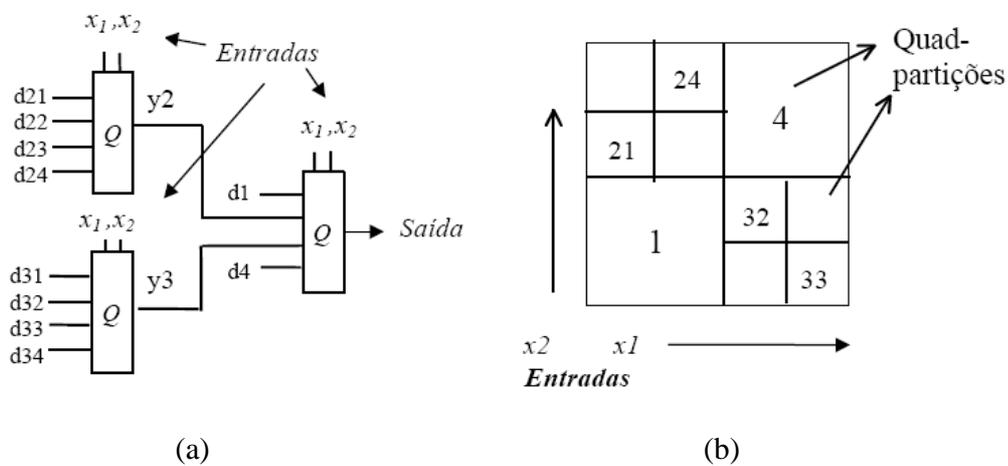


Figura 4.18 (a) Exemplo de uma arquitetura NFHB. (b) Partição do espaço de entrada realizado pela arquitetura da Figura 4.18 (a).

Neste sistema os quadrantes 1 e 4 não foram subdivididos, portanto os conseqüentes de suas respectivas regras são os valores d_1 e d_4 . Os quadrantes 2 e 3 foram subdivididos e os conseqüentes de suas regras são as saídas (y_2 e y_3) dos subsistemas 2 e 3. Estes por sua vez têm, como conseqüentes, os valores $d_{21}, d_{22}, d_{23}, d_{24}$ e $d_{31}, d_{32}, d_{33}, d_{34}$, respectivamente. Caso se esteja utilizando conseqüentes de Sugeno de ordem 0 (valores constantes), cada ' d_i ' corresponde a um '*singleton*'. Usando-se conseqüentes de Sugeno de ordem 1, cada ' d_i ' corresponde a uma combinação linear das entradas, ou seja,

$$d_i = \sum_{k=0}^n w_k \cdot x_k \quad \text{Equação 4.8}$$

A saída do sistema da figura 4.2 é dada pela equação 4.4, a seguir.

$$y = \alpha_1 \times d_1 + \alpha_4 \times d_4 + \sum_{i=2}^3 \sum_{j=1}^4 \alpha_i \times \alpha_{ij} \times d_{ij} \quad \text{Equação 4.9}$$

De uma forma genérica, a equação de saída de um sistema NFHQ de 2 níveis é dada pela fórmula 4.5 abaixo. Neste caso houve necessidade de se incluir as variáveis k_i e k_{ij} . Essas variáveis assumem apenas valores iguais a '0' ou '1', indicando a existência ou não das quad-partições de ordem ' i ' e ' ij ', respectivamente.

$$y = \sum_{i=1}^4 (\alpha_i \times k_i \times d_i) + \sum_{i=1}^4 \sum_{j=1}^4 (\alpha_i \times \alpha_{ij} \times k_{ij} \times d_{ij}) \quad \text{Equação 4.10}$$

Expandindo a Figura 4.13 para um sistema NFHQ de quatro níveis de hierarquia tem-se a seguinte fórmula:

$$y = \sum_{i=1}^4 (\alpha_i \times k_i \times d_i) + \sum_{i=1}^4 \sum_{j=1}^4 (\alpha_i \times \alpha_{ij} \times k_{ij} \times d_{ij}) + \sum_{i=1}^4 \sum_{j=1}^4 \sum_{k=1}^4 (\alpha_i \times \alpha_{ij} \times \alpha_{ijk} \times k_{ijk} \times d_{ijk}) + \sum_{i=1}^4 \sum_{j=1}^4 \sum_{k=1}^4 \sum_{m=1}^4 (\alpha_i \times \alpha_{ij} \times \alpha_{ijk} \times \alpha_{ijkm} \times k_{ijkm} \times d_{ijkm}) \quad \text{Equação 4.11}$$

onde :

- α_i , α_{ij} , α_{ijk} , α_{ijkl} , são os níveis de disparo das regras de cada quad-partição i , ij , ijk , ou $ijkl$, respectivamente;

- k_i (k_{ij} , k_{ijk} , k_{ijkl}), é igual a “1” se a partição i , (ou ij , ou ijk ou $ijkl$) existe e “0” caso contrário;

- d_i , d_{ij} , d_{ijk} , d_{ijkl} , são os conseqüentes (*singletons* ou combinações lineares) das regras existentes.

Algoritmo de Aprendizado

O aprendizado de sistemas neuro-fuzzy é geralmente dividido em duas partes: a identificação da estrutura e o ajuste dos parâmetros. O modelo NFHQ não foge a esta regra; entretanto, um único algoritmo realiza as duas tarefas de aprendizado.

O algoritmo de aprendizado do modelo NFHQ é realizado em sete passos correspondentes à numeração do fluxograma da Figura 4.19. Este algoritmo descreve o aprendizado de um sistema NFHQ com conseqüentes *singletons* ou conseqüentes de Sugeno de ordem 1 (combinações lineares de entradas).

Os parâmetros que definem os perfis das funções de pertinência dos antecedentes e dos conseqüentes são encarados como os “pesos fuzzy” dos sistemas neuro-fuzzy. Assim, no sistema NFHQ, os d_i 's e os parâmetros ‘ a ’ e ‘ b ’ são encarados como sendo os pesos fuzzy do modelo.

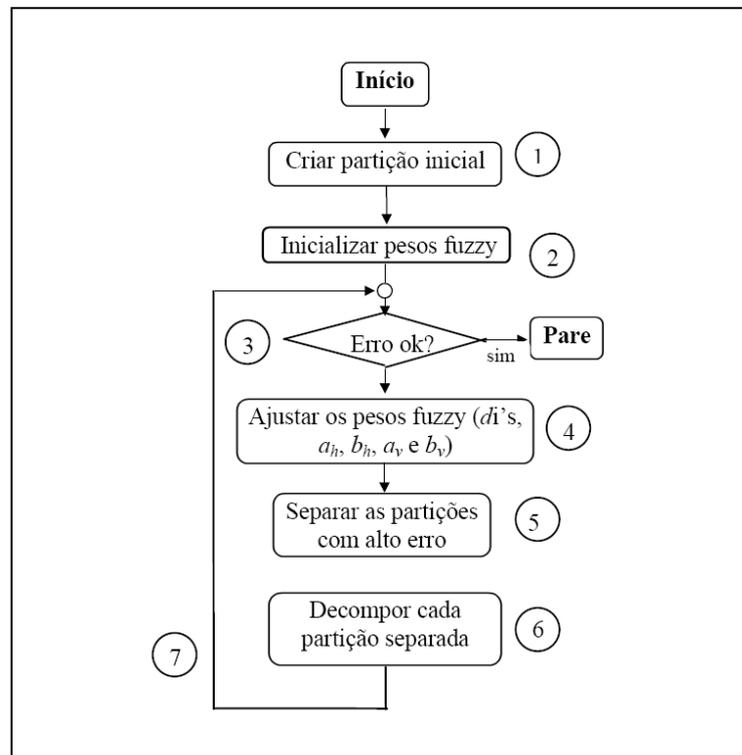


Figura 4.19 Algoritmo de Aprendizado do modelo NFHQ.

Os sete passos estão descritos abaixo:

1) **Cria-se a partição inicial** dividindo-se em quatro partes o espaço de entrada, utilizando dois conjuntos fuzzy, *alto* e *baixo*, para cada variável de entrada, x_h e x_v (entrada horizontal e entrada vertical). Neste passo é criada a 1a. célula *quadtree*, chamada de célula raiz.

2) **Cada parâmetro ajustável d_i** (peso fuzzy) é **inicializado** com a média dos valores-alvo dos padrões de saída que incidem sobre a quad-partição (Figura 4.18.b) de índice i . Por exemplo, para se calcular o valor inicial do peso d_4 , somam-se todos os valores-alvo dos padrões que incidem sobre o quadrante 4 e, em seguida, divide-se o valor encontrado pelo número de padrões que incidem sobre o quadrante 4. Esse processo se aplica aos

conseqüentes *singletons* ou, no caso de conseqüentes combinações lineares, ao parâmetro constante “*bias*”. O **parâmetro ‘b’** dos antecedentes das regras é inicializado com o valor igual à metade do intervalo do universo de discurso da variável de entrada da célula. O **parâmetro ‘a’** dos antecedentes das regras é inicializado, por escolha heurística, com o valor igual ao dobro do inverso daquele intervalo.

Exemplificando, sejam x_h e x_v as variáveis das entradas de particionamento da célula da primeira partição (raiz). Sejam, também, a_h , b_h , a_v e b_v os parâmetros que definem os perfis das funções de pertinência dos antecedentes. Sejam, ainda, I_h e I_v os intervalos dos universos de discurso das variáveis x_h e x_v , e

$LimI_h$, o limite inferior do universo de discurso da variável x_h ;

$LimI_v$, o limite inferior do universo de discurso da variável x_v ;

$LimSh$, o limite superior do universo de discurso da variável x_h ;

$LimSv$, o limite superior do universo de discurso da variável x_v .

Deste modo, os valores iniciais para a_h , b_h , a_v e b_v são:

$$a_h = \frac{2}{I_h} \quad \text{Equação 4.12}$$

$$b_h = \frac{(LimSh + LimI_h)}{2} \quad \text{Equação 4.13}$$

$$a_v = \frac{2}{I_v} \quad \text{Equação 4.14}$$

$$b_v = \frac{(LimSv + LimIv)}{2} \quad \text{Equação 4.15}$$

Sendo que,

$$I_h = (LimSh - LimIh) \quad \text{Equação 4.16}$$

$$I_v = (LimSv - LimIv) \quad \text{Equação 4.17}$$

3) O **erro total do sistema** é calculado para todo o conjunto de treinamento, de acordo com a expressão do erro médio quadrático dada, abaixo:

$$E_{rms} = \sqrt{\frac{1}{L} \sum_{n=1}^L (y_n - y_n^d)^2} \quad \text{Equação 4.18}$$

Onde L é o número de padrões no conjunto de treinamento e y_n e y_n^d são, respectivamente, o valor de saída do sistema NFHQ e o valor desejado de saída para o padrão de índice “n”.

Caso este erro esteja abaixo do mínimo desejado, o processo de aprendizado pára; caso contrário, o processo de aprendizado continua com o passo 4.

4) Este passo, referente ao **ajuste dos pesos fuzzy**, pode ser implementado segundo as seguintes opções:

a) O método do “*Gradient Descent*” ajusta apenas os pesos fuzzy *di*'s (conseqüentes *singleton* ou pesos das combinações lineares). Neste caso, é utilizado o particionamento fixo, não havendo ajuste dos perfis dos antecedentes;

b) O método dos mínimos quadrados ordinários (MQO) - vide apêndice 3 – ajusta apenas os pesos fuzzy *di*'s (conseqüentes *singleton* ou pesos das combinações lineares). Neste caso também é utilizado o particionamento fixo;

c) O MQO ajusta os pesos fuzzy *di*'s e um método de “*Gradient Descent*” ajusta os parâmetros *ah,av* e *bv,bh* das funções de pertinência dos antecedentes. Neste caso tem-se o que se chama de particionamento adaptativo.

d) Um método de “*Gradient Descent*” ajusta tanto os pesos fuzzy *di*'s quanto os parâmetros *ah,av* e *bv,bh* das funções de pertinência dos antecedentes. Neste caso tem-se também o particionamento adaptativo.

5) Neste caso, cada quad-partição é avaliada em relação a sua contribuição para o erro total e em relação ao erro mínimo aceitável. **Cada quad-partição com erro inaceitável é separada.** A avaliação do erro gerado pelo conjunto de dados que incidem sobre a partição *ij* é calculada pela expressão:

$$E_{ms}^{ij} = \sqrt{\frac{1}{L} \sum_{n=1}^L \alpha_i^n \cdot \alpha_{ij}^n \cdot (y_n - y_n^d)^2} \quad \text{Equação 4.19}$$

Onde α_i^n , e α_{ij}^n são os níveis de disparo das regras para o padrão ‘*n*’.

6) Neste passo é efetuada a **decomposição das partições separadas**. Para cada quadpartição separada é realizado um processo de decomposição da seguinte forma: Aloca-se um novo nó (nova célula) na estrutura *quadtree* para a quadpartição separada (ela é dividida em 4). Deste modo, são geradas quatro novas funções de pertinência que constituirão as quatro partições recém-criadas. Isto é feito independentemente do tipo de consequente empregado pelo modelo. É o caso de se trabalhar com consequentes de um só tipo (*singletons* ou combinações lineares). A Figura 4.20 ilustra graficamente este processo.

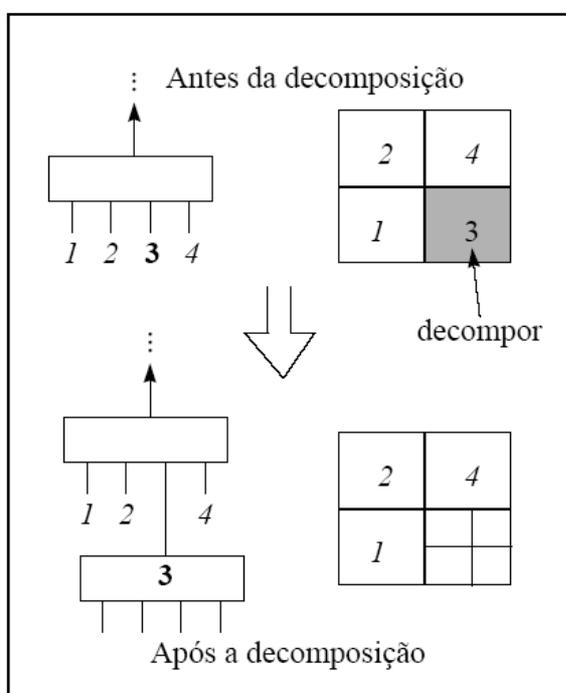


Figura 4.20 Decomposição das partições.

7) Voltar ao passo “3” para continuar o aprendizado.

Taxa de decomposição

De forma a se limitar o crescimento indefinido da estrutura do sistema, cria-se um parâmetro de aprendizado denominado **taxa de decomposição** (δ). Este parâmetro é adimensional e impede que o processo de decomposição seja realizado indefinidamente. Seu valor fica geralmente entre 0,001 e 0,05 e é comparado constantemente, durante o aprendizado, com a população de padrões que incidem sobre um determinado quadrante. Quando a densidade populacional de padrões de um quadrante (razão entre o número de padrões que incidem sobre o quadrante e o número total de padrões) cai abaixo da taxa de decomposição, este quadrante não deve ser decomposto, o que limita o crescimento da estrutura. Segundo [Error! Bookmark not defined.], este parâmetro deve variar com o número de padrões a ser aprendidos pelo sistema.

Extração de Regras

Uma das grandes vantagens dos sistemas neuro-fuzzy é a possibilidade de se extrair conhecimento, sob o formato de regras fuzzy, a partir de um conjunto de dados. Os modelos neuro-fuzzy discutidos nesta tese permitem a execução de tal tarefa. O processo para extração de regras pode ser dividido nos seguintes passos:

- 1) Treinar o sistema neuro-fuzzy a partir do conjunto de dados, gerando sua estrutura e ajustando seus parâmetros (antecedentes e consequentes);

2) Uma vez obtida a estrutura em forma de árvore quaternária, executar um caminhamento nesta árvore, visitando cada célula do sistema NFHQ;

No instante da visita de cada célula, extrair os dados nela contidos, referentes às regras fuzzy hierárquicas.

4.2.4.3. Modelo NFHB

O sistema NFHB – Neuro-Fuzzy Hierárquico BSP – é um sistema que utiliza o particionamento recursivo BSP (*Binary Spacing Partitioning*) para o espaço de entrada.

A diferença principal entre o modelo NFHQ e o NFHB está na forma de particionamento empregada no espaço de entrada.

A Figura 4.21 ilustra a célula neuro-fuzzy BSP e a Figura 4.22 mostra um exemplo de uma arquitetura do sistema NFHB.

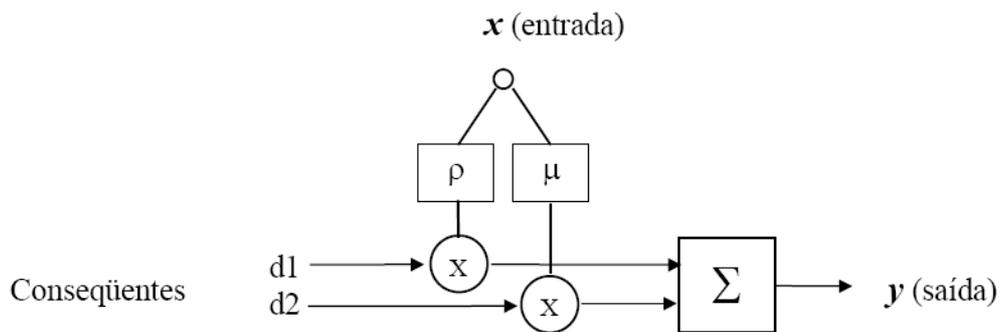


Figura 4.21 Célula Neuro-Fuzzy BSP.

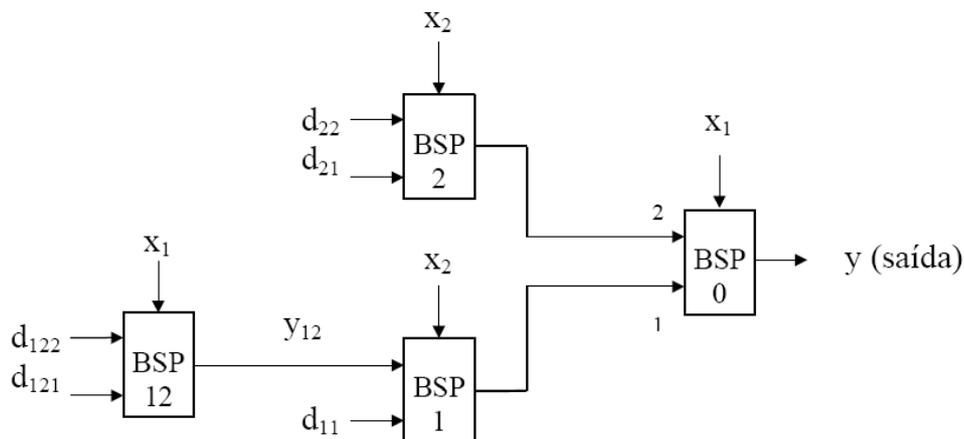


Figura 4.22 Exemplo de um sistema NFHB.

Sob certo ponto de vista, a classe dos modelos NFHQ está contida na classe dos modelos NFHB, uma vez que estes últimos podem emular qualquer arquitetura NFHQ. A base de regras hierárquicas dos modelos NFHQ, embora mais compactas, têm sua equivalência nos modelos NFHB. De uma forma geral, pode-se dizer que os modelos NFHB são mais flexíveis que os modelos NFHQ e tendem a ter uma estrutura mais simples.

Conforme foi apresentado, o sistema NFHB possui apenas uma saída. Para que o sistema NFHB seja utilizado como um classificador de padrões, é preciso definir um critério de faixas de valores (janelas) para a saída do sistema. Cada faixa de valores representa uma classe de padrões do banco de dados. Dessa forma, para se descobrir a classe do padrão, é necessário, a partir do valor numérico na saída do sistema, inferir a que classe o padrão pertence.

A definição de faixa de valores não é um processo trivial para a tarefa de classificação de padrões. É necessário um especialista, que conheça a estrutura dos dados, para definir em que faixas de valores, cada uma das classes da base de dados será melhor

caracterizada. O que se busca em um sistema classificador de padrões, é a capacidade do mesmo descobrir, automaticamente, a que classe o padrão pertence, sem a necessidade de se aplicar à saída do sistema a um módulo de inferência.

Para suprir essa necessidade, o modelo NFHB-Invertido [2], [3], [4], [5] e [162] é um sistemas que possui o número de saídas igual ao número de classes dos padrões da base de dados. Dessa forma, evita-se o uso de inferir a que classe o padrão pertence através do critério de faixas de valores, uma vez que o sistema por si só é capaz de informar a classe do padrão.

4.2.4.4. Modelo NFHB-Invertido

O modelo NFHB-Invertido [2], [3], [4], [5] e [162] é um sistema neuro-fuzzy desenvolvido especificamente para a tarefa de classificação de padrões. As regras geradas por esse novos sistema têm maior interpretabilidade que as geradas pelo sistema NFHB, pois as suas estruturas, por si só, já caracterizam o conjunto de regras fuzzy (conhecimento). Além disso, o modelo NFHB-Invertido dispensa a criação de faixas de valores para definir as classes dos padrões como no modelo NFHB.

O modelo NFHB-Invertido utiliza a arquitetura NFHB, apresentada na seção anterior, para a criação da estrutura ou fase de aprendizado/treinamento. Em seguida, para a fase de teste/validação do modelo, a arquitetura NFHB é invertida passando a ter várias saídas, ao invés da única saída do modelo original. Essas saídas são então ligadas a outras células que determinam a classe a que o padrão pertence, evitando-se assim a necessidade de se criar faixas de valores.

Célula Básica NFHB-Invertida

Uma célula básica NFHB-Invertida é um mini sistema neuro-fuzzy que realiza um particionamento fuzzy e binário em um determinado espaço, segundo as funções de pertinência descritas pela Figura 4.23. A célula NFHB-Invertida gera duas saídas precisas (*crisp*) após um processo de *defuzzificação*.

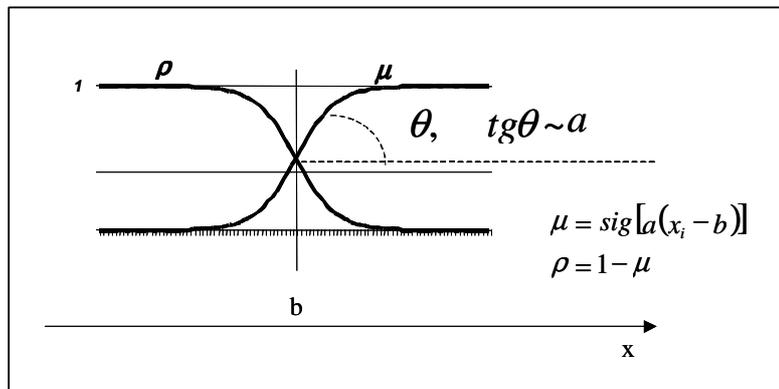


Figura 4.23 Exemplo de perfil das funções de pertinência da célula BSP-Invertida.

A Figura 4.24 mostra a representação básica da célula NFHB-Invertida e a Figura 4.25 ilustra o interior da célula NFHB-Invertida.

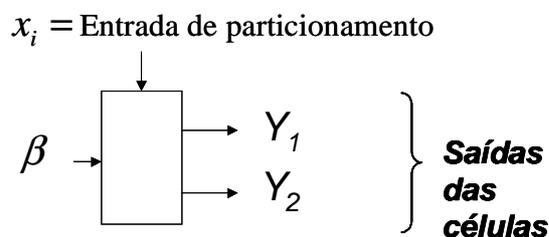


Figura 4.24 Célula NFHB-Invertida.

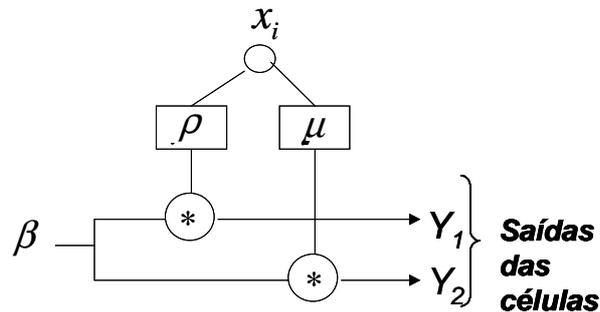


Figura 4.25 Interior da Célula NFHB-Invertida.

As saídas (*crisp*) de uma célula NFHB-Invertida são dadas pelas Equação 4.20 e Equação 4.21.

$$y_1 = \frac{\beta * \rho(x)}{\rho(x) + \mu(x)} \quad \text{Equação 4.20}$$

$$y_2 = \frac{\beta * \mu(x)}{\rho(x) + \mu(x)} \quad \text{Equação 4.21}$$

onde β corresponde a um dos dois casos possíveis abaixo:

à entrada da primeira célula: caso em que $\beta = 1$, onde o valor '1' na entrada da primeira célula representa todo o espaço de entrada, ou seja, todo o universo de discurso da variável x_i que está sendo utilizada como entrada da célula.

à saída de um estágio de nível anterior: caso em que $\beta = y_j$, onde y_j representa uma das duas saídas de uma célula genérica 'j', cujo valor é calculado também pela Equação 4.20 ou pela Equação 4.21.

Na célula NFHB-Invertida básica, a função de pertinência (μ) *alto* foi implementada por uma sigmóide e a função de pertinência (ρ) *baixo* por seu complemento a um [$1 - \mu(x)$]. A utilização do complemento a um leva a uma simplificação no procedimento de *defuzzificação* realizado pela Equação 4.20 e Equação 4.21, pois a soma dada pela Equação 4.22, abaixo, é igual a 1 para quaisquer valores de 'x'.

$$\rho(x) + \mu(x) = 1 \quad \text{Equação 4.22}$$

Devido a este fato as equações de saída ficam simplificadas para:

$$y_1 = \beta * \rho(x) \quad \text{Equação 4.23}$$

$$y_2 = \beta * \mu(x) \quad \text{Equação 4.24}$$

Algoritmo de Aprendizado do sistema NFHB-Invertido

O algoritmo de aprendizado do modelo NFHB-Invertido é igual ao algoritmo de aprendizado do modelo NFHB. Para o modelo NFHB-Invertido utiliza-se o método dos Mínimos Quadrados Ordinários (MQO) para calcular os conseqüentes (*di's*) e o *Back Propagation* para calcular os parâmetros (*a* e *b*) dos antecedentes das regras. Após a criação da estrutura, o modelo NFHB é invertido obtendo-se a arquitetura NFHB-Invertida.

Arquitetura NFHB-Invertida

A Figura 4.26 mostra um exemplo de uma arquitetura NFHB original obtida na fase de treinamento do sistema, para uma base de dados que possui três classes distintas, e a Figura 4.27 mostra a seu respectivo particionamento. A Figura 4.28 mostra a arquitetura NFHB-Invertida.

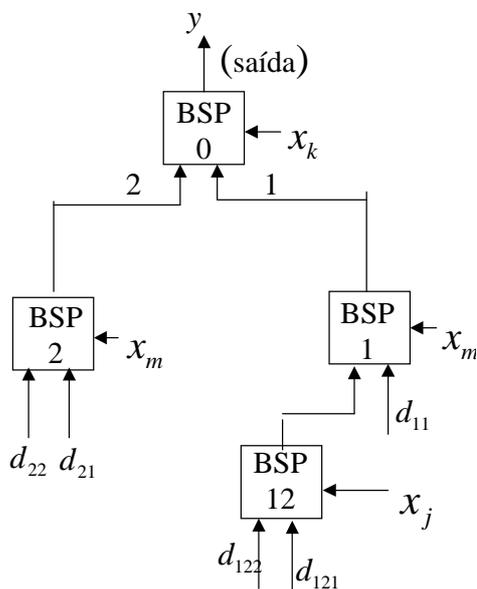


Figura 4.26 Arquitetura NFHB.

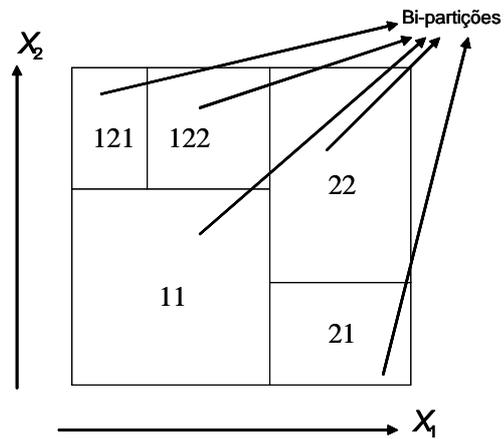


Figura 4.27 Particionamento do espaço de entrada do sistema NFHB.

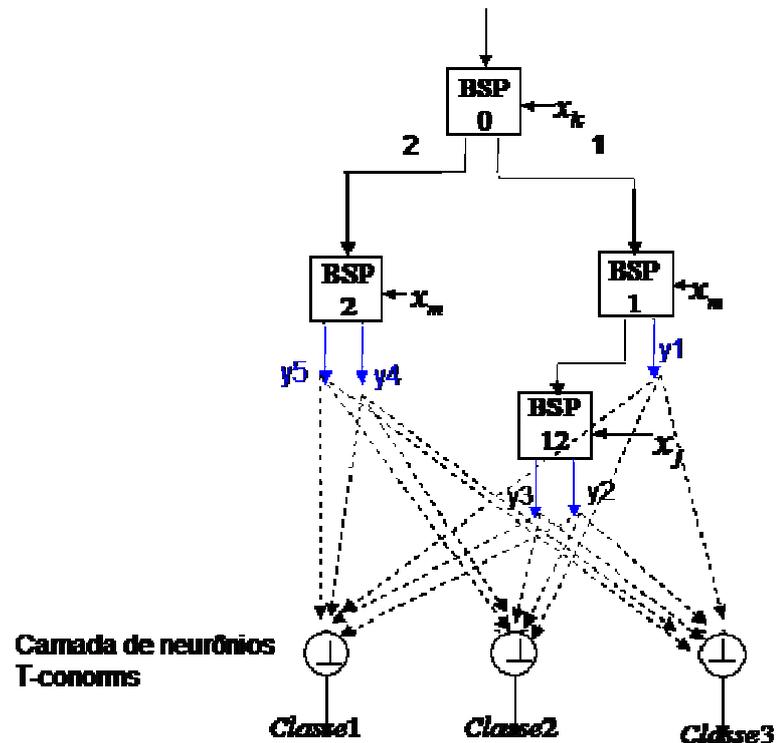


Figura 4.28 Arquitetura NFHB – Invertida.

Para que o sistema NFHB possa classificar os padrões dessa base de dados que possui três classes, é necessário definir três faixas de valores para enquadrar a saída do sistema. Se a saída do sistema está entre os valores $k1$ e $k2$ (*Faixa1*), então diz-se que o padrão pertence à classe 1, se a saída do sistema está entre os valores $k2$ e $k3$ (*Faixa2*), então diz-se que o padrão pertence à classe 2 e se a saída do sistema está compreendida entre os valores $k3$ e $k4$ (*Faixa3*), então diz-se que a saída do sistema pertence à classe 3.

Dessa forma, para descobrir a classe a que o padrão pertence, basta aplicar o padrão no sistema NFHB, obter a saída e verificar em que faixa de valores a saída do sistema se encontra, para em seguida descobrir a qual classe o padrão pertence.

O critério de faixas de valores não é totalmente eficaz para a tarefa de classificação de padrões. Tomando como exemplo ainda a arquitetura NFHB, mostrada pela Figura 4.26, para uma base de dados com 3 classes distintas (*classe1*, *classe2* e *classe3*). Se um dado padrão *P* dessa base de dados pertencer à *classe1* e for classificado como pertencente à *classe3*, ou seja, se a saída do sistema para esse padrão *P* estiver contida entre os valores k_3 e k_4 (*Faixa3*), o erro de classificação será dado por: $Erro=(Faixa3 - Faixa1)$. Porém se o mesmo padrão *P* fosse classificado como pertencente à *classe2*, o erro de classificação seria dado por: $Erro=(Faixa2 - Faixa1)$. Através dessa análise pode-se verificar que se o padrão *P* fosse classificado como pertencente à *classe3*, o erro de classificação seria maior do que se o padrão *P* fosse classificado como pertencente à *classe2*, pois $(Faixa2 - Faixa1) < (Faixa3 - Faixa1)$. Na verdade essa afirmação não faz sentido, pois o erro do sistema em classificar um padrão *P* pertencente à *classe1*, como pertencente à *classe3* ou à *classe2*, deve ser exatamente igual, não favorecendo nenhuma das classes.

Na arquitetura NFHB-Invertida, Figura 4.28, o sistema passa a ter várias saídas, e essas saídas são agora conectadas às células T-conorms que definem as classes. A saída do sistema (*classe1*, *classe2*, ou *classe3*) com o maior valor, definirá a classe a que pertence o padrão que foi apresentado ao sistema.

O particionamento correspondente ao sistema NFHB-Invertido é o mesmo do modelo NFHB mostrado pela Figura 4.27.

As saídas das células folhas do sistema da Figura 4.28 são dadas pelo seguinte conjunto de equações:

$$y1 = \rho_0 \cdot \rho_1 \quad \text{Equação 4.25}$$

$$y2 = \rho_0 \cdot \mu_1 \cdot \rho_{12} \quad \text{Equação 4.26}$$

$$y3 = \rho_0 \cdot \mu_1 \cdot \mu_{12} \quad \text{Equação 4.27}$$

$$y4 = \mu_0 \cdot \rho_2 \quad \text{Equação 4.28}$$

$$y5 = \mu_0 \cdot \mu_2 \quad \text{Equação 4.29}$$

Nas equações descritas acima já se levou em consideração a simplificação causada pelo uso das funções de pertinência complementares ($\rho + \mu = 1$) no método de *defuzzificação* das saídas de cada subsistema neuro-fuzzy.

Uma vez calculada a saída de cada célula folha do sistema NFHB-Invertido, é feita a ligação dessas células folhas com os neurônios *T-conorms*, de modo a se obter a saída final do sistema classificador de padrões.

Estratégia de Conexão das Células Folhas com Neurônios T-conorms

Para utilizar o modelo NFHB-Invertido é necessário definir como as saídas das células folhas finais serão conectadas aos neurônios *T-conorms*. Cada neurônio *T-conorm* está associado a uma classe específica, conforme pode ser observado no exemplo descrito pela Figura 4.28, onde existem três classes distintas, e conseqüentemente, três neurônios *T-conorms*.

As ligações das células folhas com os neurônios *T-conorms* são feitas, inicialmente, conectando-se todas as células folhas com todos os neurônios *T-conorms*, conforme o número de classes em que está organizada a base de dados. Após esta conexão, é necessário

estabelecer pesos para essas ligações (arcos). Para a atribuição desses pesos, foi utilizado o método dos Mínimos Quadrados mostrado a seguir.

Método dos Mínimos Quadrados para ajuste dos pesos dos arcos que ligam as saídas das células folhas (finais) aos neurônios T-conorms.

A política adotada para ajustar os pesos das conexões das células folhas aos neurônios T-conorms é definida da seguinte forma: apresentam-se todos os padrões de treinamento para o modelo NFHB – Invertido e, para cada padrão apresentado, tem-se um grau de ativação para cada saída das células folhas do sistema (caminho).

Para cada saída das células folhas (caminhos) têm-se um conjunto de valores, que representa o grau de ativação de cada padrão para aquele caminho, conforme mostrado na Figura 4.29. Desta forma, podemos montar uma matriz de ordem [número de padrões x número de caminhos], onde cada elemento dessa matriz representa o grau de ativação de um padrão para um determinado caminho. Essa matriz é denominada de matriz A.

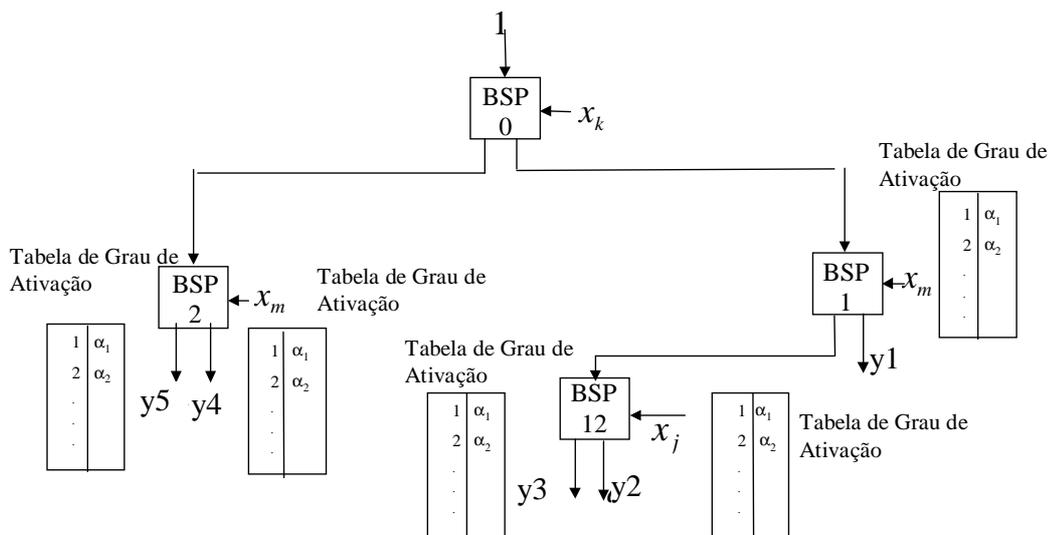


Figura 4.29 Arquitetura NFBH – Invertida com as tabelas de graus de ativação de todos os padrões para todos os caminhos. A coluna da esquerda de cada tabela representa o número do padrão, e a coluna da direita representa o grau de ativação do respectivo padrão para um dado caminho.

Como todos os caminhos estão conectados com todos os neurônios *T-conorms*, o problema é descobrir os pesos dos arcos que ligam os caminhos aos neurônios *T-conorms*.

É denominada de W a matriz de ordem [número de caminhos x número classes], onde cada elemento (dessa matriz) representa o peso dos arcos que ligam os caminhos aos neurônios.

Para cada padrão do conjunto de treinamento, sabe-se a qual classe o mesmo pertence, tendo-se portanto, uma matriz de ordem [número de padrões x número de classes], onde cada elemento dessa matriz pode assumir um dos valores inteiros 0 ou 1. O valor 0 significa que o padrão não pertence à classe enquanto que o valor 1 significa que o padrão pertence à classe. Essa matriz representa a saída desejada do sistema. Denomina-se essa matriz de matriz B .

Desta forma pode-se montar o seguinte sistema de equações:

$$AW=B \qquad \text{Equação 4.30}$$

Esse sistema de equações representa o problema dos mínimos quadrados e a busca da melhor solução para os elementos do vetor W , que minimiza o quadrado $|AW-B|^2$, é o objetivo do método dos mínimos quadrados. Denomina-se de W^* a matriz que atende a este requisito.

O sistema de equações dado pela Equação 4.30 é chamado de sistema de equações normais. Para encontrar os valores de W^* , aplica-se o processo da pseudo-inversa:

$$W^* = (A^T \cdot A)^{-1} \cdot A^T \cdot B \qquad \text{Equação 4.31}$$

onde A^T é a transposta da matriz A ; a matriz $(A^T.A)^{-1}$ é conhecida como pseudo-inversa de A , contanto que $(A^T.A)^{-1}$ seja não singular. Assim, os valores da matriz W^* podem ser encontrados simplesmente pela solução do sistema de equações lineares dado por:

$$(A^T.A).W^* = A^T.B \quad \text{Equação 4.32}$$

Para solucionar a Equação 4.32, o modelo NFHB-Invertido emprega o método iterativo de Gauss-Seidel [163], tendo em vista que a solução analítica passa pelo cálculo da inversa da matriz A , que, embora rápido, pode levar a uma quase singularidade nessa matriz, causando uma possível instabilidade.

Cálculo das Saídas Finais do Modelo NFHB-Invertido

Após ter definido a estratégia de como as células folhas foram conectadas aos neurônios *T-conorms*, e como foram atribuídos os pesos dessas ligações, é necessário definir que operadores *T-conorms* serão utilizados para se obter a saída final do modelo NFHB-Invertido.

Todos as saídas das células folhas foram conectadas a todos neurônios *T-conorms*, como pode ser observado pela Figura 4.28. Cada uma dessas saídas é multiplicada pelo respectivo peso da sua ligação com o neurônio *T-conorm*. O passo seguinte é definir como deve ser feito o tratamento de todas essas entradas dos neurônios *T-conorms* que são provenientes das células folhas.

A Figura 4.30 mostra uma estrutura NFHB-Invertida para uma base de dados composta por três classes distintas, juntamente com a ligação de duas saídas de células folhas, y_2 e y_5 , com o intuito de ilustrar a atribuição de pesos para as ligações. W_{21} , W_{22} e W_{23} , são os pesos das ligações da saída y_2 da célula folha com os neurônios *T-conorms* *classe1*, *classe2* e *classe3*, respectivamente. Da mesma forma, W_{51} , W_{52} e W_{53} , são os pesos das ligações da saída y_5 da célula folha com os neurônios *T-conorms* *classe1*, *classe2* e *classe3*, respectivamente.

As equações abaixo mostram como são calculadas todas as entradas dos neurônios *T-conorms* para um determinado padrão. Não foram mostradas todas as ligações na Figura 4.30, pois isto dificultaria o entendimento da mesma.

$$\mathbf{T-conorm\ classe1} = y_1 * w_{11} \oplus y_2 * w_{21} \oplus y_3 * w_{31} \oplus y_4 * w_{41} \oplus y_5 * w_{51} \quad \text{Equação 4.33}$$

$$\mathbf{T-conorm\ classe2} = y_1 * w_{12} \oplus y_2 * w_{22} \oplus y_3 * w_{32} \oplus y_4 * w_{42} \oplus y_5 * w_{52} \quad \text{Equação 4.34}$$

$$\mathbf{T-conorm\ classe3} = y_1 * w_{13} \oplus y_2 * w_{23} \oplus y_3 * w_{33} \oplus y_4 * w_{43} \oplus y_5 * w_{53} \quad \text{Equação 4.35}$$

Onde:

y_1 , y_2 , y_3 , y_4 , e y_5 são as saídas das células folhas;

W_{11} , W_{12} , W_{13} , W_{21} , W_{22} , W_{23} , W_{31} , W_{32} , W_{33} , W_{41} , W_{42} , W_{43} , W_{51} , W_{52} e W_{53} são os pesos das ligações entre as células folhas e os neurônios *T-conorms*;

\oplus é a operação *T-conorm*, soma limitada [164] utilizada pelo neurônio *T-conorm* para processar a saída final do sistema NFHB-Invertido.

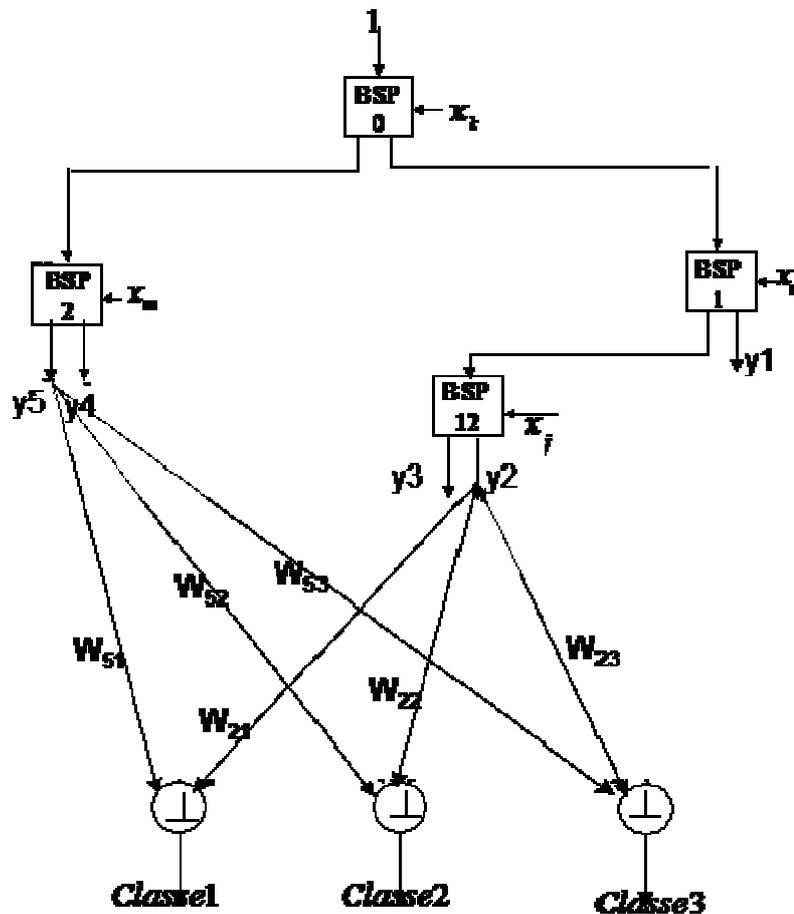


Figura 4.30 Arquitetura NFHB-Invertida mostrando os pesos das ligações das saídas y_2 e y_5 das células folhas com os neurônios *T-conorms* classe1, classe2 e classe3.

O padrão aplicado ao sistema NFHB-Invertido irá pertencer à classe correspondente à maior saída de todos os neurônios *T-conorms*.

4.2.4.5. Modelo NFHB-Class

O modelo NFHB-Class [2], [3], [4], [5], é uma segunda adaptação do modelo NFHB para problemas de classificação. A diferença principal entre o modelo NFHB-

Invertido e o modelo NFHB-Class está na maneira de como é obtida a estrutura do sistema. No modelo NFHB-Invertido, a estrutura é criada pelo modelo NFHB original, para em seguida obter-se o sistema classificador de padrões. Já o modelo NFHB-Class gera sua própria estrutura, evitando assim a necessidade de utilização de outro modelo.

O modelo NFHB-Class utiliza a célula básica NFHB-Invertida, descrita na seção anterior, e cria uma nova estrutura hierárquica já invertida. A arquitetura NFHB-Class é mostrada a seguir.

Arquitetura NFHB-Class

O modelo NFHB-Class, ao contrário do modelo NFHB-Invertido, não utiliza a estrutura criada pelo modelo NFHB original. O modelo NFHB-Class, é capaz de criar a sua própria estrutura, automaticamente, para a tarefa específica de classificação de padrões, e em seguida, de posse da sua estrutura, é capaz de extrair regras que possam explicar a base de dados.

O modelo NFHB-Class utiliza a célula básica NFHB-Invertida. A Figura 4.31.a mostra um exemplo de uma arquitetura NFHB-Class, obtida na fase de treinamento do sistema, para uma base de dados que possui três classes distintas; e o seu respectivo particionamento é ilustrado pela Figura 4.31.b. Vale ressaltar que a estrutura foi criada automaticamente invertida, sem a necessidade da utilização do modelo NFHB original para a fase de treinamento.

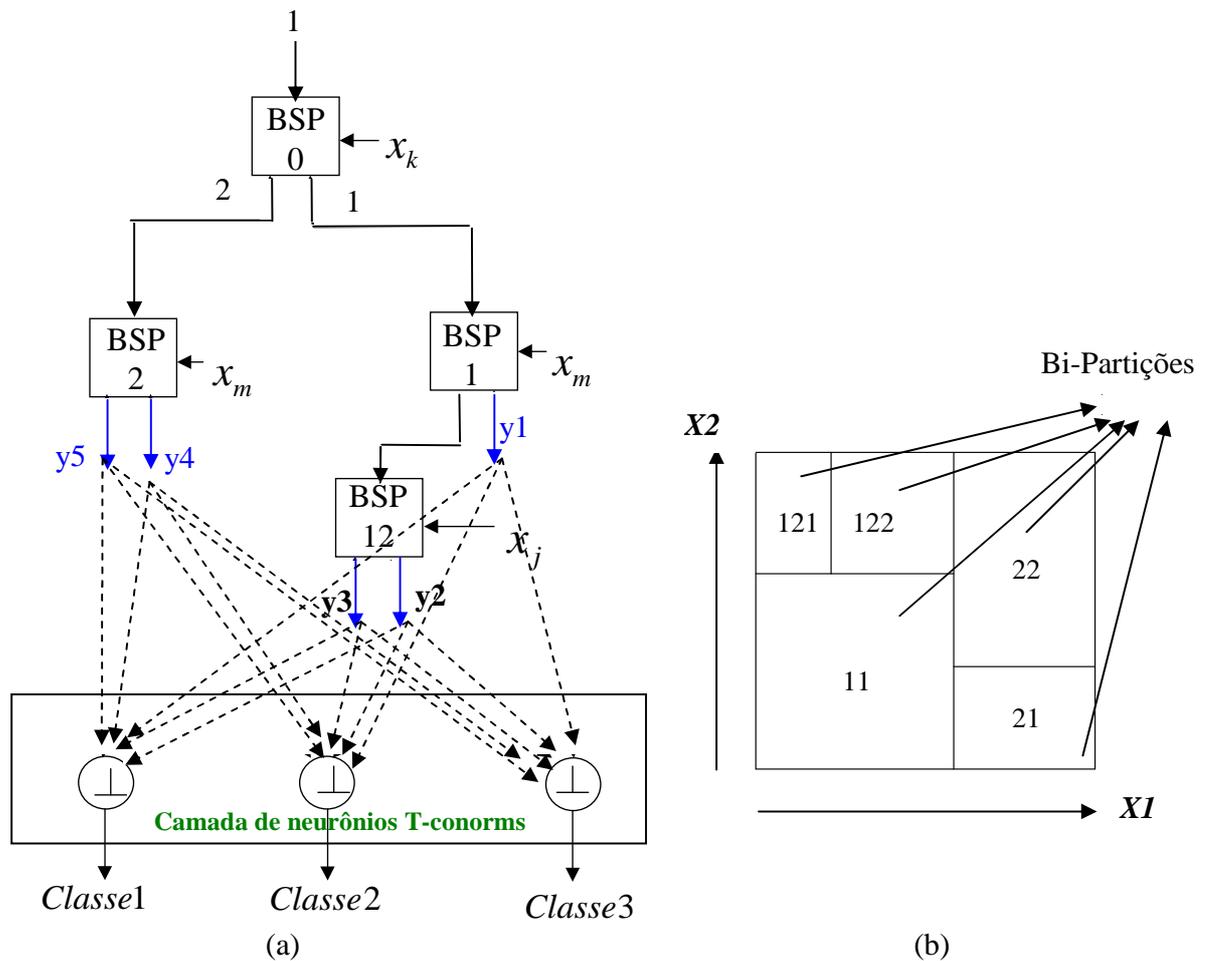


Figura 4.31 (a) Arquitetura NFHB-Class. (b) Particionamento do espaço de entrada do sistema NFHB-Class.

Embora a Figura 4.31.a seja idêntica à Figura 5.5, as estruturas dos modelos NFHB-Invertido e NFHB-Class são diferentes, conforme será visto no capítulo 8, onde é descrito o estudo de casos.

Da mesma forma que o modelo NFHB-Invertido descrito no capítulo 5, na arquitetura NFHB-Class (Figura 4.31.a), o sistema possui várias saídas, que são conectadas às células *T-conorms* que definem as classes. A saída do sistema (*classe1*, *classe2*, ou *classe3*) com maior valor define a classe a que pertence o padrão apresentado ao sistema.

As saídas das células folhas do sistema da Figura 4.31.a estão listadas a seguir:

$$y1 = \rho_0 \cdot \rho_1 \quad \text{Equação 4.36}$$

$$y2 = \rho_0 \cdot \mu_1 \cdot \rho_{12} \quad \text{Equação 4.37}$$

$$y3 = \rho_0 \cdot \mu_1 \cdot \mu_{12} \quad \text{Equação 4.38}$$

$$y4 = \mu_0 \cdot \rho_2 \quad \text{Equação 4.39}$$

$$y5 = \mu_0 \cdot \mu_2 \quad \text{Equação 4.40}$$

Após ter-se calculado a saída de cada célula folha do sistema, é feita a ligação dessas células folhas com os neurônios *T-conorms*, para que possa ser obtida a saída final do sistema classificador de padrões.

Algoritmo de Aprendizado NFHB-Class

O processo de aprendizado do modelo NFHB-Class é efetuado em sete passos, conforme apresentado no fluxograma da Figura 4.32.

Os parâmetros que definem os perfis das funções de pertinência (parâmetros ‘*a*’ e ‘*b*’) dos antecedentes são parâmetros ajustáveis do modelo, sendo encarados como os pesos fuzzy do sistema neuro-fuzzy. Vale ressaltar que no modelo NFHB-Class não existem mais os parâmetros ‘*di*’ do modelo NFHB original que definiam os conseqüentes *singletons*. No

modelo NFHB-Class é necessário ajustar os pesos dos arcos que ligam as células folhas aos neurônios *T-conorms*.

A Figura 4.32 ilustra o algoritmo de aprendizado.

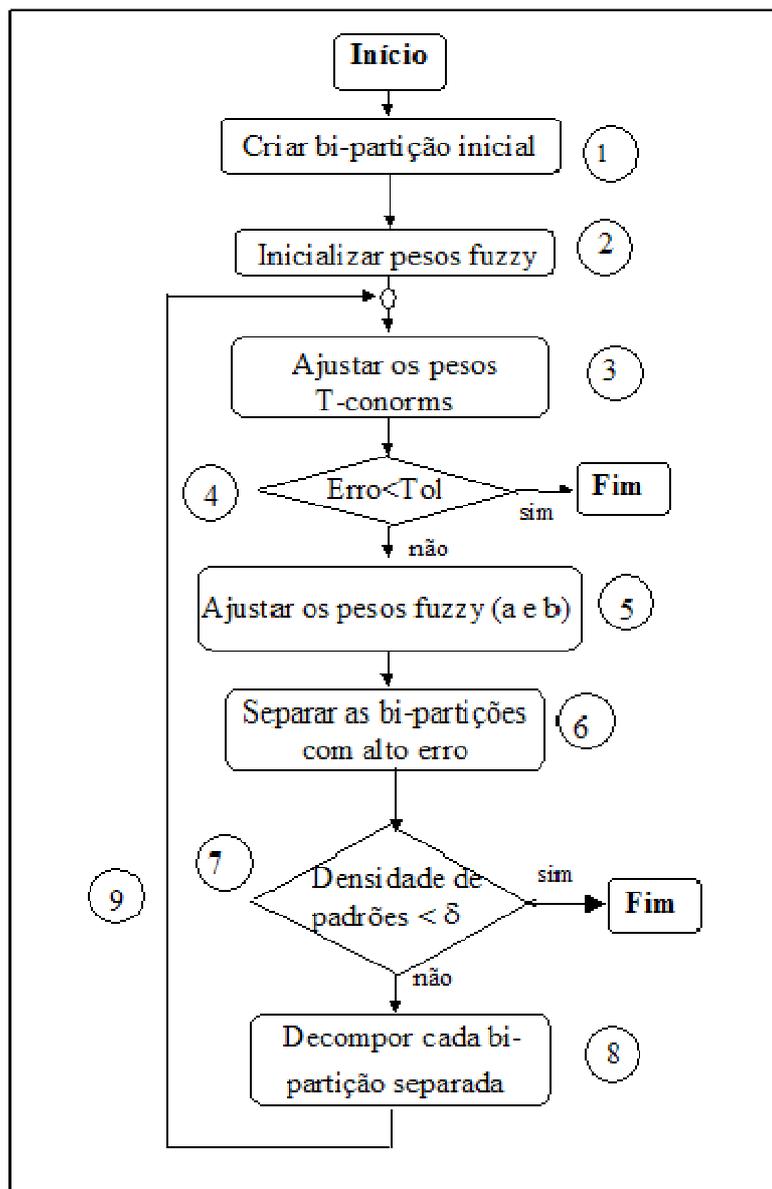


Figura 4.32 Algoritmo de aprendizado do modelo NFHB-Class.

Os nove passos do algoritmo de aprendizado estão descritos abaixo:

Cria-se a bipartição inicial dividindo-se em duas partes o espaço de entrada, utilizando-se dois conjuntos fuzzy, *alto* e *baixo*, para a variável de entrada x . Neste passo é criada a primeira célula NFHB-Invertida, chamada de célula raiz.

O parâmetro ' b ' dos antecedentes das regras é inicializado com o valor igual à metade do intervalo do universo de discurso da variável de entrada da célula. O parâmetro ' a ' dos antecedentes das regras é inicializado, por escolha heurística, com o valor igual ao dobro do inverso do universo de discurso daquele intervalo. As Equação 4.41 e Equação 4.42 ilustram a inicialização de ' a ' e ' b '.

$$a = 2 / (LimS - LimI) \quad \text{Equação 4.41}$$

$$b = (LimS + LimI) / 2 \quad \text{Equação 4.42}$$

onde : $LimI$ e $LimS$ são, respectivamente, os limites inferior e superior do universo de discurso da variável de entrada do particionamento da célula.

Nesta etapa, os pesos dos arcos que ligam as células folhas aos neurônios *T-conorms* são ajustados pelo MQO (Método dos Mínimos Quadrados Ordinários), conforme descrito anteriormente. Após o cálculo dos pesos é computado o valor de saída cada neurônio *T-conorm* do sistema NFHB-Class.

O erro total do sistema é calculado para todo o conjunto de treinamento, de acordo com a expressão do erro médio quadrático:

$$E_{RMS} = \sqrt{\frac{1}{L} \sum_{n=1}^L \sum_{c=1}^{\#classes} (y_{nc} - y_{nc}^d)^2} \quad \text{Equação 4.43}$$

onde:

L é o número de padrões do conjunto de treinamento;

y_{nc} é o valor de saída do neurônio *T-conorm* que representa a classe ‘c’ para o padrão de índice ‘n’;

y_{nc}^d é o valor desejado de saída do neurônio *T-conorm* que representa a classe ‘c’ para o padrão de índice ‘n’.

Exemplificando, seja uma base de dados com 3 classes distintas: classe 1, classe 2 e classe 3. Sejam também j e k padrões de índices ‘j’ e ‘k’ dessa base de dados que pertencem às classe 2 e 3, respectivamente. Desta forma, têm-se as saídas desejadas do sistema para o padrão j dadas por: $y_{j1}^d = 0$; $y_{j2}^d = 1$, $y_{j3}^d = 0$; para o padrão k são dadas por: $y_{k1}^d = 0$; $y_{k2}^d = 0$, $y_{k3}^d = 1$. Deste modo, o erro do sistema com relação a esses dois padrões de índice ‘j’ e ‘k’ é dado pela Equação 4.44:

$$E_{RMS} = \sqrt{\frac{1}{2} \left[\left(y_{j1} - y_{j1}^d \right)^2 + \left(y_{j2} - y_{j2}^d \right)^2 + \left(y_{j3} - y_{j3}^d \right)^2 + \left(y_{k1} - y_{k1}^d \right)^2 + \left(y_{k2} - y_{k2}^d \right)^2 + \left(y_{k3} - y_{k3}^d \right)^2 \right]} \quad \text{Equação 4.44}$$

Para se calcular o erro total do sistema, basta generalizar o erro para todos os padrões da base de dados, conforme a Equação 4.43. Caso este erro esteja abaixo do mínimo desejado, o processo de aprendizado é encerrado; caso contrário, o processo de aprendizado continua com o passo 5.

Este passo referente ao ajuste dos pesos fuzzy pode ser efetuado mediante 2 algoritmos diferentes:

Manter os parâmetros ' a ' e ' b ' das funções de pertinência dos antecedentes sem alteração. Neste caso, é utilizado o particionamento fixo, não havendo ajuste dos perfis dos antecedentes.

Um método de “Gradiente Descendente” para ajustar os parâmetros ' a ' e ' b ' das funções de pertinência dos antecedentes. Neste caso tem-se um particionamento adaptativo.

Diferente do algoritmo de aprendizado mostrado para o modelo NFHB, que ajusta os pesos fuzzy ' d_i ' (conseqüentes *singleton* ou combinações lineares), o Modelo NFHB-Class só ajusta os pesos dos parâmetros ' a ' e ' b ' das funções de pertinência dos antecedentes, pois a sua célula básica, célula NFHB-Invertida, não possui ' d_i '.

Nesta etapa, cada bi-partição é avaliada em relação à sua contribuição para o erro total e em relação ao erro mínimo aceitável. Cada bi-partição com erro inaceitável é separada e a avaliação do erro gerado pelo conjunto de dados que incidem sobre a partição ij é calculada pela Equação 4.45.

$$E_{RMS} = \sqrt{\frac{1}{L} \sum_{n=1}^L \alpha_i^n \alpha_{ij}^n \sum_{c=1}^{\#classes} (y_{nc} - y_{nc}^d)^2}$$

Equação 4.45

onde α_i^n , e α_{ij}^n são os níveis de disparo das regras para o padrão 'n'.

Para limitar o crescimento indefinido da estrutura do sistema, é utilizado um parâmetro de aprendizado denominado **taxa de decomposição (δ)**. Este parâmetro é adimensional e atua impedindo que o processo de decomposição seja realizado indefinidamente. Seu valor situa-se, geralmente entre, 0,001 e 0,05. Ele é comparado constantemente, durante o aprendizado, com a população de padrões que incidem sobre um determinado quadrante. Quando a densidade populacional de padrões de um quadrante (razão entre o número de padrões que incidem sobre o quadrante e o número total de padrões) cai abaixo da taxa de decomposição, este quadrante não deve ser decomposto, o que limita o crescimento da estrutura.

Neste passo é efetuada a decomposição das partições separadas. Para cada bipartição separada é realizado um processo de decomposição que segue o seguinte processo: aloca-se um novo nó (nova célula) na estrutura BSP para a bipartição separada (ela é dividida em duas). Deste modo, são geradas duas novas funções de pertinência que constituirão as duas partições recém criadas. A Figura 4.33 ilustra graficamente este processo.

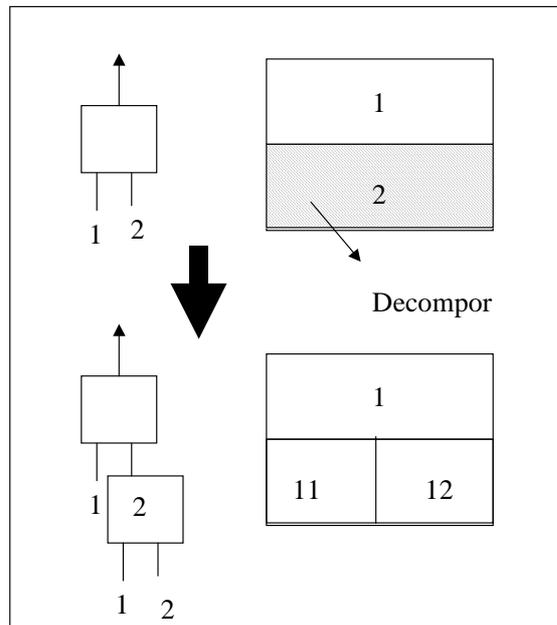


Figura 4.33 Decomposição BSP.

Volta ao passo “3” para continuar o aprendizado.

4.2.4.6. Seleção de Características dos Modelos NFHB

Os métodos de seleção de características tratam exatamente da escolha, dentre todos os atributos da base de dados, daqueles mais relevantes do ponto de vista da informação [165], [166].

Existem inúmeras técnicas [150], [167], [168], [169], [170] para a tarefa de seleção de variáveis, sendo estas categorizadas como *métodos dependentes do modelo* (“Model Based”) e *métodos independentes do modelo* (“Model-Free”) [171]. Dentre os métodos dependentes do modelo podem-se mencionar técnicas baseadas em redes neurais, em modelos neuro-fuzzy e em algoritmos genéticos. No caso dos métodos independentes do

modelo há métodos estatísticos, Análise de Componentes Principais, Correlação e Entropia. Cada tipo de técnica tem suas próprias características, apresentando vantagens e desvantagens.

Os modelos Neuro Fuzzy Hierárquicos já existentes, juntamente com dois dos três modelos criados nesta tese (modelos NFHB-SubClass e RN-NFHB-SubClass) utilizam o método baseado no modelo ANFIS para a escolha dos atributos mais relevantes. O outro modo criado nessa tese (modelo RN-Hierárquico-SubClass) não utiliza essa metodologia pois utiliza redes neurais ao invés de sistemas NFHB-Class.modelo ANFIS.

Este método escolhe as entradas baseado na possibilidade destas conduzirem a um ótimo desempenho do modelo ANFIS mostrado na Figura 4.34.a. Esse método utiliza uma configuração do modelo ANFIS [150], [172] com duas entradas divididas em 4 conjuntos fuzzy cada (particionamento fuzzy *grid* fixo). Deste modo, conforme pode ser observado na Figura 4.34.b, o espaço de entrada é dividido em 16 partições.

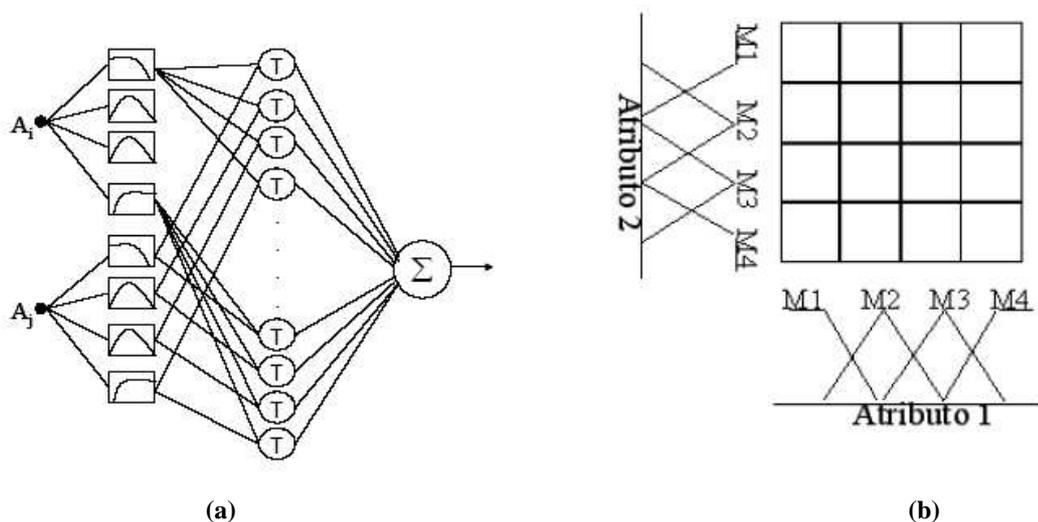


Figura 4.34 (a) Sistema ANFIS simplificado (2 entradas) para seleção de características ANFIS. (b) Respectivo particionamento.

Utilizando como entradas atributos da base de dados escolhidos dois a dois, treina-se o sistema, durante um certo número de ciclos especificado, e, em seguida, calcula-se o erro de classificação para esses dois atributos. Em seguida, escolhe-se um novo par de atributos, treina-se o sistema pelo mesmo número de ciclos, até que todas as configurações de pares de entrada tenham sido testadas. Posteriormente, as duplas de entradas são listadas em ordem crescente do valor do erro, selecionando-se as entradas de menor erro.

4.3. *Resumo*

Neste capítulo foram abordados, para a tarefa de classificação de padrões, os métodos estatísticos e os métodos que utilizam o paradigma de inteligência computacional, tais como: árvores de decisão, redes neurais, sistemas fuzzy e modelos híbridos neuro-fuzzy. Foi abordado também o método de seleção de atributos mais relevantes em uma base de dados para os modelos Neuro Fuzzy Hierárquicos.

O próximo capítulo será apresentado o método de extração de regras fuzzy, através das estruturas criadas pelos modelos NFHB-Invertido e NFHB-Class.

Capítulo 5

Extração de Regras Fuzzy

5.1. *Introdução*

Os sistemas neuro-fuzzy combinam a capacidade de aprendizado das redes neurais com o poder de interpretação lingüístico dos sistemas de inferência fuzzy. Um dos principais objetivos desses sistemas é a extração de conhecimento, sob a forma de regras fuzzy interpretáveis, a partir de um conjunto de dados.

Os modelos NFHB-Invertido e NFHB-Class permitem extrair conhecimento, sob o formato de regras fuzzy, a partir de suas estruturas geradas, com o intuito de descobrir informação em uma determinada base de dados.

Lanas [6] criou novo processo de extração de regras, capaz de extrair regras fuzzy a partir da estrutura de árvore BSP (*Binary Space Partitioning*) criada. Abaixo se encontram-se todos os passos do processo.

- 1) Treinar o modelo a partir do conjunto de dados, gerando sua estrutura e ajustando seus parâmetros (antecedente e conseqüentes);
- 2) Uma vez obtida a estrutura em forma de árvore binária, executar um caminhamento nesta árvore, visitando cada célula do sistema;
- 3) No instante da visita de cada célula, extrair os dados nela contidos (valores dos conseqüentes);
- 4) Visualização das regras fuzzy hierárquicas;
- 5) Avaliação das regras utilizando a acurácia fuzzy e abrangência fuzzy.

5.2. Cálculo dos Graus de Pertinência

Realizando-se um caminhamento pré-fixado [173] na árvore binária, vão se extrair as regras correspondentes a cada caminhamento e, paralelamente, calculando-se os coeficientes de disparo de cada registro em cada nó da árvore. Estes coeficientes de disparo são posteriormente utilizados para calcular o grau de pertinência de cada padrão em cada partição. No caso de árvores *crisp*, pode ser feito um levantamento estatístico e se determinar a classe “ganhadora” para cada partição. Já no caso fuzzy, todas as classes são “ganhadoras”, estando presentes em maior ou menor grau (de pertinência) em todas as partições. A maior dificuldade do processo está na determinação do grau de pertinência de cada classe em cada partição (nó final da árvore).

A Figura 5.1 mostra um exemplo com uma base de dados hipotética, seu respectivo particionamento e árvore neuro-fuzzy BSP. A base de dados mostrada possui apenas 2 atributos para simplificar a representação da partição BSP no espaço bidimensional.

| | Idade | Peso | Classe |
|---|-------|------|--------|
| A | 10 | 30 | 1 |
| B | 12 | 30 | 1 |
| C | 40 | 90 | 1 |
| D | 55 | 45 | 0 |
| E | 55 | 55 | 0 |
| F | 60 | 92 | 0 |
| G | 62 | 95 | 0 |
| H | 75 | 40 | 1 |

(a)

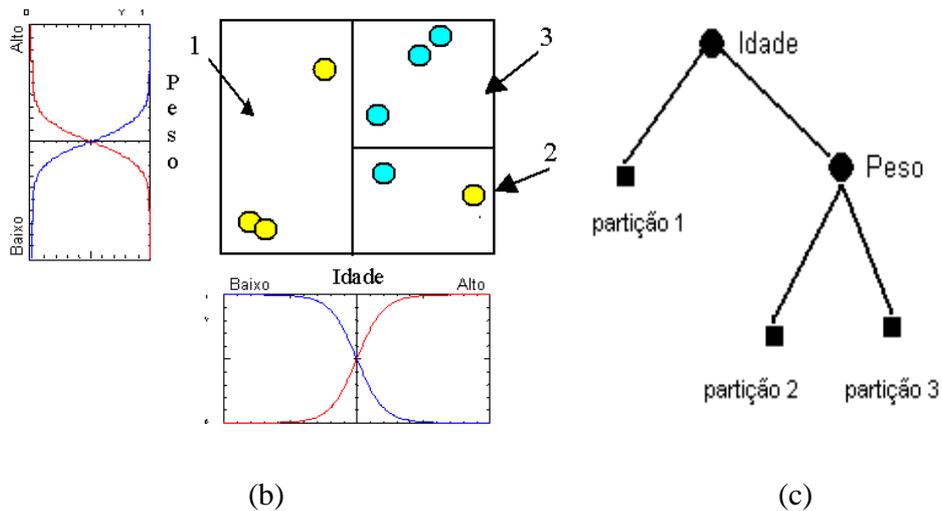


Figura 5.1 (a) Base de dados exemplo. (b) Particionamento encontrado para a base de dados mostrada em (a). (c) Árvore neuro-fuzzy BSP.

No caso *crisp*, cada padrão está ou não presente numa partição; no caso fuzzy todos os padrões (A, B, C, ..., H) estão presentes, com diferentes graus, em todas as partições (1, 2, 3).

As Figura 5.2 e Figura 5.3 apresentam uma árvore *crisp* e uma árvore fuzzy, respectivamente. Observa-se que, no caso *crisp*, os padrões A, B e C pertencem somente à partição 1, enquanto o padrão D pertence somente à partição 2. Entretanto, no caso fuzzy,

todos os padrões estão presentes em ambas as partições, mas com diferentes graus de pertinência.

Para o caso *crisp* pode-se fazer um levantamento estatístico e determinar que (ver Figura 5.1):

Se Idade < 50 então classe 1 e Se idade > 50 então classe 0

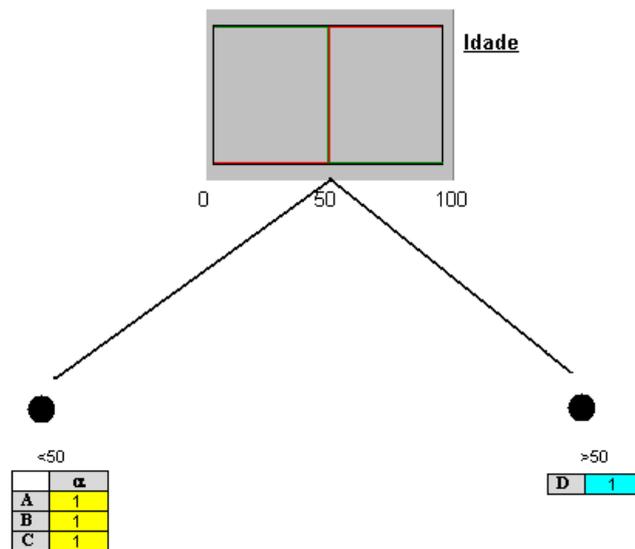


Figura 5.2 Árvore Crisp.

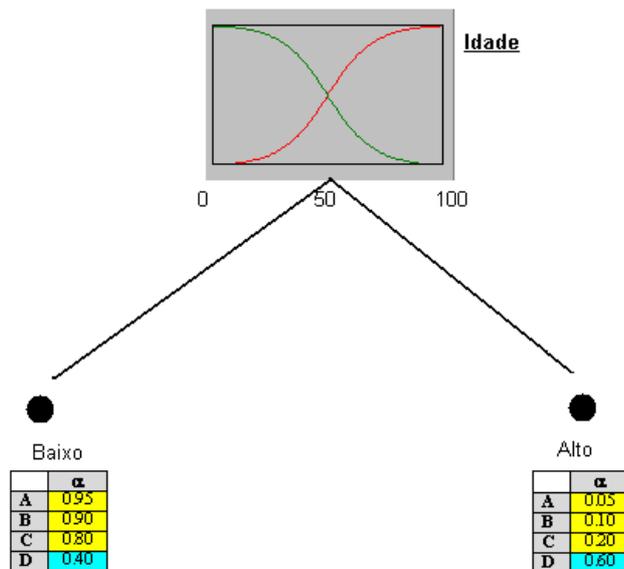


Figura 5.3 Árvore Fuzzy.

No caso fuzzy, para poder definir totalmente as regras, devem ser levados em consideração os graus de disparo de cada registro em cada nó. Pode-se considerar que cada caminhamento resulta em uma regra, mas cada regra classifica todas as classes existentes na base de dados. Portanto, no caso fuzzy, cada regra efetivamente é válida para as duas classes (Figura 5.4), com diferentes graus de pertinência. Para se determinar o grau de cada padrão em cada partição, basta efetuar, para cada caminhamento, a interseção (“E”) dos graus de disparo de cada padrão.

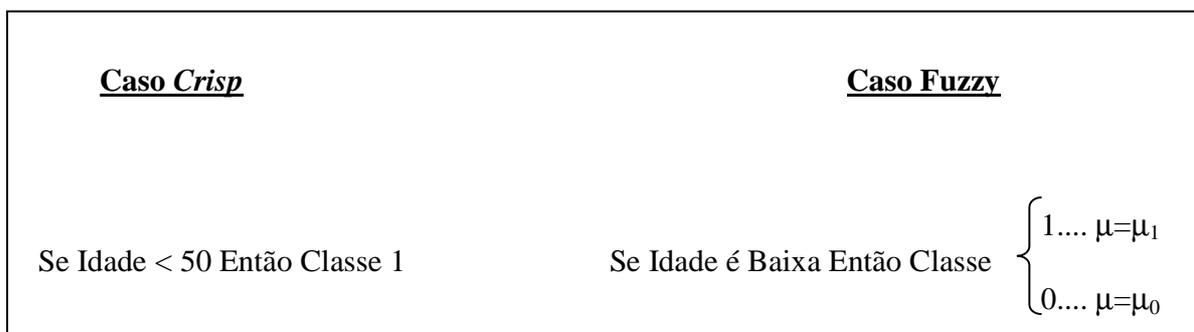
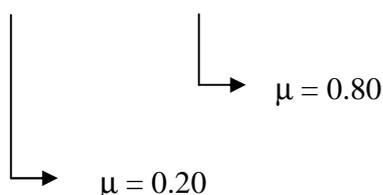


Figura 5.4 Regras *Crisp* x Regras Fuzzy.

A seguir, na Figura 5.5, é mostrado o resultado dos graus de disparo de cada padrão do exemplo da Figura 5.1. Para cada nó da árvore são registrados os graus de disparo de cada padrão (graus de pertinência) em função do atributo de entrada (tabelas “Alto” e “Baixo”). Posteriormente, utilizando o operador “produto” para efetuar o conectivo “E”, é realizada a interseção de todos os antecedentes para o cálculo do grau de disparo da regra.

O padrão C da regra 3 é mostrado na Figura 5.5.

Se Idade é Alta e Peso é Alto então ...



O grau de pertinência na partição 3 utilizando o conectivo “E” (produto), é de 0.16.

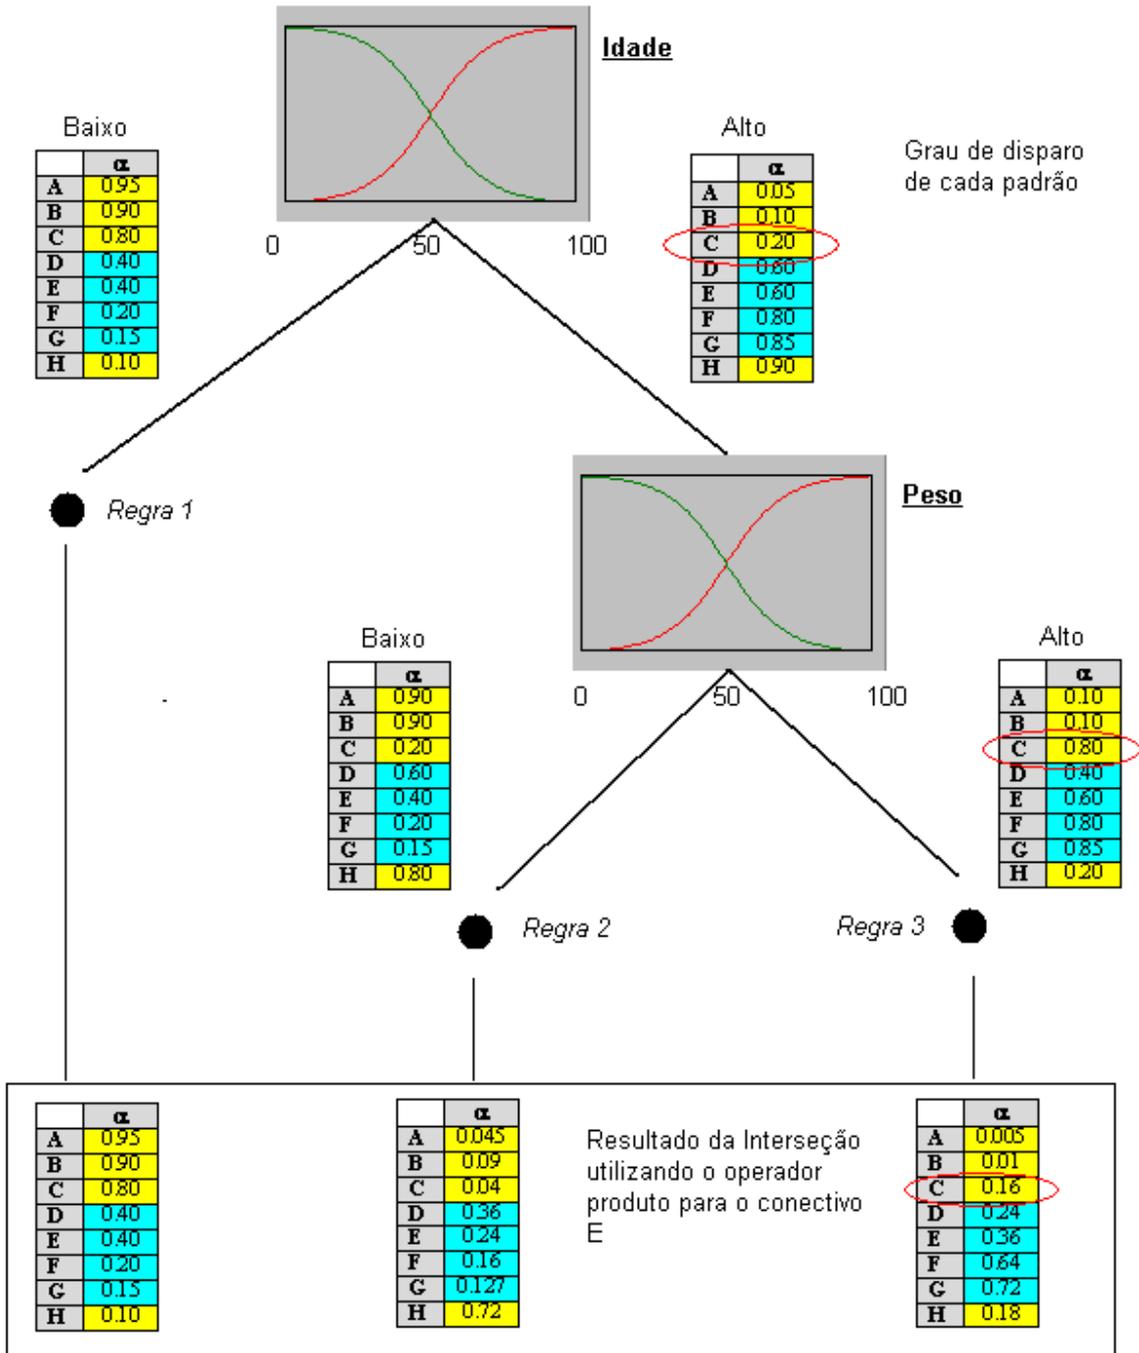


Figura 5.5 Grau de pertinência usando o T-norm produto.

A seguir será mostrado como é realizado o processo de visualização das regras.

5.3. Visualização das Regras

No modelo criado por Lanas [6] o conjunto de regras extraído é apresentado da seguinte forma:

Se IDADE é Baixa e PESO é Baixo e ALTURA é Alta então Classe 1

A seguir são mostradas as regras fuzzy extraídas da arquitetura BSP mostrada na Figura 5.5:

- Partição 1: Se Idade é Baixa Então Classe $\left\{ \begin{array}{l} 0 \\ 1 \end{array} \right.$ [regra 1]
- Partição 2: Se Idade é Alta e o Peso é Baixo Então Classe $\left\{ \begin{array}{l} 0 \\ 1 \end{array} \right.$ [regra 2]
- Partição 3: Se Idade é Alta e o Peso é Alto Então Classe $\left\{ \begin{array}{l} 0 \\ 1 \end{array} \right.$ [regra 3]

Como foi mostrado na seção anterior, para o caso fuzzy cada caminhamento ou partição (1, 2, 3) corresponde a uma regra. Entretanto, cada regra representa todas as classes existentes na partição, com diferentes graus de pertinência. Deste modo, cada regra pode ser decomposta em tantas “sub-regras” quantas forem as classes existentes na base de dados.

De forma a esclarecer o conceito da regra associado a um caminamento ou partição, e o conceito de “sub-regras”, associado a cada classe nessa partição, é utilizado a seguir o caminamento 1 como exemplo. Neste exemplo tem-se a seguinte regra:

$$\text{Se idade é Baixa então Classe} \left\{ \begin{array}{l} 0 \\ 1 \end{array} \right.$$

As sub-regras para cada classe (0 e 1) na partição 1 são então definidas como:

Se idade é Baixa então Classe=0

Se idade é Baixa então Classe=1

Apesar dessa diferença entre os conceitos de regra e sub-regra, neste trabalho se utilizá-se indistintamente o nome regra para referência às regras (caminamento) e às sub-regras (classe).

5.4. Avaliação das Regras

5.4.1. Acurácia Fuzzy

A acurácia de uma regra mede o quanto a solução é boa em função do grau de certeza, ou confiança, obtido através do conjunto de dados. Em outras palavras, a acurácia

mede o quão boa a regra descoberta (o conhecimento a respeito da base de dados) se aplica aos dados [174].

Na seção 6.2 foi mostrado que no caso fuzzy todos os padrões da base de dados estão presentes, em maior ou menor grau, em todas as partições. Assim cada regra extraída da árvore neuro-fuzzy NFHB-Invertida e NFHB-Class na verdade classifica todas as classes presentes. Para determinação do grau ou peso (*grau de pertinência*) de cada classe foi utilizada a medida de acurácia fuzzy [6] conforme a Equação 5.1.

$$Acuracia_Fuzzy_{N_i} = \frac{\sum_{j=1}^{P_N} \alpha_{N_i,j}}{\sum_{j=1}^l \alpha_{i,j}} \quad \text{Equação 5.1}$$

onde:

N_i é a classe N da partição i;

$\alpha_{N_i,j}$ é o grau de pertinência do padrão j da classe N da partição i;

$\alpha_{i,j}$ é o grau de pertinência do padrão j na partição i;

P_N é o número total de padrões da classe N;

l é o número total de padrões da partição i.

No caso de bases de dados com diferentes números de padrões por classe, deve-se aplicar o *Fator corretor* (W_N) para compensar a distribuição não uniforme dos padrões [6]. A acurácia corrigida (*Acurácia_Fuzzy**) é mostrada pelas Equação 5.2 e Equação 5.3.

$$Acurácia_Fuzzy^*_N = Acuracia_fuzzy_N . W_N \quad \text{Equação 5.2}$$

$$W_N = \frac{1}{P_N \cdot \sum_{j=1}^{N_c} \frac{Acurácia_Fuzzy_{N_j}}{P_j}} \quad \text{Equação 5.3}$$

onde:

- N_c é o número total de classes;
- P_j é o número de padrões da classe j ;
- P_N é o número de padrões da classe N ;
- N_j é a classe N da partição j .

No caso do exemplo da Figura 5.1, a distribuição de padrões em cada classe é uniforme (classe 0: 4 padrões, classe 1: 4 padrões), o valor de W_n para esse caso é 1.

Aplicando a fórmula da Acurácia para as regras obtidas da árvore da Figura 5.5, tem-se:

Regra da Partição 1

Se Idade é Baixa Então Classe 0

$$Acuracia_fuzzy_0 = \frac{\sum_{i=1}^8 \alpha_D + \alpha_E + \alpha_F + \alpha_G}{\sum_{i=1}^8 \alpha_i} = \frac{0.40+0.40+0.20+0.15}{0.95+0.9+0.8+0.4+0.4+0.2+0.15+0.1} = 0.29$$

Se Idade é Baixa Então Classe 1

$$Acuracia_fuzzy_1 = \frac{\sum_{i=1}^8 \alpha_A + \alpha_B + \alpha_C + \alpha_H}{\sum_{i=1}^8 \alpha_i} = \frac{0.95+0.9+0.8+0.1}{0.95+0.9+0.8+0.4+0.4+0.2+0.15+0.1} = 0.71$$

Regra da Partição 2

Se Idade é Alta e Peso é Baixo Então Classe 0

$$\text{Acuracia_fuzzy}_0 = \frac{\sum_{i=1}^{i=8} \alpha_D + \alpha_E + \alpha_F + \alpha_G}{\sum_{i=1}^{i=8} \alpha_i} = \frac{0.36 + 0.24 + 0.16 + 0.127}{0.045 + 0.09 + 0.04 + 0.36 + 0.24 + 0.16 + 0.127 + 0.72} = 0.49$$

Se Idade é Alta e Peso é Baixo Então Classe 1

$$\text{Acuracia_fuzzy}_1 = \frac{\sum_{i=1}^{i=8} \alpha_A + \alpha_B + \alpha_C + \alpha_H}{\sum_{i=1}^{i=8} \alpha_i} = \frac{0.045 + 0.09 + 0.04 + 0.72}{0.045 + 0.09 + 0.04 + 0.36 + 0.24 + 0.16 + 0.127 + 0.72} = 0.51$$

Regra da Partição 3

Se Idade é Alta e Peso é Alto Então Classe 0

$$\text{Acuracia_fuzzy}_0 = \frac{\sum_{i=1}^{i=8} \alpha_D + \alpha_E + \alpha_F + \alpha_G}{\sum_{i=1}^{i=8} \alpha_i} = \frac{0.24 + 0.36 + 0.64 + 0.72}{0.005 + 0.01 + 0.16 + 0.24 + 0.36 + 0.64 + 0.72 + 0.18} = 0.84$$

Se Idade é Alta e Peso é Alto Então Classe 1

$$\text{Acuracia_fuzzy}_1 = \frac{\sum_{i=1}^{i=8} \alpha_A + \alpha_B + \alpha_C + \alpha_H}{\sum_{i=1}^{i=8} \alpha_i} = \frac{0.005 + 0.01 + 0.16 + 0.18}{0.005 + 0.01 + 0.16 + 0.24 + 0.36 + 0.64 + 0.72 + 0.18} = 0.16$$

Por exemplo, no caso da regra da partição 3 (*Se Idade é Alta e Peso é Alto Então Classe ...*), o resultado da acurácia fuzzy indica que um padrão que satisfaz esta regra pertence à classe 0 com uma acurácia de 84% e pertence à classe 1 com uma acurácia de 16%.

O somatório de todas as acurácias das classes correspondentes a uma regra (partição) é igual a 1. As funções de pertinência de cada nó (Baixo-Alto) são complementares. Cada padrão tem um grau de disparo “x” na função *Baixa* e “1-x” na função *Alta*. O grau de presença de cada padrão em cada partição é definido pelos graus de disparo em cada nó e se realizando a interseção de todos eles utilizando o operador produto como conectivo “E”. Utilizando-se funções de ativação não complementares ou outro operador interseção diferente do produto, os resultados das acurácias devem ser normalizados para continuar mantendo o somatório das acurácias igual a 1.

Por exemplo, seja a partição 1, onde:

$$\text{Se Idade é Baixa Então Classe} \begin{cases} 0 \text{ acuracia_fuzzy} = 0.29 \\ 1 \text{ acuracia_fuzzy} = 0.71 \end{cases} \Rightarrow \sum \text{acuracia_fuzzy} = 0.29 + 0.71 = 1$$

O somatório dos graus de pertinência de cada padrão em todas as partições é igual a 1, pelas características acima mencionadas (funções complementares e operador produto).

Por exemplo, no caso do padrão H distribuído nas três partições existentes, tem-se:

$$\alpha_{1_H} + \alpha_{2_H} + \alpha_{3_H} = 0.10 + 0.72 + 0.18 = 1$$

Em alguns casos, pode ser interessante definir-se um **α -cut** para eliminar da partição registros cujo grau de pertinência é muito pequeno. A presença destes registros afeta o resultado de acurácia da regra (Equação 5.2). Supondo uma base de dados com muitos registros, onde para uma partição qualquer existe um grande número de registros

com grau de pertinência pequeno (0.1~0.3), estes registros podem ser eliminados mediante um α -cut igual a 0.35, proporcionando um aumento no resultado da acurácia.

Para o exemplo da Figura 5.5, são mostrados a seguir (Tabela 5.1), os resultados das acurácias das classes 0/1 considerando diferentes valores de α -cut.

Tabela 5.1 Acurácias/ α -cut

| Regra | α -cut=0.0 | α -cut=0.2 | α -cut=0.4 |
|-------|-------------------|-------------------|-------------------|
| 1 | 0.29/0.71 | 0.23/0.77 | 0/1 |
| 2 | 0.49/0.51 | 0.45/0.55 | 0/1 |
| 3 | 0.84/0.16 | 1/0 | 1/0 |

Outra medida de avaliação importante é a abrangência fuzzy da regra, descrita a seguir.

5.4.2. Abrangência Fuzzy

A medida da abrangência fuzzy fornece uma medida do peso que cada regra tem no total da base de regras, ou seja “quantos” padrões são afetados por essa regra. A definição da abrangência fuzzy [6] é mostrada pela Equação 5.4 a seguir:

$$Abrangência_Fuzzy_i = \frac{\sum_{j=1}^k \alpha_{i,j}}{P} \quad \text{Equação 5.4}$$

onde:

P = número total de padrões na base de dados;

$\alpha_{i,j}$ = grau de pertinência do padrão j na partição i.

k = número de padrões da partição i.

Aplicando-se a medida de abrangência fuzzy nas regras fuzzy anteriormente obtidas tem-se:

Regra da Partição 1

Se Idade é Baixa Então Classe $\left\{ \begin{array}{l} 0 \\ 1 \end{array} \right.$

$$\text{Abrangência_fuzzy}_1 = \frac{\sum_{r=1}^{r=8} \alpha_r}{P} = \frac{0.95 + 0.9 + 0.8 + 0.4 + 0.4 + 0.2 + 0.15 + 0.1}{8} = 0.49$$

Do ponto de vista fuzzy a regra afeta 49% do total de padrões.

Regra da Partição 2

Se Idade é Alta e Peso é Baixo Então Classe $\begin{cases} 0 \\ 1 \end{cases}$

$$\text{Abrangência_fuzzy}_2 = \frac{\sum_{r=1}^{r=8} \alpha_r}{P} = \frac{0.045 + 0.09 + 0.04 + 0.36 + 0.24 + 0.16 + 0.127 + 0.72}{8} = 0.22$$

Do ponto de vista fuzzy a regra afeta 22% do total de padrões.

Regra da Partição 3

Se Idade é Alta e Peso é Alto Então Classe $\begin{cases} 0 \\ 1 \end{cases}$

$$\text{Abrangência_fuzzy}_3 = \frac{\sum_{r=1}^{r=8} \alpha_r}{P} = \frac{0.005 + 0.01 + 0.16 + 0.24 + 0.36 + 0.64 + 0.72 + 0.18}{8} = 0.29$$

Do ponto de vista fuzzy a regra afeta 29% do total de padrões.

Pelas características anteriormente citadas na seção 6.4.1 (funções de pertinência complementares e operador produto), a composição de todas as regras abrange o total de padrões, ou seja, o somatório das abrangências de todas as partições é igual a 1. No exemplo acima mostrado tem-se:

$$\text{Abrangência_fuzzy}_1 + \text{Abrangência_fuzzy}_2 + \text{Abrangência_fuzzy}_3 = 0.49 + 0.22 + 0.29 = 1$$

5.5. *Resumo*

Neste capítulo foi abordado o processo de extração de regras fuzzy a partir da estrutura hierárquica criada pelos modelos NFHB-Invertido e NFHB-Class. Além disso, foram utilizadas medidas fuzzy de avaliação: acurácia fuzzy e abrangência fuzzy, para avaliar a “precisão” e o “alcance” de cada regra.

No próximo capítulo será apresentado os modelos hierárquicos SubClass: NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass desenvolvidos neste trabalho, para a tarefa de classificação de imagens de rochas.

Capítulo 6

Modelos Hierárquicos SubClass

Este capítulo irá apresentar novas extensões do modelo NFHB-Class e de redes neurais para problemas de classificação onde cada classe é composta por diversas subclasses. Para problemas de classificação de padrões com grande número de classes e subclasses, são necessários sistemas com topologias bastante complexas e grande número de padrões representativos para cada uma das classes e subclasses envolvidas.

Para suprir essa necessidade, buscou-se criar sistemas que sejam especialistas em cada classe macro em questão. Dessa forma, cada sistema possui sua topologia reduzida e é capaz de classificar com muito mais precisão os padrões das suas subclasses. Um sistema, pai ou raiz, é responsável pela classificação macro das classes, e uma vez que esse sistema tenha classificado a classe macro, os sistemas abaixo hierarquicamente, serão responsáveis pelas subclasses de cada classe macro pré classificada pelo sistema pai ou raiz.

Três novos modelos híbridos serão apresentados:

NFHB-SubClass: um sistema NFHB-Class, pai ou raiz, atuando como classificador macro e sistemas NFHB-Class atuando como responsáveis pela tarefa de subclassificação.

RN-NFHB-SubClass: uma rede neural, pai ou raiz, atuando como classificador macro e sistemas NFHB-Class atuando como responsáveis pela tarefa de subclassificação.

RN-Hierárquico-SubClass: uma rede neural, pai ou raiz, atuando como classificador macro e outras redes neurais atuando como responsáveis pela tarefa de subclassificação.

6.1. Modelo NFHB-SubClass

O modelo NFHB-SubClass é uma terceira adaptação do modelo NFHB para problemas de classificação. A principal diferença do modelo NFHB-SubClass para os modelos NFHB-Invertido e NFHB-Class está no fato de que esse novo modelo é capaz de realizar classificações macros e subclassificações a partir dessas classificações macros.

Na tarefa de classificação de rochas é muito comum haver determinados tipos de classes de rochas e dentro de cada classe de rocha ainda existir uma nova subclassificação da rocha. Conforme será visto no capítulo referente ao estudo de casos, foram utilizadas para testes as rochas do tipo: basalto, diabásio, gnaiss e riolito. Porém, para cada uma dessas classificações de rochas há subclasses conforme a listagem abaixo:

- Basalto
 - Basalto afanítico afírico
 - Basalto afanítico afírico oxidado
 - Basalto porfirítico

- Basalto porfirítico amigdaloidal
- Diabásio
 - Diabásio amigdaloidal alterado
 - Diabásio equigranular
 - Diabásio porfirítico
 - Diabásio porfirítico alterado
 - Diabásio porfirítico amigdaloidal
- Gnaisse
 - Gnaisse granítico
 - Gnaisse leucocrático
- Riolito
 - Riolito alterado
 - Riolito amigdaloidal
 - Riolito porfirítico
 - Riolito porfirítico amigdaloidal
 - Riolito porfirítico amigdaloidal venulado

No modelo NFHB-SubClass existe a necessidade de se criar um sistema NFHB-Class para cada uma das classes macros envolvidas na tarefa de classificação, ou seja, para os dados que serão utilizados no estudo de casos, serão criados um sistema NFHB-Class para classificar todos os tipos de subclasses das rochas basalto, um outro sistema NFHB-Class para classificar todos os tipos de subclasses das rochas diabásio, um terceiro sistema NFHB-Class para classificar todos os tipos de subclasses das rochas gnaisse e um quarto

sistema NFHB-Class para classificar todos os tipos de subclasses das rochas riolito. Após cada um dos sistemas NFHB-Class serem treinados, cria-se um sistema NFHB-Class, raiz ou pai, que será o sistema responsável pela classificação macro. No exemplo acima, o mesmo será o responsável por fazer a classificações das rochas como sendo do tipo: basalto, diabásio, gnaisse ou riolito.

6.1.1. Arquitetura NFHB-SubClass

A Figura 6.1 mostra um exemplo de uma arquitetura NFHB-SubClass obtida na fase de treinamento do sistema, para uma base de dados que possui quatro classes macro distintas, sendo a primeira classe macro composta de quatro subclasses, a segunda classe macro composta de cinco subclasses, a terceira classe macro composta de duas subclasses e a quarta classe macro composta de cinco subclasses.

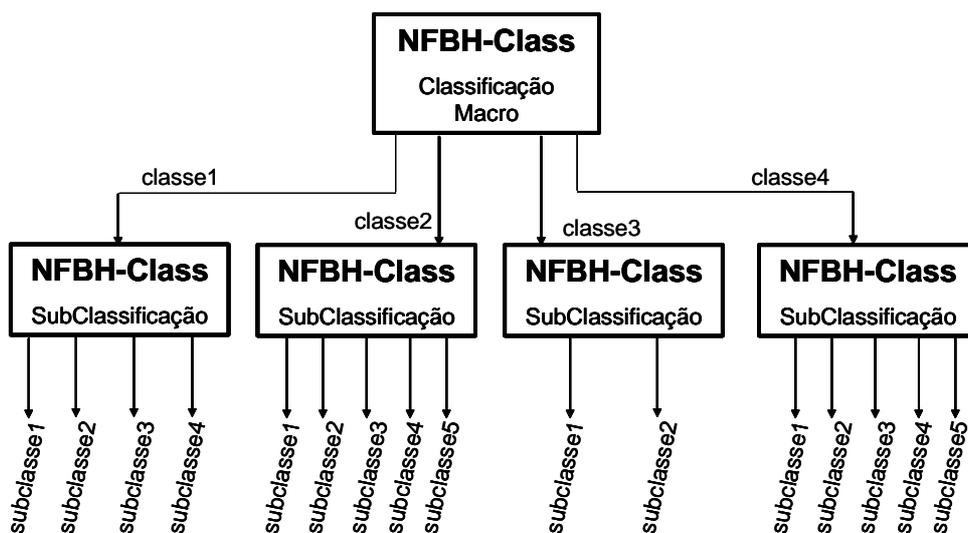


Figura 6.1 Exemplo de Arquitetura NFHB-Subclass para classificação de 4 classes macros com subclasses.

Na arquitetura NFHB-Subclass, Figura 6.1, o sistema NFHB-Class, pai ou raiz, passa a ter o número de saídas igual ao número de classes macros (*classe1*, *classe2*, *classe3* e *classe4*). A saída do sistema (*classe1*, *classe2*, *classe3* ou *classe4*) com o maior valor, definirá a classe a que pertence o padrão que foi apresentado ao sistema, e conseqüentemente irá definir qual sistema NFHB-Class realizará a tarefa de subclassificação. A tarefa de subclassificação será realizada pelo sistema NFHB-Class responsável pela classe macro, previamente classificada pelo sistema NFHB-Class raiz ou pai.

6.1.2. Algoritmo de Aprendizado NFHB-SubClass

O processo de aprendizado do modelo NFHB-SubClass é realizado separadamente para cada classe composta por suas subclasses. Inicialmente é criado um modelo NFHB-Class responsável pela classificação macro dos padrões. Em seguida para cada classe macro é criado um modelo NFHB-Class que torna possível a subclassificação dentro de cada classe pré classificada pelo classificador macro.

Os dados para treinamento são todos apresentados para cada um dos sistemas NFHB-Class que compõem o sistema NFHB-SubClass. Dessa forma treinam-se todos os modelos NFHB-Class individualmente, e em seguida, após cada um dos sistemas NFHB-Class treinado, faz-se a construção do sistema NFHB-SubClass contendo todos os modelo NFHB-Class treinados.

A Figura 6.2 ilustra o algoritmo de aprendizado.

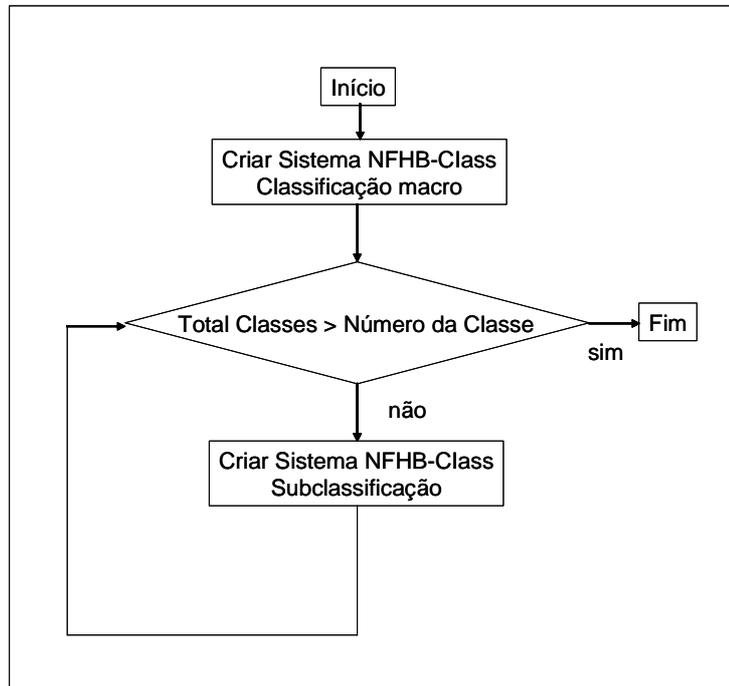


Figura 6.2 Algoritmo de aprendizado do modelo da arquitetura NFHB-Subclass.

6.2. Modelo RN-NFHB-Subclass

O modelo RN-NFHB-SubClass, é uma hibridização das redes neurais com o modelo NFHB-Class, capaz de realizar classificações macros e subclassificações a partir dessas classificações macros.

No modelo RN-NFHB-SubClass, treina-se uma rede neural MLP (*multilayer perceptrons*) com algoritmo supervisionado *backpropagation* [129Error! Bookmark not defined.] que será responsável pela classificação macro do sistema, e subsistemas NFHB-

Class para classificar todos os tipos de subclasses de cada classe macro pré classificada pela rede neural.

Em termos comparativos com o modelo NFHB-SubClass, a diferença está no sistema de classificação macro que substitui um modelo NFHB-Class por uma rede neural MLP.

6.2.1. Arquitetura RN-NFHB-SubClass

A Figura 6.3 mostra um exemplo de uma arquitetura RN-NFHB-SubClass obtida na fase de treinamento do sistema, para uma base de dados que possui quatro classes macro distintas, sendo a primeira classe macro composta de quatro subclasses, a segunda classe macro composta de cinco subclasses, a terceira classe macro composta de duas subclasses e a quarta classe macro composta de cinco subclasses.

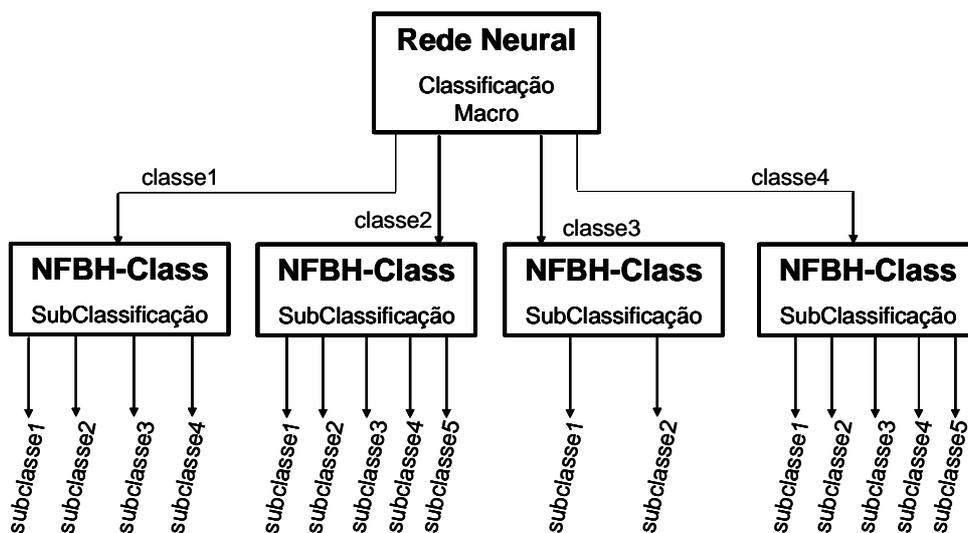


Figura 6.3 Exemplo de Arquitetura RN-NFHB-Subclass para classificação de 4 classes macros com subclasses.

Na arquitetura RN-NFHB-Subclass, Figura 6.3, a rede neural, passa a ter o número de saídas igual ao número de classes macros (*classe1*, *classe2*, *classe3* e *classe4*). A saída do sistema (*classe1*, *classe2*, *classe3* ou *classe4*) com o maior valor, definirá a classe a que pertence o padrão que foi apresentado ao sistema, e conseqüentemente irá definir qual sistema NFHB-Class realizará a tarefa de subclassificação. A tarefa de subclassificação será realizada pelo sistema NFHB-Class responsável pela classe macro, previamente classificada pela rede neural.

6.2.2. Algoritmo de Aprendizado RN-NFHB-SubClass

O processo de aprendizado do modelo RN-NFHB-SubClass é realizado separadamente para cada classe composta por suas subclasses. Inicialmente é treinada uma rede neural responsável pela classificação macro dos padrões. Em seguida para cada classe macro é criado um modelo NFHB-Class que torna possível a subclassificação dentro de cada classe pré classificada pelo classificador macro.

Os dados para treinamento são todos apresentados para a rede neural e para cada um dos sistemas NFHB-Class que compõem o sistema NFHB-SubClass. Dessa forma treinam-se a rede neural e todos os modelos NFHB-Class individualmente, e em seguida, após cada um dos sistemas ser treinado, faz-se a construção do sistema NFHB-SubClass contendo a rede neural treinada, juntamente com todos os modelo NFHB-Class treinados.

A Figura 6.4 ilustra o algoritmo de aprendizado.

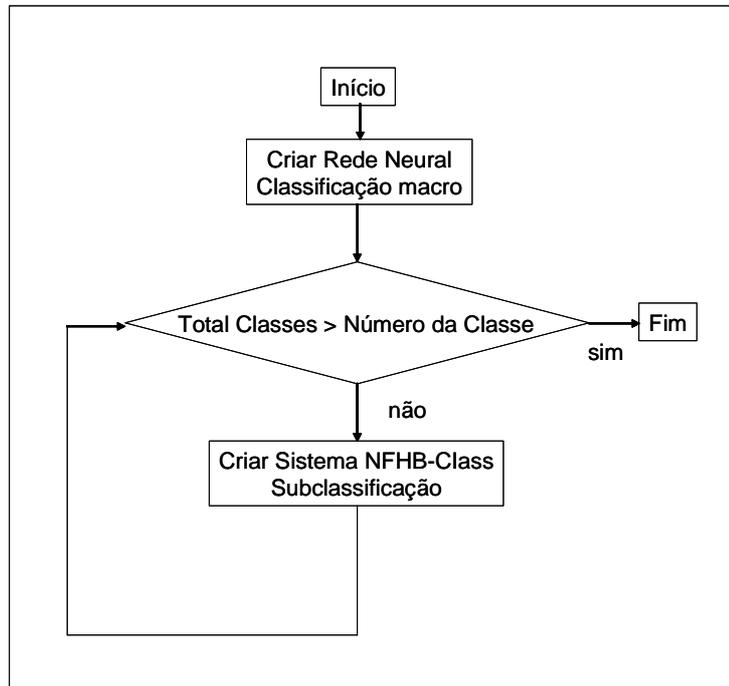


Figura 6.4 Algoritmo de aprendizado do modelo da arquitetura RN-NFHB-Subclass.

6.3. Modelo RN-Hierárquico-Subclass

O modelo RN-Hierárquico-SubClass, é uma hierarquia das redes neurais MLP (*multilayer perceptrons*) com algoritmo supervisionado *backpropagation* [129], capaz de realizar classificações macros e subclassificações a partir dessas classificações macros.

No modelo RN-Hierárquico-SubClass, treina-se uma rede neural MLP, pai ou raiz, que será responsável pela classificação macro do sistema, e outras redes neurais MLP para classificar todos os tipos de subclasses de cada classe macro pré classificada pela rede neural pai ou raiz.

6.3.1. Arquitetura RN-Hierárquico-Subclass

A Figura 6.5 mostra um exemplo de uma arquitetura RN-Hierárquico-SubClass obtida na fase de treinamento do sistema, para uma base de dados que possui quatro classes macro distintas, sendo a primeira classe macro composta de quatro subclasses, a segunda classe macro composta de cinco subclasses, a terceira classe macro composta de duas subclasses e a quarta classe macro composta de cinco subclasses.

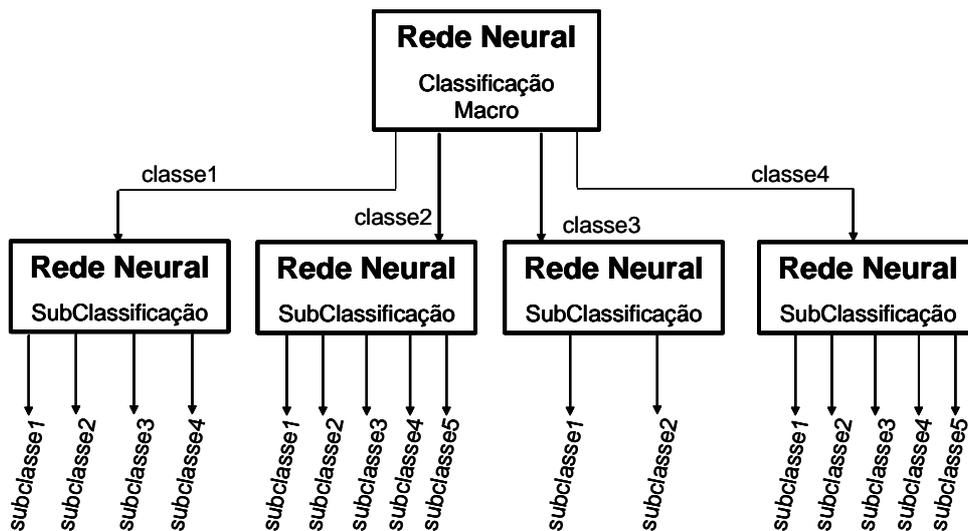


Figura 6.5 Exemplo de Arquitetura RN-Hierárquico-SubClass para classificação de 4 classes macros com subclasses.

Na arquitetura RN-Hierárquico-SubClass, Figura 6.5, a rede neural, passa a ter o número de saídas igual ao número de classes macros (*classe1*, *classe2*, *classe3* e *classe4*). A saída do sistema (*classe1*, *classe2*, *classe3* ou *classe4*) com o maior valor, definirá a

classe a que pertence o padrão que foi apresentado ao sistema, e conseqüentemente irá definir qual rede neural realizará a tarefa de subclassificação. A tarefa de subclassificação será realizada pela rede neural responsável pela classe macro, previamente classificada pela rede neural pai ou raiz.

6.3.2. Algoritmo de Aprendizado RN-Hierárquico-Subclass

O processo de aprendizado do modelo RN-Hierárquico-SubClass é realizado separadamente para cada classe composta por suas subclasses. Inicialmente é treinada uma rede neural, pai ou raiz, responsável pela classificação macro dos padrões. Em seguida para cada classe macro é criado uma rede neural que torna possível a subclassificação dentro de cada classe pré classificada pelo classificador macro.

Os dados para treinamento são todos apresentados para a rede neural e para cada uma das redes neurais que compõem o sistema RN-Hierárquico-SubClass. Dessa forma treinam-se a rede neural pai ou raiz e todas as outras redes neurais individualmente, e em seguida, após cada uma das redes ser treinada, faz-se a construção do sistema RN-Hierárquico-SubClass contendo a rede neural, pai ou raiz, treinada, juntamente com todos as outras redes neurais treinadas.

A Figura 6.6 ilustra o algoritmo de aprendizado.

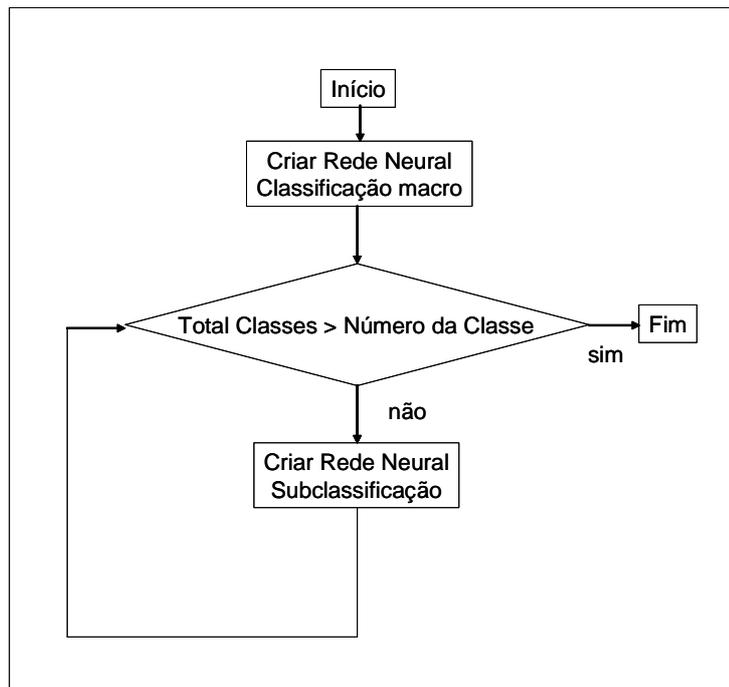


Figura 6.6 Algoritmo de aprendizado do modelo da arquitetura RN-Hierárquico-SubClass.

6.4. *Resumo*

Neste capítulo foi abordado em detalhes os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, novos modelos capazes de realizar classificação de padrões de forma macro e em subclasses.

O próximo capítulo introduz as estratégias de seleção de características em uma base de dados.

Capítulo 7

Estudo de Casos

A seguir, serão apresentados os resultados de classificação para diversas classes e subclasses de rochas. Em todos os testes de classificação para classes macros e para as subclasses das classes macros foram realizados ensaios com os modelos NFHB-Class com estratégia de seleção de característica fixa, NFHB-Class com estratégia de seleção de características adaptativa e redes neurais.

Para os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass foram realizadas as classificações das classes macros e das subclasses de forma conjunta.

Nos modelos NFHB-Class, NFHB-SubClass variou-se o parâmetro **taxa de decomposição** (δ). Para as redes neurais MLP e RN-Hierárquico-SubClass foi utilizado o algoritmo supervisionado “*backpropagation*” para treinamento das redes. Para o modelo RN-NFHB-SubClass é necessário tanto o parâmetro da taxa de aprendizado para obter

melhor configuração dos modelos NFHB-Class como também o treinamento das redes neurais, pois se trata de um modelo híbrido.

7.1. Descrição

Para avaliar o desempenho de todos os modelos foram utilizadas 50 imagens RGB, de tamanho 401x401, para cada uma das classes e subclasses de rochas a seguir, compondo um total de 800 imagens. As imagens das rochas são apresentadas no apêndice. As classes e subclasses de rochas que compõem o banco de imagens são:

- Basalto
 - Basalto afanítico afríco
 - Basalto afanítico afríco oxidado
 - Basalto porfirítico
 - Basalto porfirítico amigdaloidal
- Diabásio
 - Diabásio amigdaloidal alterado
 - Diabásio equigranular
 - Diabásio porfirítico
 - Diabásio porfirítico alterado
 - Diabásio porfirítico amigdaloidal
- Gnaisse
 - Gnaisse granítico
 - Gnaisse leucocrático

- Riolito
 - Riolito alterado
 - Riolito amigdaloidal
 - Riolito porfirítico
 - Riolito porfirítico amigdaloidal
 - Riolito porfirítico amigdaloidal venulado

De posse das 800 imagens criadas (16 x 50) foi utilizado o software matlab como ambiente de programação para obter os seguintes descritores de imagens:

- Coeficiente de Hurst para imagens em tons de cinza e coloridas (um coeficiente para cada canal RGB)
- Coeficiente de Variação Espacial para imagens em tons de cinza e coloridas (um coeficiente para cada canal RGB)
- Entropia da imagem em tons de cinza e para imagens coloridas (Entropia para cada canal RGB)
- Matriz de Coocorrência de tamanho 256 x 256 para cada imagem nas direções de 0, 45, 90 e 135 graus e para distâncias entre pixels de 1 até 40, criando assim um total de 160 matrizes de coocorrência de tamanho 256 x 256. Desse total de 160 matrizes, foi feita a média das matrizes nas direções de 0, 45, 90 e 135 graus para cada distância, obtendo-se assim apenas 40 matrizes para as 40 distâncias. De posse dessas 40 matrizes utilizou-se os seguintes descritores nas matrizes:

- Contraste
- Homogeneidade
- Energia

- Entropia

- Correlação

Para cada dos 5 descritores acima obteve-se 40 pontos que plotados geraram uma curva. Então, de posse das 5 curvas para cada imagem extraiu-se a área e o máximo, e utilizou-se esses valores como atributos para determinar a textura das imagens. Depois de obter todos esse descritores montou-se uma base de dados para as 800 imagens criadas.

Os testes foram realizados nas seguintes etapas:

- Foi criada uma base de dados somente com as 2 subclasses de rochas Gnaisse: Gnaisse granítico e Gnaisse leucocrático
- Foi criada uma base de dados somente com as 4 subclasses de rochas Basalto: Basalto afanítico afírico, Basalto afanítico afírico oxidado, Basalto porfirítico e Basalto porfirítico amigdaloidal.
- Foi criada uma base de dados somente com as 5 subclasses de rochas Diabásio: Diabásio amigdaloidal alterado, Diabásio equigranular, Diabásio porfirítico, Diabásio porfirítico alterado e Diabásio porfirítico amigdaloidal.
- Foi criada uma base de dados somente com as 5 subclasses de rochas Riolito: Riolito alterado, Riolito amigdaloidal, Riolito porfirítico, Riolito porfirítico amigdaloidal e Riolito porfirítico amigdaloidal venulado.
- Foi criada uma base de dados somente com as 2 classes macro das rochas gnaisse e basalto, sem considerar as suas subclasses.
- Foi criada uma base de dados somente com as 2 classes macro das rochas diabásio e riolito, sem considerar as suas subclasses.

- Foi criada uma base de dados somente com as 3 classes macro das rochas basalto, diabásio e riolito, sem considerar as suas subclasses.
- Foi criada uma base de dados somente com as 4 classes macro das rochas gnaisse, basalto, diabásio e riolito, sem considerar as suas subclasses.

Os modelos NFHB-SubClass, RN-NFHB-SubClass e NFHB-Class foram implementados na plataforma Delphi. Já para o modelos RN-Hierárquico-SubClass e para as redes neurais foi utilizado o software Qnet V2000[7]. Em todos os testes foram utilizados 50% da base de dados para treinamento e 50% da base de dados para validação.

7.2. Classificação das rochas através dos modelos NFHB-Class e Redes Neurais

7.2.1. Rocha Gnaisse

A seguir serão apresentados os resultados obtidos com o modelos NFHB-Class¹ (estratégia de seleção de características fixa) e NFHB-Class² (estratégia de seleção de características adaptativa) para a classificação da base de dados dos descritores de textura da rocha gnaisse. Na tabela as classes 1 e 2 referem-se as classes: gnaisse granítico e gnaisse leucocrático, respectivamente. Os atributos estão codificados por: 1 – Coeficiente de Hurst para tons de cinza, 2 – Coeficiente de Hurst canal Red, 3 – Coeficiente de Hurst canal Green, 4 – Coeficiente de Hurst canal Blue, 5 – CVE para tons de cinza, 6 – CVE para canal Red, 7 – CVE para canal Green, 8 – CVE para canal Blue, 9 – Entropia da

Imagem em tons de cinza, 10 – Entropia da Imagem canal Red, 11 – Entropia da Imagem canal Green, 12 – Entropia da Imagem canal Blue, 13 – Maior valor do descritor contraste encontrado na matriz de coocorrência, 14 – Área do descritor contraste encontrado na matriz de coocorrência, 15 – Maior valor do descritor correlação encontrado na matriz de coocorrência, 16 – Área do descritor correlação encontrada na matriz de coocorrência, 17 – Maior valor do descritor energia encontrado na matriz de coocorrência, 18 – Área do descritor energia encontrado na matriz de coocorrência, 19 – Maior valor do descritor entropia encontrado na matriz de coocorrência, 20 Valor da distância onde foi encontrado o maior valor do descritor entropia encontrado na matriz de coocorrência, 21 – Área do descritor entropia encontrado na matriz de coocorrência, 22 – Maior valor do descritor homogeneidade encontrado na matriz de coocorrência, 23 – Área do descritor homogeneidade encontrado na matriz de coocorrência.

Os conjuntos de dados utilizados nas Tabela 7.1, Tabela 7.2 e Tabela 7.3 são interpretados por:

- Gnaisse1: Teste feito com a base dados contendo somente como atributos os coeficientes para tons de cinza
- Gnaisse2: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB
- Gnaisse3: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB e os coeficientes para tons de cinza
- Gnaisse4: Teste feito com a base dados contendo somente como atributos os extraídos das matrizes de coocorrência.

A Tabela 7.1 resume os resultados de classificação obtidos para os dados das rochas gnaisse, utilizando os modelos NFHB-Class com estratégia de seleção de características fixa e adaptativa.

A Tabela 7.2 mostra as configurações das redes neurais utilizadas para as bases de dados Gnaisse1, Gnaisse2, Gnaisse3 e Gnaisse 4.

A Tabela 7.4 resume o desempenho das redes neurais e dos modelos NFHB-SubClass e NFHB-Class com estratégias de seleção fixa (NFHB-SubClass¹ e NFHB-Class¹) e adaptativa (NFHB-SubClass² e NFHB-Class²). Essa tabela foi elaborada com base no maior acerto percentual do conjunto de validação para cada modelo.

Tabela 7.1 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das subclasses das rochas gnaissse.

| Modelo | Conjunto de dados utilizados para teste | | Erros no conjunto treinamento | | Erros no Conjunto de validação | | Acerto Percentual de conjunto treinamento | Acerto Percentual de conjunto de validação | Número de regras geradas | Taxa de decomp. | Ordem dos atributos utilizados |
|-------------------------|---|--------------|-------------------------------|--------------|--------------------------------|--------------|---|--|--------------------------|-----------------|--|
| | granítico | leucocrático | granítico | leucocrático | granítico | leucocrático | | | | | |
| NFHB-Class ¹ | 0/25 | 1/25 | 2/25 | 0/25 | 2/25 | 0/25 | 98 % | 96 % | 32 | 0,03 | 5, 9, 1 |
| NFHB-Class ² | 0/25 | 1/25 | 2/25 | 0/25 | 2/25 | 0/25 | 98 % | 96 % | 17 | 0,08 | |
| NFHB-Class ¹ | 0/25 | 0/25 | 1/25 | 0/25 | 1/25 | 0/25 | 100 % | 98 % | 52 | 0,01 | 8, 12, 7, 6, 10, 11, 3, 2, 4 |
| NFHB-Class ² | 0/25 | 2/25 | 1/25 | 2/25 | 1/25 | 2/25 | 96 % | 94 % | 12 | 0,1 | |
| NFHB-Class ¹ | 0/25 | 3/25 | 0/25 | 2/25 | 0/25 | 2/25 | 94 % | 96 % | 52 | 0,01 | 8, 12, 7, 5, 6, 10, 9, 11, 3 |
| NFHB-Class ² | 0/25 | 0/25 | 1/25 | 0/25 | 1/25 | 0/25 | 100 % | 98 % | 54 | 0,008 | |
| NFHB-Class ¹ | 0/25 | 0/25 | 0/25 | 1/25 | 0/25 | 1/25 | 100 % | 98 % | 81 | 0,01 | 13, 23, 19, 22, 21, 14, 17, 18, 15, 20, 16 |
| NFHB-Class ² | 0/25 | 1/25 | 1/25 | 1/25 | 1/25 | 1/25 | 98 % | 96 % | 9 | 0,1 | |

Tabela 7.2 Configurações das redes neurais utilizadas para as subclasses das rochas gnaiss.

| Conjunto de dados utilizados para teste | Número de camadas | Número de Neurônios na camada de entrada | Número de neurônios na primeira camada escondida | Número de neurônios na camada de saída |
|---|-------------------|--|--|--|
| Gnaiss1 | 3 | 3 | 5 | 2 |
| Gnaiss2 | 3 | 9 | 9 | 2 |
| Gnaiss3 | 3 | 12 | 9 | 2 |
| Gnaiss4 | 3 | 11 | 9 | 2 |

Tabela 7.3 Desempenho das redes neurais, para as subclasses das rochas gnaiss.

| Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | Erros no conjunto de validação | Acerto | |
|---|----------------------------------|--------------------------------|---------------------------------------|-------------------------------------|
| | | | Percentual de conjunto de treinamento | Percentual de conjunto de validação |
| Gnaiss1 | leucocrático | 0/25 | 100 % | 92 % |
| | granítico | 3/25 | 88 % | 92 % |
| Gnaiss2 | leucocrático | 0/25 | 100 % | 96 % |
| | granítico | 0/25 | 100 % | 96 % |
| Gnaiss3 | leucocrático | 0/25 | 100 % | 96 % |
| | granítico | 2/25 | 92 % | 96 % |
| Gnaiss4 | leucocrático | 0/25 | 100 % | 96 % |
| | granítico | 2/25 | 96 % | 96 % |

Tabela 7.4 Melhor desempenho obtido pelos modelos, NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa) e redes neurais, para as subclasses das rochas gnaisse.

| Modelo | Rocha Gnaisse | |
|-------------------------|--|--|
| | Melhor desempenho para o conjunto de treinamento | Melhor desempenho para o conjunto de validação |
| NFHB-Class ¹ | 100 % | 98 % |
| NFHB-Class ² | 100 % | 98 % |
| Redes neurais | 100 % | 96 % |

A partir da Tabela 7.4, observa-se que o melhor desempenho de validação, para a rocha gnaisse, foi encontrado com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa).

7.2.2. Rocha Basalto

A seguir serão apresentados os resultados obtidos com o modelos NFHB-Class¹ (estratégia de seleção de características fixa) e NFHB-Class² (estratégia de seleção de características adaptativa) para a classificação da base de dados dos descritores de textura da rocha basalto. Na tabela as classes 1, 2, 3 e 4 referem-se as classes: basalto afanítico africano, basalto afanítico africano oxidado, basalto porfírico e basalto porfírico amigdaloidal, respectivamente. Os atributos estão codificados por: 1 – Coeficiente de Hurst para tons de cinza, 2 – Coeficiente de Hurst canal Red, 3 – Coeficiente de Hurst canal Green, 4 – Coeficiente de Hurst canal Blue, 5 – CVE para tons de cinza, 6 – CVE para canal Red, 7 – CVE para canal Green, 8 – CVE para canal Blue, 9 – Entropia da Imagem em tons de cinza, 10 – Entropia da Imagem canal Red, 11 – Entropia da Imagem canal

Green, 12 – Entropia da Imagem canal Blue, 13 – Maior valor do descritor contraste encontrado na matriz de coocorrência, 14 – Área do descritor contraste encontrado na matriz de coocorrência, 15 – Maior valor do descritor correlação encontrado na matriz de coocorrência, 16 – Área do descritor correlação encontrada na matriz de coocorrência, 17 – Maior valor do descritor energia encontrado na matriz de coocorrência, 18 – Área do descritor energia encontrado na matriz de coocorrência, 19 – Maior valor do descritor entropia encontrado na matriz de coocorrência, 20 Valor da distância onde foi encontrado o maior valor do descritor entropia encontrado na matriz de coocorrência, 21 – Área do descritor entropia encontrado na matriz de coocorrência, 22 – Maior valor do descritor homogeneidade encontrado na matriz de coocorrência, 23 – Área do descritor homogeneidade encontrado na matriz de coocorrência.

Os conjuntos de dados utilizados nas Tabela 7.5, Tabela 7.6 e Tabela 7.7 são interpretados por:

- Basalto1: Teste feito com a base dados contendo somente como atributos os coeficientes para tons de cinza.
- Basalto2: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB.
- Basalto3: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB e os coeficientes para tons de cinza.
- Basalto4: Teste feito com a base dados contendo somente como atributos os extraídos das matrizes de coocorrência.

A Tabela 7.5 resume os resultados de classificação obtidos para os dados das rochas basalto, utilizando os modelos NFHB-Class com estratégia de seleção de características fixa e adaptativa.

A Tabela 7.6 mostra as configurações das redes neurais utilizadas para as bases de dados Basalto1, Basalto2, Basalto3 e Basalto4.

A Tabela 7.8 resume o desempenho das redes neurais e dos modelos NFHB-SubClass e NFHB-Class com estratégias de seleção fixa (NFHB-SubClass¹ e NFHB-Class¹) e adaptativa (NFHB-SubClass² e NFHB-Class²). Essa tabela foi elaborada com base no maior acerto percentual do conjunto de validação para cada modelo.

Tabela 7.5 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das subclasses das rochas basalto.

| Modelo | Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | | | | Erros no Conjunto de validação | | | | Acerto Percent conjunto de treino | Acerto Percent conjunto de validação | Num. de regras | Taxa de dec. | Ordem dos atrib. utilizados |
|-------------------------|---|----------------------------------|---------------------------|-----------|------------------------|--------------------------------|---------------------------|-----------|------------------------|-----------------------------------|--------------------------------------|----------------|--|-----------------------------|
| | | afanítico afírico | afanítico afírico oxidado | porfírico | porfírico amigdaloidal | afanítico afírico | afanítico afírico oxidado | porfírico | porfírico amigdaloidal | | | | | |
| NFHB-Class ¹ | Basalto1 | 7/25 | 1/25 | 11/25 | 2/25 | 12/25 | 7/25 | 20/25 | 2/25 | 79% | 73 | 0,006 | 1, 5, 9 | |
| | | 5/25 | 1/25 | 3/25 | 1/25 | 8/25 | 6/25 | 18/25 | 3/25 | 90% | 118 | 0,0009 | | |
| NFHB-Class ¹ | Basalto2 | 1/25 | 0/25 | 4/25 | 0/25 | 7/25 | 0/25 | 6/25 | 0/25 | 95% | 81 | 0,006 | 10, 12, 11, 2, 8, 4, 3, 7, 6 | |
| | | 3/25 | 0/25 | 7/25 | 2/25 | 7/25 | 0/25 | 8/25 | 1/25 | 88% | 25 | 0,003 | | |
| NFHB-Class ¹ | Basalto3 | 5/25 | 1/25 | 10/25 | 5/25 | 5/25 | 0/25 | 11/25 | 1/25 | 79% | 96 | 0,004 | 2, 8, 9, 12, 11, 6, 5, 3, 1, 10, 7, 4 | |
| | | 0/25 | 0/25 | 2/25 | 0/25 | 8/25 | 0/25 | 11/25 | 0/25 | 98% | 61 | 0,009 | | |
| NFHB-Class ¹ | Basalto4 | 5/25 | 0/25 | 4/25 | 1/25 | 11/25 | 0/25 | 7/25 | 8/25 | 86% | 81 | 0,01 | 14, 15, 13, 16, 17, 18, 19, 20, 22, 21, 23 | |
| | | 3/25 | 0/25 | 4/25 | 2/25 | 10/25 | 0/25 | 10/25 | 5/25 | 91% | 41 | 0,006 | | |
| NFHB-Class ² | | | | | | | | | | | | | | |

Tabela 7.6 Configurações das redes neurais utilizadas para as subclasses das rochas basalto.

| Conjunto de dados utilizados para teste | Número de camadas | Número de Neurônios na camada de entrada | Número de neurônios na primeira camada escondida | Número de neurônios na segunda camada escondida | Número de neurônios na camada de saída |
|---|-------------------|--|--|---|--|
| Basalto1 | 4 | 3 | 10 | 10 | 4 |
| Basalto2 | 4 | 9 | 10 | 10 | 4 |
| Basalto3 | 4 | 12 | 10 | 10 | 4 |
| Basalto4 | 4 | 11 | 10 | 10 | 4 |

Tabela 7.7 Desempenho das redes neurais, para a classe rocha basalto.

| Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | Erros no Conjunto de validação | Acerto Percentual | |
|---|----------------------------------|--------------------------------|----------------------------|-----------------------|
| | | | al conjunto de treinamento | conjunto de validação |
| Basalto1 | porfirítico amigdaloidal | 2/25 | 81% | 55% |
| | porfirítico | 17/25 | 100% | 86% |
| | afanítico afírico oxidado | 13/25 | 100% | 85% |
| | afanítico afírico | 13/25 | 96% | 67% |
| Basalto2 | porfirítico amigdaloidal | 2/25 | 0/25 | 0/25 |
| | porfirítico | 5/25 | 0/25 | 0/25 |
| | afanítico afírico oxidado | 4/25 | 0/25 | 0/25 |
| | afanítico afírico | 8/25 | 0/25 | 1/25 |
| Basalto3 | porfirítico amigdaloidal | 2/25 | 0/25 | 0/25 |
| | porfirítico | 5/25 | 0/25 | 0/25 |
| | afanítico afírico oxidado | 4/25 | 0/25 | 0/25 |
| | afanítico afírico | 8/25 | 0/25 | 1/25 |
| Basalto4 | porfirítico amigdaloidal | 2/25 | 0/25 | 0/25 |
| | porfirítico | 5/25 | 0/25 | 0/25 |
| | afanítico afírico oxidado | 4/25 | 0/25 | 0/25 |
| | afanítico afírico | 8/25 | 0/25 | 1/25 |

Tabela 7.8 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para a classe rocha basalto.

| Modelo | Rocha Basalto | |
|-------------------------|--|--|
| | Melhor desempenho para o conjunto de treinamento | Melhor Desempenho para o conjunto de validação |
| NFHB-Class ¹ | 95% | 87% |
| NFHB-Class ² | 88% | 84% |
| Redes neurais | 100% | 86% |

A partir da Tabela 7.8, observa-se que o melhor desempenho de validação, para rocha basalto, foi encontrado com o modelo NFHB-Class¹ (estratégia de seleção fixa).

7.2.3. Rocha Diabásio

A seguir serão apresentados os resultados obtidos com o modelos NFHB-Class¹ (estratégia de seleção de características fixa) e NFHB-Class² (estratégia de seleção de características adaptativa) para a classificação da base de dados dos descritores de textura da rocha diabásio. Na tabela as classes 1, 2, 3, 4 e 5 referem-se as classes: diabásio amigdaloidal alterado, diabásio equigranular, diabásio porfirítico, diabásio porfirítico alterado e diabásio porfirítico amigdaloidal, respectivamente. Os atributos estão codificados por: 1 – Coeficiente de Hurst para tons de cinza, 2 – Coeficiente de Hurst canal Red, 3 – Coeficiente de Hurst canal Green, 4 – Coeficiente de Hurst canal Blue, 5 – CVE para tons de cinza, 6 – CVE para canal Red, 7 – CVE para canal Green, 8 – CVE para canal Blue, 9 – Entropia da Imagem em tons de cinza, 10 – Entropia da Imagem canal Red, 11 – Entropia da Imagem canal Green, 12 – Entropia da Imagem canal Blue, 13 – Maior valor do descritor contraste encontrado na matriz de coocorrência, 14 – Área do descritor contraste encontrado na matriz de coocorrência, 15 – Maior valor do descritor correlação encontrado

na matriz de coocorrência, 16 – Área do descritor correlação encontrada na matriz de coocorrência, 17 – Maior valor do descritor energia encontrado na matriz de coocorrência, 18 – Área do descritor energia encontrado na matriz de coocorrência, 19 – Maior valor do descritor entropia encontrado na matriz de coocorrência, 20 Valor da distância onde foi encontrado o maior valor do descritor entropia encontrado na matriz de coocorrência, 21 – Área do descritor entropia encontrado na matriz de coocorrência, 22 – Maior valor do descritor homogeneidade encontrado na matriz de coocorrência, 23 – Área do descritor homogeneidade encontrado na matriz de coocorrência.

Os conjuntos de dados utilizados nas Tabela 7.9, Tabela 7.10 e Tabela 7.11 são interpretados por:

- Diabásio1: Teste feito com a base dados contendo somente como atributos os coeficientes para tons de cinza.
- Diabásio2: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB.
- Diabásio3: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB e os coeficientes para tons de cinza.
- Diabásio4: Teste feito com a base dados contendo somente como atributos os extraídos das matrizes de coocorrência.

A Tabela 7.9 resume os resultados de classificação obtidos para os dados das rochas diabásio, utilizando os modelos NFHB-Class com estratégia de seleção de características fixa e adaptativa.

A Tabela 7.10 mostra as configurações das redes neurais utilizadas para as bases de dados Diabásio1, Diabásio2, Diabásio3 e Diabásio4.

Tabela 7.9 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das subclasses das rochas diabásio.

| Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | | | | | Erros no Conjunto de validação | | | | | Acerto Percentual conjunto de treinam. | Acerto Percent. conjunto de valida. | Núm. de regras gerad. | Taxa de decomp. | Ordem dos atributos utilizados |
|---|----------------------------------|--------------|-------------|----------------------|--------------------------|--------------------------------|--------------|-------------|----------------------|--------------------------|--|-------------------------------------|-----------------------|-----------------|--|
| | amigdaloidal alterado | equigranular | porfirítico | porfirítico alterado | porfirítico amigdaloidal | amigdaloidal alterado | equigranular | porfirítico | porfirítico alterado | porfirítico amigdaloidal | | | | | |
| Diabásio1 | 9/25 | 2/25 | 10/25 | 10/25 | 12/25 | 11/25 | 10/25 | 9/25 | 10/25 | 15/25 | 65.6% | 56% | 26 | 0,03 | 1, 5, 9 |
| | 4/25 | 0/25 | 1/25 | 3/25 | 4/25 | 13/25 | 7/25 | 10/25 | 9/25 | 15/25 | 90.4% | 56.8% | 87 | 0,009 | |
| Diabásio2 | 3/25 | 4/25 | 5/25 | 5/25 | 6/25 | 4/25 | 2/25 | 6/25 | 9/25 | 15/25 | 81.6% | 71.2% | 110 | 0,006 | 4, 7, 6, 3, 8, 2, 12, 10, 11 |
| | 1/25 | 1/25 | 2/25 | 1/25 | 5/25 | 3/25 | 6/25 | 5/25 | 4/25 | 15/25 | 9.2% | 73.6% | 83 | 0,002 | |
| Diabásio3 | 1/25 | 3/25 | 2/25 | 3/25 | 8/25 | 5/25 | 7/25 | 4/25 | 8/25 | 14/25 | 85.6% | 69.6% | 63 | 0,003 | 4, 7, 6, 5, 3, 1, 8, 2, 9, 10, 11, 12 |
| | 0/25 | 2/25 | 3/25 | 4/25 | 4/25 | 4/25 | 8/25 | 4/25 | 5/25 | 16/25 | 89.6% | 70.4% | 62 | 0,0003 | |
| Diabásio4 | 5/25 | 14/25 | 6/25 | 6/25 | 6/25 | 7/25 | 16/25 | 5/25 | 7/25 | 6/25 | 70.4% | 67.2% | 64 | 0,008 | 19, 21, 16, 17, 22, 14, 15, 23, 18, 20, 13 |
| | 4/25 | 8/25 | 5/25 | 7/25 | 7/25 | 5/25 | 16/25 | 4/25 | 9/25 | 725 | 75.2% | 67.2% | 35 | 0,009 | |

Tabela 7.10 Configurações das redes neurais utilizadas para as subclasses das rochas diabásio.

| Conjunto de dados utilizados para teste | Número de camadas | Número de Neurônios na camada de entrada | Número de neurônios na primeira camada escondida | Número de neurônios na segunda camada escondida | Número de neurônios na camada de saída |
|---|-------------------|--|--|---|--|
| Diabásio1 | 4 | 3 | 20 | 15 | 5 |
| Diabásio2 | 4 | 9 | 20 | 15 | 5 |
| Diabásio3 | 4 | 12 | 20 | 25 | 5 |
| Diabásio4 | 4 | 11 | 20 | 15 | 5 |

Tabela 7.11 Desempenho das redes neurais, para as subclasses das rochas diabásio.

| Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | Erros no Conjunto de validação | Acerto Percentual | |
|---|----------------------------------|--------------------------------|--------------------------|-----------------------|
| | | | Conjunto de treinamento. | conjunto de validação |
| Diabásio1 | porfírico amigdaloidal | 15/25 | 13/25 | 51,2% |
| | porfírico alterado | 13/25 | 6/25 | 73,6% |
| | porfírico | 13/25 | 6/25 | 69,6% |
| | equigranular | 9/25 | 8/25 | 68% |
| | amigdaloidal alterado | 11/25 | 5/25 | 54,4% |
| Diabásio2 | porfírico amigdaloidal | 7/25 | 4/25 | |
| | porfírico alterado | 6/25 | 1/25 | |
| | porfírico | 12/25 | 2/25 | |
| | equigranular | 2/25 | 0/25 | |
| | amigdaloidal alterado | 6/25 | 1/25 | |
| Diabásio3 | porfírico amigdaloidal | 7/25 | 4/25 | |
| | porfírico alterado | 6/25 | 1/25 | |
| | porfírico | 12/25 | 2/25 | |
| | equigranular | 2/25 | 0/25 | |
| | amigdaloidal alterado | 6/25 | 1/25 | |
| Diabásio 4 | porfírico amigdaloidal | 7/25 | 4/25 | |
| | porfírico alterado | 6/25 | 1/25 | |
| | porfírico | 12/25 | 2/25 | |
| | equigranular | 2/25 | 0/25 | |
| | amigdaloidal alterado | 6/25 | 1/25 | |

A Tabela 7.12 resume o desempenho das redes neurais e dos modelos NFHB-SubClass e NFHB-Class com estratégias de seleção fixa (NFHB-SubClass¹ e NFHB-Class¹) e adaptativa (NFHB-SubClass² e NFHB-Class²). Essa tabela foi elaborada com base no maior acerto percentual do conjunto de validação para cada modelo.

Tabela 7.12 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para a classe rocha diabásio.

| Modelo | Rocha Diabásio | |
|-------------------------|--|--|
| | Melhor desempenho para o conjunto de treinamento | Melhor Desempenho para o conjunto de validação |
| NFHB-Class ¹ | 81,6 % | 71,2 % |
| NFHB-Class ² | 92 % | 73,6 % |
| Redes neurais | 93,6% | 69,6% |

A partir da Tabela 7.12, observa-se que o melhor desempenho de validação, para a rocha diabásio, foi encontrado com o modelo NFHB-Class² (estratégia de seleção adaptativa).

7.2.4. Rocha Riolito

A seguir serão apresentados os resultados obtidos com o modelos NFHB-Class¹ (estratégia de seleção de características fixa) e NFHB-Class² (estratégia de seleção de características adaptativa) para a classificação da base de dados dos descritores de textura da rocha riolito. Na tabela as classes 1, 2, 3, 4 e 5 referem-se as classes: riolito alterado, riolito amigdaloidal, riolito porfirítico, riolito porfirítico amigdaloidal e riolito porfirítico amigdaloidal venulado, respectivamente. Os atributos estão codificados por: 1 –

Coeficiente de Hurst para tons de cinza, 2 – Coeficiente de Hurst canal Red, 3 – Coeficiente de Hurst canal Green, 4 – Coeficiente de Hurst canal Blue, 5 – CVE para tons de cinza, 6 – CVE para canal Red, 7 – CVE para canal Green, 8 – CVE para canal Blue, 9 – Entropia da Imagem em tons de cinza, 10 – Entropia da Imagem canal Red, 11 – Entropia da Imagem canal Green, 12 – Entropia da Imagem canal Blue, 13 – Maior valor do descritor contraste encontrado na matriz de coocorrência, 14 – Área do descritor contraste encontrado na matriz de coocorrência, 15 – Maior valor do descritor correlação encontrado na matriz de coocorrência, 16 – Área do descritor correlação encontrada na matriz de coocorrência, 17 – Maior valor do descritor energia encontrado na matriz de coocorrência, 18 – Área do descritor energia encontrado na matriz de coocorrência, 19 – Maior valor do descritor entropia encontrado na matriz de coocorrência, 20 Valor da distância onde foi encontrado o maior valor do descritor entropia encontrado na matriz de coocorrência, 21 – Área do descritor entropia encontrado na matriz de coocorrência, 22 – Maior valor do descritor homogeneidade encontrado na matriz de coocorrência, 23 – Área do descritor homogeneidade encontrado na matriz de coocorrência.

Os conjuntos de dados utilizados nas Tabela 7.13, Tabela 7.14 e Tabela 7.15 são interpretados por:

- Riolito1: Teste feito com a base dados contendo somente como atributos os coeficientes para tons de cinza.
- Riolito2: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB.
- Riolito3: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB e os coeficientes para tons de cinza.

- Riolito4: Teste feito com a base dados contendo somente como atributos os extraídos das matrizes de coocorrência

A Tabela 7.13 resume os resultados de classificação obtidos para os dados das rochas riolito, utilizando os modelos NFHB-Class com estratégia de seleção de características fixa e adaptativa.

Tabela 7.13 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das subclasses das rochas riolito.

| Modelo | Conj. de dados utiliz. para teste | Erros no conjunto de treinamento | | | | | Erros no Conjunto de validação | | | | | Acerto Percent. conjunto de treinam. | Acerto Percent. conjunto de validação | Núm de regras gerad. | Taxa de decomp | Ordem dos atributos utilizados |
|-------------------------|-----------------------------------|----------------------------------|--------------|-----------|------------------------|---------------------------------|--------------------------------|--------------|-----------|------------------------|---------------------------------|--------------------------------------|---------------------------------------|----------------------|----------------|--|
| | | alterado | amigdaloidal | porfírico | porfírico amigdaloidal | porfírico amigdaloidal venulado | alterado | amigdaloidal | porfírico | porfírico amigdaloidal | porfírico amigdaloidal venulado | | | | | |
| NFHB-Class ¹ | Riolito1 | 10/25 | 5/25 | 12/25 | 9/25 | 3/25 | 13/25 | 10/25 | 10/25 | 15/25 | 4/25 | 68,8% | 56,8% | 97 | 0,008 | 5, 9, 1 |
| | | 3/25 | 1/25 | 4/25 | 5/25 | 2/25 | 12/25 | 10/25 | 10/25 | 10/25 | 8/25 | 88% | 60,8% | 133 | 0,005 | |
| NFHB-Class ² | Riolito2 | 5/25 | 1/25 | 3/25 | 5/25 | 1/25 | 8/25 | 7/25 | 5/25 | 3/25 | 3/25 | 88% | 75,2% | 68 | 0,008 | 7, 8, 6, 11, 10, 4, 12, 2, 3 |
| | | 1/25 | 0/25 | 1/25 | 3/25 | 0/25 | 6/25 | 5/25 | 5/25 | 5/25 | 5/25 | 96% | 78,4% | 56 | 0,007 | |
| NFHB-Class ¹ | Riolito3 | 0/25 | 2/25 | 3/25 | 3/25 | 0/25 | 2/25 | 7/25 | 6/25 | 7/25 | 5/25 | 93,6% | 78,4% | 225 | 0,002 | 7, 8, 5, 6, 11, 10, 4, 9, 12, 2, 3, 1 |
| | | 0/25 | 0/25 | 0/25 | 0/25 | 0/25 | 5/25 | 3/25 | 8/25 | 9/25 | 4/25 | 100% | 76,8% | 108 | 0,007 | |
| NFHB-Class ² | Riolito4 | 5/25 | 6/25 | 6/25 | 11/25 | 2/25 | 4/25 | 8/25 | 11/25 | 13/25 | 5/25 | 76% | 67,2% | 85 | 0,009 | 21, 23, 14, 19, 18, 17, 13, 22, 15, 16, 20 |
| | | 6/25 | 12/25 | 9/25 | 12/25 | 5/25 | 6/25 | 6/25 | 10/25 | 10/25 | 6/25 | 64,8% | 69,6% | 17 | 0,01 | |

A Tabela 7.14 mostra as configurações das redes neurais utilizadas para as bases de dados Riolito1, Riolito2, Riolito3 e Riolito4.

Tabela 7.14 Configurações das redes neurais utilizadas para as subclasses das rochas riolito.

| Conjunto de dados utilizados para teste | Número de camadas | Número de Neurônios na camada de entrada | Número de neurônios na primeira camada escondida | Número de neurônios na segunda camada escondida | Número de neurônios na camada de saída |
|---|-------------------|--|--|---|--|
| Riolito1 | 4 | 3 | 20 | 15 | 5 |
| Riolito2 | 4 | 9 | 20 | 15 | 5 |
| Riolito3 | 4 | 12 | 20 | 15 | 5 |
| Riolito4 | 4 | 11 | 20 | 15 | 5 |

Tabela 7.15 Desempenho das redes neurais para as subclasses das rochas riolito.

| Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | Erros no Conjunto de validação | Acerto Percentual | |
|---|----------------------------------|--------------------------------|-------------------------|-----------------------|
| | | | conjunto de treinamento | conjunto de validação |
| Riolito1 | porfírico | 15/25 | 10/25 | 9/25 |
| | amigdaloidal | 13/25 | 7/25 | 12/25 |
| | alterado | 14/25 | 3/25 | 9/25 |
| | porfírico | 9/25 | 10/25 | 11/25 |
| | amigdaloidal venulado | 6/25 | 0/25 | 2/25 |
| Riolito2 | porfírico | 9/25 | 0/25 | 2/25 |
| | amigdaloidal | 3/25 | 1/25 | 11/25 |
| | alterado | 8/25 | 0/25 | 11/25 |
| | porfírico | 9/25 | 10/25 | 9/25 |
| | amigdaloidal venulado | 6/25 | 0/25 | 3/25 |
| Riolito3 | porfírico | 9/25 | 0/25 | 3/25 |
| | amigdaloidal | 3/25 | 0/25 | 11/25 |
| | alterado | 8/25 | 0/25 | 9/25 |
| | porfírico | 9/25 | 10/25 | 11/25 |
| | amigdaloidal venulado | 6/25 | 0/25 | 3/25 |
| Riolito4 | porfírico | 9/25 | 0/25 | 11/25 |
| | amigdaloidal | 3/25 | 0/25 | 11/25 |
| | alterado | 8/25 | 0/25 | 13/25 |
| | porfírico | 9/25 | 10/25 | 11/25 |
| | amigdaloidal venulado | 6/25 | 0/25 | 12/25 |
| | | | 76% | 75,2% |
| | | | 98,4% | 64% |
| | | | 88% | 59,2% |

A Tabela 7.16 resume o desempenho das redes neurais e dos modelos NFHB-SubClass e NFHB-Class com estratégias de seleção fixa (NFHB-SubClass¹ e NFHB-Class¹) e adaptativa (NFHB-SubClass² e NFHB-Class²). Essa tabela foi elaborada com base no maior acerto percentual do conjunto de validação para cada modelo.

Tabela 7.16 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para a classe rocha riolito.

| Rocha Riolito | | |
|-------------------------|--|--|
| Modelo | Melhor desempenho para o conjunto de treinamento | Melhor Desempenho para o conjunto de validação |
| NFHB-Class ¹ | 93,6 % | 78,4 % |
| NFHB-Class ² | 96 % | 78,4 % |
| Redes neurais | 97,6% | 75,2% |

A partir da Tabela 7.16, observa-se que o melhor desempenho de validação, para a rocha riolito, foi encontrado com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa).

7.2.5. Rochas Gnaiss e Basalto

A seguir serão apresentados os resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção de características fixa) e NFHB-Class² (estratégia de seleção de características adaptativa) para a classificação da base de dados dos descritores de textura das rochas gnaiss e basalto. Na tabela as classes 1 e 2 referem-se as classes macro: gnaiss e basalto, respectivamente. Como os resultados com os atributos extraídos das matrizes de coocorrência apresentaram resultados sempre inferiores em comparação aos outros

atributos, eles não foram mais utilizados nos testes de classificação. Os atributos estão codificados por: 1 – Coeficiente de Hurst para tons de cinza, 2 – Coeficiente de Hurst canal Red, 3 – Coeficiente de Hurst canal Green, 4 – Coeficiente de Hurst canal Blue, 5 – CVE para tons de cinza, 6 – CVE para canal Red, 7 – CVE para canal Green, 8 – CVE para canal Blue, 9 – Entropia da Imagem em tons de cinza, 10 – Entropia da Imagem canal Red, 11 – Entropia da Imagem canal Green, 12 – Entropia da Imagem canal Blue.

Os conjuntos de dados utilizados nas Tabela 7.17, Tabela 7.18 e Tabela 7.19 são interpretados por:

- Gnaisse e Basalto1: Teste feito com a base dados contendo somente como atributos os coeficientes para tons de cinza.
- Gnaisse e Basalto2: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB.
- Gnaisse e Basalto3: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB e os coeficientes para tons de cinza.

A Tabela 7.17 resume os resultados de classificação obtidos para os dados das rochas gnaisse e basalto, utilizando os modelos NFHB-Class com estratégia de seleção de características fixa e adaptativa.

A Tabela 7.18 mostra as configurações das redes neurais utilizadas para as bases de dados Gnaisse e Basalto1, Gnaisse e Basalto2 e Gnaisse e Basalto3.

A Tabela 7.20 resume o desempenho das redes neurais e dos modelos NFHB-SubClass e NFHB-Class com estratégias de seleção fixa (NFHB-SubClass¹ e NFHB-

Class¹) e adaptativa (NFHB-SubClass² e NFHB-Class²). Essa tabela foi elaborada com base no maior acerto percentual do conjunto de validação para cada modelo.

Tabela 7.17 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das classes das rochas gnaisse e basalto.

| Modelo | Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | | Erros no conjunto de validação | | Acerto Percentual de conjunto de treinamento | Acerto Percentual de conjunto de validação | Número de regras geradas | Taxa de decomp. | Ordem dos atributos utilizados |
|-------------------------|---|----------------------------------|---------|--------------------------------|---------|--|--|--------------------------|-----------------|---------------------------------------|
| | | Gnaisse | Basalto | Gnaisse | Basalto | | | | | |
| NFHB-Class ¹ | Gnaisse e Basalto1 | 7/50 | 7/100 | 11/50 | 7/100 | 90,67 % | 88 % | 37 | 0,02 | 1, 5, 9 |
| NFHB-Class ² | | 6/50 | 6/100 | 12/50 | 9/100 | 92 % | 86 % | 46 | 0,01 | |
| NFHB-Class ¹ | Gnaisse e Basalto2 | 3/50 | 3/100 | 3/50 | 3/100 | 96 % | 96 % | 53 | 0,007 | 4, 7, 10, 3, 2, 11, 8, 6, 12 |
| NFHB-Class ² | | 2/50 | 9/100 | 1/50 | 6/100 | 92,67 % | 95,33 % | 22 | 0,02 | |
| NFHB-Class ¹ | Gnaisse e Basalto3 | 2/50 | 6/100 | 4/50 | 11/100 | 94,67 % | 90 % | 68 | 0,009 | 4, 7, 10, 2, 11, 5, 3, 1, 9, 8, 6, 12 |
| NFHB-Class ² | | 0/50 | 2/100 | 2/50 | 3/100 | 98,67 % | 96,67 % | 68 | 0,008 | |

Tabela 7.18 Configurações das redes neurais utilizadas para as subclasses das rochas gnaisse e basalto.

| Conjunto de dados utilizados para teste | Número de camadas | Número de Neurônios na camada de entrada | Número de neurônios na primeira camada escondida | Número de neurônios na camada de saída |
|---|-------------------|--|--|--|
| Gnaisse e basalto1 | 3 | 3 | 6 | 2 |
| Gnaisse e basalto2 | 3 | 9 | 10 | 2 |
| Gnaisse e basalto3 | 3 | 12 | 10 | 2 |

Tabela 7.19 Desempenho das redes neurais, para as subclasses das rochas gnaisse e basalto.

| Conjunto de dados utilizados para teste | | Erros no conjunto de treinamento | Erros no Conjunto de validação | Acerto |
|---|---------|----------------------------------|--------------------------------|---------------------------------------|
| | | | | Percentual de conjunto de treinamento |
| Gnaisse e Basalto1 | Gnaisse | 5/50 | 16/50 | 80% |
| | Basalto | 6/100 | 14/100 | |
| Gnaisse e Basalto2 | Gnaisse | 0/50 | 3/50 | 94% |
| | Basalto | 0/100 | 6/100 | |
| Gnaisse e Basalto3 | Gnaisse | 0/50 | 4/50 | 94% |
| | Basalto | 0/100 | 5/100 | |

Tabela 7.20 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para as classes de rochas gnaisse e basalto.

| Modelo | Rocha Gnaiss e Basalto | |
|-------------------------|--|--|
| | Melhor desempenho para o conjunto de treinamento | Melhor Desempenho para o conjunto de validação |
| NFHB-Class ¹ | 96 % | 96 % |
| NFHB-Class ² | 98,67 % | 96,67 % |
| Redes neurais | 100 % | 94 % |

A partir da Tabela 7.20, observa-se que o melhor desempenho de validação, para a rocha gnaisse e basalto, foi encontrado com o modelo NFHB-Class² (estratégia de seleção adaptativa).

7.2.6. Rochas Diabásio e Riolito

A seguir serão apresentados os resultados obtidos com o modelos NFHB-Class¹ (estratégia de seleção de características fixa) e NFHB-Class² (estratégia de seleção de características adaptativa) para a classificação da base de dados dos descritores de textura das rochas diabásio e riolito. Na tabela as classes 1 e 2 referem-se as classes macro: diabásio e riolito, respectivamente. Os atributos estão codificados por: 1 – Coeficiente de Hurst para tons de cinza, 2 – Coeficiente de Hurst canal Red, 3 – Coeficiente de Hurst canal Green, 4 – Coeficiente de Hurst canal Blue, 5 – CVE para tons de cinza, 6 – CVE para canal Red, 7 – CVE para canal Green, 8 – CVE para canal Blue, 9 – Entropia da Imagem em tons de cinza, 10 – Entropia da Imagem canal Red, 11 – Entropia da Imagem canal Green, 12 – Entropia da Imagem canal Blue.

Os conjuntos de dados utilizados nas Tabela 7.21, Tabela 7.22 e Tabela 7.23 são interpretados por:

- Diabásio e Riolito1: Teste feito com a base dados contendo somente como atributos os coeficientes para tons de cinza
- Diabásio e Riolito2: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB
- Diabásio e Riolito3: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB e os coeficientes para tons de cinza

A Tabela 7.21 resume os resultados de classificação obtidos para os dados das rochas diabásio e riolito, utilizando os modelos NFHB-Class com estratégia de seleção de características fixa e adaptativa.

A Tabela 7.22 mostra as configurações das redes neurais utilizadas para as bases de dados Diabásio e Riolito1, Diabásio e Riolito2 e Diabásio e Riolito3.

A Tabela 7.24 resume o desempenho das redes neurais e dos modelos NFHB-SubClass e NFHB-Class com estratégias de seleção fixa (NFHB-SubClass¹ e NFHB-Class¹) e adaptativa (NFHB-SubClass² e NFHB-Class²). Essa tabela foi elaborada com base no maior acerto percentual do conjunto de validação para cada modelo.

Tabela 7.21 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das classes das rochas diabásio e riolito.

| Modelo | Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | | Erros no conjunto de validação | | Acerto Percentual conjunto de treinamento | Acerto Percentual de conjunto de validação | Número de regras geradas | Taxa de decomp. | Ordem dos atributos utilizados |
|-------------------------|---|----------------------------------|---------|--------------------------------|---------|---|--|--------------------------|-----------------|--------------------------------------|
| | | Diabásio | Riolito | Diabásio | Riolito | | | | | |
| NFHB-Class ¹ | Diabásio e Riolito1 | 41/125 | 34/125 | 51/125 | 28/125 | 70 % | 68,4 % | 29 | 0,02 | 5, 9, 1 |
| NFHB-Class ² | | 33/125 | 18/125 | 49/125 | 25/125 | 79,6 % | 70,4 % | 83 | 0,008 | |
| NFHB-Class ¹ | Diabásio e Riolito2 | 20/125 | 26/125 | 15/125 | 20/125 | 81,6 % | 86 % | 22 | 0,02 | 6, 7, 8, 10, 11, 12, 2, 3,4 |
| NFHB-Class ² | | 10/125 | 22/125 | 12/125 | 23/125 | 87,2 % | 86 % | 33 | 0,01 | |
| NFHB-Class ¹ | Diabásio e Riolito3 | 15/125 | 17/125 | 14/125 | 23/125 | 87,2 % | 85,2 % | 59 | 0,009 | 5, 7, 6, 8, 10, 9, 11, 12, 2, 1, 3,4 |
| NFHB-Class ² | | 11/125 | 24/125 | 15/125 | 22/125 | 86 % | 85,2 % | 25 | 0,03 | |

Tabela 7.22 Configurações das redes neurais utilizadas para as subclasses das rochas diabásio e riolito.

| Conjunto de dados utilizados para teste | Número de camadas | Número de Neurônios na camada de entrada | Número de neurônios na primeira camada escondida | Número de neurônios na segunda camada escondida | Número de neurônios na camada de saída |
|---|-------------------|--|--|---|--|
| Diabásio e Riolito1 | 4 | 3 | 20 | 25 | 2 |
| Diabásio e Riolito2 | 4 | 9 | 25 | 20 | 2 |
| Diabásio e Riolito3 | 4 | 12 | 20 | 25 | 2 |

Tabela 7.23 Desempenho das redes neurais, para as subclasses das rochas diabásio e riolito.

| Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | Acerto Percentual conjunto de treinamento | Erros no conjunto de validação | | Acerto Percentual conjunto de validação |
|---|----------------------------------|---|--------------------------------|---------|---|
| | | | Diabásio | Riolito | |
| Diabásio e Riolito1 | Diabásio | 23/125 | 42/125 | 28/125 | 72% |
| | Riolito | 21/125 | 17/125 | 20/125 | |
| Diabásio e Riolito2 | Diabásio | 0/125 | 17/125 | 20/125 | 85,2% |
| | Riolito | 2/125 | 19/125 | 20/125 | |
| Diabásio e Riolito3 | Diabásio | 7/125 | 19/125 | 20/125 | 84,4% |
| | Riolito | 5/125 | 17/125 | 20/125 | |

Tabela 7.24 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para as classes de rochas diabásio e riolito.

| Modelo | Rocha Diabásio e Riolito | |
|-------------------------|--|--|
| | Melhor desempenho para o conjunto de treinamento | Melhor Desempenho para o conjunto de validação |
| NFHB-Class ¹ | 81,6 % | 86 % |
| NFHB-Class ² | 87,2 % | 86 % |
| Redes neurais | 99,2% | 85,2 % |

A partir da Tabela 7.24, observa-se que o melhor desempenho de validação, para as rochas diabásio e riolito, foi encontrado com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa).

7.2.7. Rochas Basalto, Diabásio e Riolito

A seguir serão apresentados os resultados obtidos com o modelos NFHB-Class¹ (estratégia de seleção de características fixa) e NFHB-Class² (estratégia de seleção de características adaptativa) para a classificação da base de dados dos descritores de textura das rochas basalto, diabásio e riolito. Na tabela as classes 1, 2, 3 referem-se as classes macro: basalto, diabásio e riolito, respectivamente. Os atributos estão codificados por: 1 – Coeficiente de Hurst para tons de cinza, 2 – Coeficiente de Hurst canal Red, 3 – Coeficiente de Hurst canal Green, 4 – Coeficiente de Hurst canal Blue, 5 – CVE para tons de cinza, 6 – CVE para canal Red, 7 – CVE para canal Green, 8 – CVE para canal Blue, 9 – Entropia da Imagem em tons de cinza, 10 – Entropia da Imagem canal Red, 11 – Entropia da Imagem canal Green, 12 – Entropia da Imagem canal Blue.

Os conjuntos de dados utilizados nas Tabela 7.25, Tabela 7.26 e Tabela 7.27 são interpretados por:

- Basalto, diabásio e riolito1: Teste feito com a base dados contendo somente como atributos os coeficientes para tons de cinza.
- Basalto, diabásio e riolito2: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB.
- Basalto, diabásio e riolito3: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB e os coeficientes para tons de cinza.

A Tabela 7.25 resume os resultados de classificação obtidos para os dados das rochas basalto, diabásio e riolito, utilizando os modelos NFHB-Class com estratégia de seleção de características fixa e adaptativa.

A Tabela 7.26 mostra as configurações das redes neurais utilizadas para as bases de dados Basalto, Diabásio e Riolito1; Basalto, Diabásio e Riolito2 e Basalto, Diabásio e Riolito3.

A Tabela 7.28 resume o desempenho das redes neurais e dos modelos NFHB-SubClass e NFHB-Class com estratégias de seleção fixa (NFHB-SubClass¹ e NFHB-Class¹) e adaptativa (NFHB-SubClass² e NFHB-Class²). Essa tabela foi elaborada com base no maior acerto percentual do conjunto de validação para cada modelo.

Tabela 7.25 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das classes das rochas basalto, diabásio e riolito.

| Modelo | Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | | | Erros no conjunto de validação | | | Acerto conjunto de treinamento | Acerto Percentual conjunto de validação | Número de regras geradas | Taxa de decomposição | Ordem dos atributos utilizados |
|-------------------------|---|----------------------------------|----------|---------|--------------------------------|----------|---------|--------------------------------|---|--------------------------|----------------------|---------------------------------------|
| | | Basalto | Diabásio | Riolito | Basalto | Diabásio | Riolito | | | | | |
| NFHB-Class ¹ | Basalto, diabásio e riolito1 | 28/100 | 62/125 | 33/125 | 32/100 | 63/125 | 40/125 | 64,86% | 61,43% | 34 | 0,006 | 5, 9, 1 |
| NFHB-Class ² | | 24/100 | 53/125 | 27/125 | 28/100 | 68/125 | 41/125 | 70,29% | 60,86% | 67 | 0,009 | |
| NFHB-Class ¹ | Basalto, diabásio e riolito2 | 19/100 | 15/125 | 22/125 | 23/100 | 19/125 | 26/125 | 84% | 80,57% | 77 | 0,008 | 6, 10, 7, 8, 2, 11, 3, 12, 4 |
| NFHB-Class ² | | 15/100 | 15/125 | 25/125 | 19/100 | 21/125 | 29/125 | 84,29% | 80,29% | 33 | 0,005 | |
| NFHB-Class ¹ | Basalto, diabásio e riolito3 | 16/100 | 15/125 | 22/125 | 18/100 | 20/125 | 30/125 | 84,86% | 80,57% | 98 | 0,006 | 6, 10, 5, 7, 8, 9, 2, 11, 1, 3, 12, 4 |
| NFHB-Class ² | | 13/100 | 18/125 | 28/125 | 20/100 | 21/125 | 33/125 | 83,14% | 78,86% | 50 | 0,006 | |

Tabela 7.26 Configurações das redes neurais utilizadas para as subclasses das rochas basalto, diabásio e riolito.

| Conjunto de dados utilizados para teste | Número de camadas | Número de Neurônios na camada de entrada | Número de neurônios na primeira camada escondida | Número de neurônios na segunda camada escondida | Número de neurônios na camada de saída |
|---|-------------------|--|--|---|--|
| Basalto, Diabásio e Riolito1 | 4 | 3 | 40 | 30 | 3 |
| Basalto, Diabásio e Riolito2 | 4 | 9 | 40 | 30 | 3 |
| Basalto, Diabásio e Riolito3 | 4 | 12 | 40 | 30 | 3 |

Tabela 7.27 Desempenho das redes neurais, para as subclasses das rochas basalto, diabásio e riolito.

| Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | Erros no Conjunto de validação | Acerto | |
|---|----------------------------------|--------------------------------|---------------------------------------|-------------------------------------|
| | | | Percentual de conjunto de treinamento | Percentual de conjunto de validação |
| Basalto, Diabásio e Riolito1 | Basalto | 28/100 | 75,14% | 60,85% |
| | Diabásio | 62/125 | 97,42% | 77,42% |
| | Riolito | 47/125 | 99,42% | 77,14% |
| Basalto, Diabásio e Riolito2 | Basalto | 26/100 | 97,42% | 77,42% |
| | Diabásio | 21/125 | 99,42% | 77,14% |
| | Riolito | 32/125 | 99,42% | 77,14% |
| Basalto, Diabásio e Riolito3 | Basalto | 21/100 | 99,42% | 77,14% |
| | Diabásio | 30/125 | 99,42% | 77,14% |
| | Riolito | 29/125 | 99,42% | 77,14% |

Tabela 7.28 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para as classes de rochas basalto, diabásio e riolito.

| Modelo | Rocha Basalto, Diabásio e Riolito | |
|-------------------------|--|--|
| | Melhor desempenho para o conjunto de treinamento | Melhor Desempenho para o conjunto de validação |
| NFHB-Class ¹ | 84% | 80,57% |
| NFHB-Class ² | 84,29% | 80,29% |
| Redes neurais | 97,42% | 77,42% |

A partir da Tabela 7.28, observa-se que o melhor desempenho de validação, para as rochas basalto, diabásio e riolito, foi encontrado com o modelo NFHB-Class¹ (estratégia de seleção fixa).

7.2.8. Rochas Gnaiss, Basalto, Diabásio e Riolito

A seguir serão apresentados os resultados obtidos com o modelos NFHB-Class¹ (estratégia de seleção de características fixa) e NFHB-Class² (estratégia de seleção de características adaptativa) para a classificação da base de dados dos descritores de textura das rochas gnaiss, basalto, diabásio e riolito. Na tabela as classes 1, 2, 3 e 4 referem-se as classes macro: gnaiss, basalto, diabásio e riolito, respectivamente. Os atributos estão codificados por: 1 – Coeficiente de Hurst para tons de cinza, 2 – Coeficiente de Hurst canal Red, 3 – Coeficiente de Hurst canal Green, 4 – Coeficiente de Hurst canal Blue, 5 – CVE para tons de cinza, 6 – CVE para canal Red, 7 – CVE para canal Green, 8 – CVE para canal Blue, 9 – Entropia da Imagem em tons de cinza, 10 – Entropia da Imagem canal Red, 11 – Entropia da Imagem canal Green, 12 – Entropia da Imagem canal Blue.

Os conjuntos de dados utilizados nas Tabela 7.29, Tabela 7.30 e Tabela 7.31 são interpretados por:

- Gnaisse, basalto, diabásio e riolito1: Teste feito com a base dados contendo somente como atributos os coeficientes para tons de cinza.
- Gnaisse, basalto, diabásio e riolito2: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB.
- Gnaisse, basalto, diabásio e riolito3: Teste feito com a base dados contendo somente como atributos os coeficientes para os canais RGB e os coeficientes para tons de cinza.

A Tabela 7.29 resume os resultados de classificação obtidos para os dados das rochas gnaisse, basalto, diabásio e riolito utilizando os modelos NFHB-Class com estratégia de seleção de características fixa e adaptativa.

A Tabela 7.30 mostra as configurações das redes neurais utilizadas para as bases de dados Basalto, Diabásio e Riolito1; Basalto, Diabásio e Riolito2; e Basalto, Diabásio e Riolito3.

A Tabela 7.32 resume o desempenho das redes neurais e dos modelos NFHB-SubClass e NFHB-Class com estratégias de seleção fixa (NFHB-SubClass¹ e NFHB-Class¹) e adaptativa (NFHB-SubClass² e NFHB-Class²). Essa tabela foi elaborada com base no maior acerto percentual do conjunto de validação para cada modelo.

Tabela 7.29 Resultados obtidos com os modelos NFHB-Class¹ (estratégia de seleção fixa) e NFHB-Class² (estratégia de seleção adaptativa), para classificação das classes das rochas gnaiss, basalto, diabásio e riolito.

| Erros no conjunto de treinamento | | Erros no Conjunto de validação | | | | Acerto Percentual de conjunto de treinamento | Acerto Percentual de conjunto de validação | Número de regras geradas | Taxa de composição | Ordem dos atributos utilizados |
|----------------------------------|---------|--------------------------------|---------|--------|---------|--|--|--------------------------|--------------------|---------------------------------------|
| Gnaiss | Basalto | Diabásio | Riolito | Gnaiss | Basalto | | | | | |
| 39/50 | 65/100 | 41/125 | 39/125 | 41/50 | 65/100 | 42/125 | 43/125 | 55 | 0,004 | 5, 9, 1 |
| 36/50 | 57/100 | 38/125 | 40/125 | 38/50 | 56/100 | 40/125 | 39/125 | 51 | 0,003 | |
| 36/50 | 18/100 | 17/125 | 21/125 | 33/50 | 22/100 | 19/125 | 23/125 | 105 | 0,007 | 6, 10, 7, 11, 12, 8, 2, 3, 4 |
| 22/50 | 13/100 | 14/125 | 16/125 | 26/50 | 22/100 | 20/125 | 21/125 | 79 | 0,006 | |
| 32/50 | 21/100 | 19/125 | 25/125 | 31/50 | 24/100 | 22/125 | 26/125 | 92 | 0,008 | 6, 10, 5, 7, 8, 9, 2, 11, 1, 3, 12, 4 |
| 28/50 | 19/100 | 18/125 | 17/125 | 30/50 | 20/100 | 23/125 | 29/125 | 80 | 0,006 | |

Pode-se perceber através da tabela acima que o sistema NFHB-Class não conseguiu “aprender” os padrões da classe 1 (Gnaisse). Isso se deu devido ao fato de que a proporção de padrões da classe 1 apresentado ao sistema para treinamento foi muito menor que a quantidade de padrões das outras classes. Apenas 50 padrões da classe 1 (gnaisse), 100 padrões da classe 2 (basalto), 125 padrões da classe 3 (diabásio), 125 padrões da classe 4 (riolito). Para solucionar esse problema, optou-se por repetir os padrões da classe 1 para treinar o modelo NFHB-Class.

Tabela 7.30 Configurações das redes neurais utilizadas para as subclasses das rochas gnaisse, basalto, diabásio e riolito.

| Conjunto de dados utilizados para teste | Número de camadas | Número de Neurônios na camada de entrada | Número de neurônios na primeira camada escondida | Número de neurônios na segunda camada escondida | Número de neurônios na camada de saída |
|---|-------------------|--|--|---|--|
| Gnaisse, Basalto, Diabásio e Riolito1 | 4 | 3 | 40 | 40 | 4 |
| Gnaisse, Basalto, Diabásio e Riolito2 | 4 | 9 | 40 | 40 | 4 |
| Gnaisse, Basalto, Diabásio e Riolito3 | 4 | 12 | 40 | 40 | 4 |

Tabela 7.31 Desempenho das redes neurais para as subclasses das rochas gnaisse, basalto, diabásio e riolito.

| Conjunto de dados utilizados para teste | Erros no conjunto de treinamento | | | | Erros no Conjunto de validação | | | | Acerto Percentual de conjunto de treinamento | Acerto Percentual de conjunto de validação |
|---|----------------------------------|---------|----------|---------|--------------------------------|---------|----------|---------|--|--|
| | Gnaisse | Basalto | Diabásio | Riolito | Gnaisse | Basalto | Diabásio | Riolito | | |
| Gnaisse, Basalto, Diabásio e Riolito1 | 33/50 | 21/100 | 51/125 | 33/125 | 40/50 | 31/100 | 67/125 | 47/125 | 65,5% | 53,75% |
| Gnaisse, Basalto, Diabásio e Riolito2 | 0/50 | 1/100 | 7/125 | 4/125 | 17/50 | 15/100 | 31/125 | 29/125 | 97% | 77% |
| Gnaisse, Basalto, Diabásio e Riolito3 | 0/50 | 1/100 | 0/125 | 0/125 | 22/50 | 19/100 | 45/125 | 39/125 | 99,75% | 68,75% |

Tabela 7.32 Melhor desempenho obtido pelos modelos NFHB-SubClass, NFHB-Class e redes neurais, para as classes de rochas gnaisse, basalto, diabásio e riolito.

| Modelo | Rocha Gnaisse, Basalto, Diabásio e Riolito | |
|-------------------------|--|--|
| | Melhor desempenho para o conjunto de treinamento | Melhor Desempenho para o conjunto de validação |
| NFHB-Class ¹ | 77% | 75,75% |
| NFHB-Class ² | 83,75% | 77,75% |
| Redes neurais | 97% | 77% |

A partir da Tabela 7.32, observa-se que o melhor desempenho de validação, para as rochas gnaisse, basalto, diabásio e riolito, foi encontrado com o modelo NFHB-Class².

7.3. Classificação das rochas através dos modelos NFHB-SubClass, RN-NFHB-SubClass e RN-SubClass

A seguir serão mostrados os resultados encontrados com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-SubClass. Esses modelos foram feitas a classificação macro e a subclassificação de cada uma das classes de rochas. Para a realização dos testes as bases de dados foram organizadas da seguinte forma:

Duas classes macros (gnaisse e basalto) com suas subclasses (gnaisse granítico, gnaisse leucocrático, basalto afanítico africo, basalto afanítico africo oxidado, basalto porfirítico e basalto porfirítico amigdaloidal).

Duas classes macros (diabásio e riolito) com suas subclasses (diabásio amigdaloidal alterado, diabásio equigranular, diabásio porfirítico, diabásio porfirítico alterado, diabásio porfirítico amigdaloidal, riolito alterado, riolito amigdaloidal, riolito porfirítico, riolito porfirítico amigdaloidal e riolito porfirítico amigdaloidal venulado).

Três classes macros (basalto, diabásio e riolito) com suas subclasses (basalto afanítico afírico, basalto afanítico afírico oxidado, basalto porfirítico, basalto porfirítico amigdaloidal, diabásio amigdaloidal alterado, diabásio equigranular, diabásio porfirítico, diabásio porfirítico alterado, diabásio porfirítico amigdaloidal, riolito alterado, riolito amigdaloidal, riolito porfirítico, riolito porfirítico amigdaloidal e riolito porfirítico amigdaloidal venulado).

Quatro classes macros (gnaisse, basalto, diabásio e riolito) com suas subclasses (gnaisse granítico, gnaisse leucocrático, basalto afanítico afírico, basalto afanítico afírico oxidado, basalto porfirítico, basalto porfirítico amigdaloidal, diabásio amigdaloidal alterado, diabásio equigranular, diabásio porfirítico, diabásio porfirítico alterado, diabásio porfirítico amigdaloidal, riolito alterado, riolito amigdaloidal, riolito porfirítico, riolito porfirítico amigdaloidal e riolito porfirítico amigdaloidal venulado).

A arquitetura dos modelos NFHB-SubClass, necessita de um sistema NFHB-Class, no topo da hierarquia, para realização da classificação macro e de outros sistemas NFHB-Class, subordinados ao sistema NFHB-Class de classificação macro, para identificação das subclasses. As configurações utilizadas para classificação macro dos sistemas NFHB-SubClass utilizaram os melhores modelos encontrados para classificação das classes macro na seção anterior, conforme mostra a Tabela 7.33.

A arquitetura dos modelos RN-NFHB-SubClass e RN-Hierárquico-SubClass, necessitam de uma rede neural, no topo da hierarquia, para realização da classificação macro e de outros sistemas NFHB-Class para o caso dos modelo RN-NFHB-SubClass e de outras redes neurais para o caso dos modelos RN-NFHB-SubClass, subordinados a rede neural de classificação macro, para identificação das subclasses. As configurações utilizadas para classificação macro dos sistemas RN-NFHB-SubClass e RN-Hierárquico-

SubClass utilizaram os melhores modelos encontrados para classificação das classes macro na seção anterior, conforme mostra a Tabela 7.34.

Para realização dos testes com os modelos NFHB-SubClass e RN-NFHB-SubClass foram utilizados os melhores modelos encontrados para classificação das subclasses encontrados na seção anterior conforme mostra a

Tabela 7.35. Os melhores resultados foram encontrados com o modelo NFHB-Class com estratégia de seleção de características adaptativa e com os atributos das bases dados contendo somente como atributos os coeficientes para os canais RGB, que foram chamados na seção anterior de: gnaisse2, basalto2, diabásio2 e riolito2.

Tabela 7.33 Configuração dos modelos NFHB-Class para os melhores resultados obtidos para classificação das classes macros das rochas gnaisse, basalto, diabásio e riolito.

| Rocha | Acerto percentual conjunto treinamento | Acerto percentual conjunto teste | Número de regras | Taxa de decomposição |
|--------------------------------------|--|----------------------------------|------------------|----------------------|
| Gnaisse e Basalto | 98,67 % | 96,67 % | 68 | 0,008 |
| Diabásio e Riolito | 87,2 % | 86 % | 33 | 0,01 |
| Basalto, Diabásio e Riolito | 84% | 80,57% | 77 | 0,008 |
| Gnaisse, Basalto, Diabásio e Riolito | 83,75% | 77,75% | 79 | 0,006 |

Tabela 7.34 Configuração das redes neurais para os melhores resultados obtidos para classificação das classes macros das rochas gnaisse, basalto, diabásio e riolito.

| Rocha | Acerto percentual conjunto treinamento | Acerto percentual conjunto teste | Número de camadas | Num. neurônios camada de entrada | Num. neurônios camada escondida 1 | Num. neurônios camada escondida 2 | Num. Neurônios camada de saída |
|--------------------------------------|--|----------------------------------|-------------------|----------------------------------|-----------------------------------|-----------------------------------|--------------------------------|
| Gnaisse e Basalto | 100% | 94% | 3 | 9 | 10 | | 2 |
| Diabásio e Riolito | 99,2% | 85,2 % | 4 | 9 | 25 | 20 | 2 |
| Basalto, Diabásio e Riolito | 97,42% | 77,42% | 4 | 9 | 40 | 30 | 3 |
| Gnaisse, Basalto, Diabásio e Riolito | 97% | 77% | 4 | 9 | 40 | 40 | 4 |

Tabela 7.35 Configuração dos modelos NFHB-Class para os melhores resultados obtidos para classificação das subclasses das rochas gnaisse, basalto, diabásio e riolito.

| Rocha | Acerto percentual conjunto treinamento | Acerto percentual conjunto teste | Número de regras | Taxa de decomposição |
|----------|--|----------------------------------|------------------|----------------------|
| Gnaisse | 100% | 98% | 52 | 0,008 |
| Basalto | 95% | 87% | 81 | 0,006 |
| Diabásio | 92% | 73,6% | 83 | 0,002 |
| Riolito | 96% | 78,4% | 56 | 0,007 |

Para a realização dos testes com o modelo RN-Hierárquico-SubClass foram utilizadas as melhores configurações de redes neurais encontrados para classificação das subclasses encontrados na seção anterior conforme mostra a Tabela 7.36. Todos os melhores resultados foram encontrados com os atributos das bases dados contendo somente

como atributos os coeficientes para os canais RGB, que foram chamados na seção anterior de: gnaisse2, basalto2, diabásio2 e riolito2.

Tabela 7.36 Configuração dos modelos RN-SubClass para os melhores resultados obtidos para classificação das subclasses das rochas gnaisse, basalto, diabásio e riolito.

| Rocha | Acerto percentual conjunto treinamento | Acerto percentual conjunto teste | Número de camadas | Num. neurônios camada de entrada | Num. neurônios camada escondida 1 | Num. neurônios camada escondida 2 | Num. Neurônios camada de saída |
|----------|--|----------------------------------|-------------------|----------------------------------|-----------------------------------|-----------------------------------|--------------------------------|
| Gnaisse | 100% | 98% | 3 | 9 | 9 | | 2 |
| Basalto | 95% | 87% | 4 | 9 | 10 | 10 | 4 |
| Diabásio | 92% | 73,6% | 4 | 9 | 20 | 15 | 5 |
| Riolito | 96% | 78,4% | 4 | 9 | 20 | 15 | 5 |

7.3.1. Rochas Gnaisse e Basalto

A Tabela 7.37 resume os resultados de classificação obtidos para os dados das rochas gnaisse e basalto utilizando os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass.

Tabela 7.37 Resultados obtidos com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, para classificação das classes macro e subclasses das rochas gnaisse e basalto.

| Modelo | Rocha | Erros no conjunto de Validação | | | | Acerto Percentual conjunto de validação |
|-------------------------|---------|--------------------------------|---------|---------|---------|---|
| | | Classe 1 | Classe2 | Classe3 | Classe4 | |
| NFHB-SubClass | Gnaisse | 3/25 | 0/25 | | | 88% |
| | Basalto | 7/25 | 1/25 | 7/25 | 0/25 | |
| RN-NFHB-SubClass | Gnaisse | 2/25 | 1/25 | | | 87,33% |
| | Basalto | 7/25 | 1/25 | 6/25 | 2/25 | |
| RN-Hierárquico-SubClass | Gnaisse | 6/25 | 3/25 | | | 80,66% |
| | Basalto | 7/25 | 0/25 | 9/25 | 4/25 | |

7.3.2. Rochas Diabásio e Riolito

A Tabela 7.38 resume os resultados de classificação obtidos para os dados das rochas gnaisse e basalto utilizando os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass.

Tabela 7.38 Resultados obtidos com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, para classificação das classes macro e subclasses das rochas diabásio e riolito.

| Modelo | Rocha | Erros no conjunto de Validação | | | | | Acerto Percentual conjunto de validação |
|-------------------------|----------|--------------------------------|---------|---------|---------|---------|---|
| | | Classe 1 | Classe2 | Classe3 | Classe4 | Classe5 | |
| NFHB-SubClass | Diabásio | 3/25 | 6/25 | 5/25 | 5/25 | 15/25 | 75,2% |
| | Riolito | 6/25 | 5/25 | 6/25 | 6/25 | 5/25 | |
| RN-NFHB-SubClass | Diabásio | 5/25 | 7/25 | 6/25 | 4/25 | 15/25 | 72,8% |
| | Riolito | 6/25 | 5/25 | 7/25 | 8/25 | 5/25 | |
| RN-Hierárquico-SubClass | Diabásio | 5/25 | 8/25 | 6/25 | 8/25 | 13/25 | 67,6% |
| | Riolito | 7/25 | 7/25 | 11/25 | 9/25 | 7/25 | |

7.3.3. Rochas Basalto, Diabásio e Riolito

A Tabela 7.39 resume os resultados de classificação obtidos para os dados das rochas gnaisse e basalto utilizando os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass.

Tabela 7.39 Resultados obtidos com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, para classificação das classes macro e subclasses das rochas basalto, diabásio e riolito.

| Modelo | Rocha | Erros no conjunto de Validação | | | | | Acerto Percentual conjunto de validação |
|-------------------------|----------|--------------------------------|---------|---------|---------|---------|---|
| | | Classe 1 | Classe2 | Classe3 | Classe4 | Classe5 | |
| NFHB-SubClass | Basalto | 7/25 | 4/25 | 7/25 | 5/25 | | 74,85% |
| | Diabásio | 5/25 | 6/25 | 5/25 | 5/25 | 15/25 | |
| | Riolito | 6/25 | 5/25 | 6/25 | 6/25 | 6/25 | |
| RN-NFHB-SubClass | Basalto | 9/25 | 1/25 | 7/25 | 9/25 | | 71,71% |
| | Diabásio | 5/25 | 6/25 | 6/25 | 4/25 | 15/25 | |
| | Riolito | 6/25 | 7/25 | 8/25 | 10/25 | 6/25 | |
| RN-Hierárquico-SubClass | Basalto | 11/25 | 1/25 | 9/25 | 8/25 | | 64,85% |
| | Diabásio | 6/25 | 8/25 | 9/25 | 10/25 | 13/25 | |
| | Riolito | 3/25 | 11/25 | 15/25 | 14/25 | 5/25 | |

7.3.4. Rochas Gnaiss, Basalto, Diabásio e Riolito

A Tabela 7.40 resume os resultados de classificação obtidos para os dados das rochas gnaiss e basalto utilizando os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass.

Tabela 7.40 Resultados obtidos com os modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, para classificação das classes macro e subclasses das rochas gnaisse, basalto, diabásio e riolito.

| Modelo | Rocha | Erros no conjunto de Validação | | | | | Acerto Percentual conjunto de validação |
|-------------------------|----------|--------------------------------|---------|---------|---------|---------|---|
| | | Classe 1 | Classe2 | Classe3 | Classe4 | Classe5 | |
| NFHB-SubClass | Gnaisse | 11/25 | 15/25 | | | | 70,25% |
| | Basalto | 11/25 | 3/25 | 7/25 | 1/25 | | |
| | Diabásio | 6/25 | 10/25 | 5/25 | 4/25 | 15/25 | |
| | Riolito | 7/25 | 5/25 | 9/25 | 5/25 | 5/25 | |
| RN-NFHB-SubClass | Gnaisse | 5/25 | 12/25 | | | | 68,5% |
| | Basalto | 13/25 | 5/25 | 6/25 | 1/25 | | |
| | Diabásio | 12/25 | 8/25 | 5/25 | 11/25 | 15/25 | |
| | Riolito | 7/25 | 5/25 | 7/25 | 8/25 | 6/25 | |
| RN-Hierárquico-SubClass | Gnaisse | 5/25 | 12/25 | | | | 60,5% |
| | Basalto | 12/25 | 7/25 | 9/25 | 5/25 | | |
| | Diabásio | 12/25 | 13/25 | 7/25 | 13/25 | 15/25 | |
| | Riolito | 4/25 | 12/25 | 16/25 | 12/25 | 4/25 | |

7.4. Comparações com os modelos testados

Nesta seção será feita uma comparação entre os modelos, NFHB-Class e as redes neurais, onde é necessário saber, *a priori*, a classe macro a qual a rocha pertence para que se possa realizar a classificação das subclasses das rochas, versus os modelos, NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass, que efetuam a classificação macro e a subclassificação das rochas sem o prévio conhecimento da classe macro a qual a rocha pertence. A Tabela 7.41 apresenta, de forma resumida, os resultados obtidos.

Tabela 7.41 Comparação de desempenho entre vários sistemas para a classificação das subclasses das rochas gnaisse, basalto, diabásio e riolito.

| Modelo | Gnaisse, Basalto | Diabásio, Riolito | Basalto, Diabásio e Riolito | Gnaisse, Basalto, Diabásio e Riolito |
|-------------------------|------------------|-------------------|-----------------------------|--------------------------------------|
| Redes Neurais | 94 % | 85,2 % | 77,42% | 77% |
| NFHB-Class | 96,67 % | 86 % | 80,57% | 77,75% |
| NFHB-SubClass | 88% | 75,2% | 74,85% | 70,25% |
| RN-NFHB-SubClass | 87,33% | 72,8% | 71,71% | 68,5% |
| RN-Hierárquico-SubClass | 80,66% | 67,6% | 64,85% | 60,5% |

Como era de se esperar, se já se conhece, *a priori*, a classe macro a qual a rocha pertence, casos dos modelos NFHB-Class e das redes neurais, o acerto é maior do que nos modelos que têm que descobrir primeiramente a classe macro para depois realizar a subclassificação da rocha.

7.5. Extração das Regras

Para ilustrar a estrutura em árvore encontrada pelo modelo NFHB-Class foi escolhido o teste realizado com a rocha gnaisse, utilizando-se a base de dados Gnaisse2 (base dados contendo somente como atributos os coeficientes para os canais RGB), utilizando estratégia de seleção de características adaptativa, com a taxa de decomposição $\delta=0.1$, onde o acerto no conjunto de treinamento foi de 96% e o acerto no conjunto de validação foi de 94%, conforme pode ser verificado na Tabela 7.1. A Figura 7.1 a seguir traduz a estrutura do modelo NFHB-Class encontrada. As ligações T-conorms não são

mostradas na Figura 7.1, pois as mesmas dificultariam o entendimento do processo de extração das regras.

A Figura 7.2 ilustra a estrutura do modelo NFHB-Class completa para a rocha gnaisse. As classe1 e classe2 ilustradas representam as subclasses gnaisse granítico e gnaisse leucocrático, respectivamente.

Nas Figura 7.1 e Figura 7.2 os atributos estão codificados por: X2 – Coeficiente de Hurst canal Red, X3 – Coeficiente de Hurst canal Green, X4 – Coeficiente de Hurst canal Blue, X6 – CVE para canal Red, X7 – CVE para canal Green, X8 – CVE para canal Blue, X10 – Entropia da Imagem canal Red, X11 – Entropia da Imagem canal Green, X12 – Entropia da Imagem canal Blue,

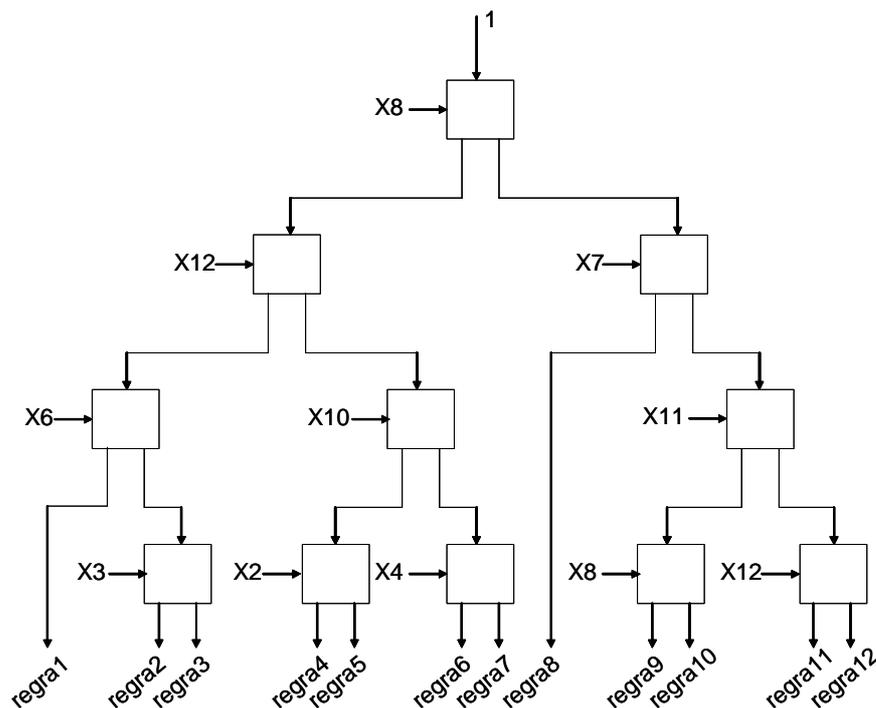


Figura 7.1 Estrutura em árvore do modelo NFHB-Class, sem conexões T-conorms, com estratégia de seleção adaptativa para o teste realizado com a rocha gnaisse.

Através do caminharmento na árvore é possível extrair as regras que descrevem a base de dados da rocha gnaisse. Abaixo estão listadas algumas das regras fuzzy extraídas da estrutura em árvore da Figura 7.1.

Regras Fuzzy:

Regra 1:

Se X8 é baixo e Se X12 é baixo e Se X6 é baixo então Classe = 1
[Acuracia: 0,6813 / Abrangência: 0,1105]

Regra 2:

Se X8 é baixo e Se X12 é baixo e Se X6 é alto e Se X3 é baixo então Classe = 1
[Acuracia: 0,548 / Abrangência: 0,06137]

Regra 3:

Se X8 é baixo e Se X12 é baixo e Se X6 é alto e Se X3 é alto então Classe = 1
[Acuracia: 0,5152 / Abrangência: 0,05707]

Regra 4:

Se X8 é baixo e Se X12 é alto e Se X10 é baixo e Se X2 é baixo então Classe = 1
[Acuracia: 0,5013 / Abrangência: 0,03149]

Regra 5:

Se X8 é baixo e Se X12 é alto e Se X10 é baixo e Se X2 é alto então Classe = 2
[Acuracia: 0,5159 / Abrangência: 0,02537]

Regra 6:

Se X8 é baixo e Se X12 é alto e Se X10 é alto e Se X4 é baixo então Classe = 1
[Acuracia: 0,5801 / Abrangência: 0,01211]

Regra 7:

Se X8 é baixo e Se X12 é alto e Se X10 é alto e Se X4 é alto então Classe = 2
[Acuracia: 0,5648 / Abrangência: 0,01475]

Regra 8:

Se X8 é alto e Se X7 é baixo então Classe = 1
[Acuracia: 0,5601 / Abrangência: 0,09951]

Regra 9:

Se X8 é alto e Se X7 é alto e Se X11 é baixo e Se X8 é baixo então Classe = 1
[Acuracia: 0,5388 / Abrangência: 0,02845]

Regra 10:

Se X8 é alto e Se X7 é alto e Se X11 é baixo e Se X8 é alto então Classe = 2
[Acuracia: 0,6614 / Abrangência: 0,03755]

Regra 11:

Se X8 é alto e Se X7 é alto e Se X11 é baixo e Se X12 é baixo então Classe = 2
[Acuracia: 0,5931 / Abrangência: 0,01464]

Regra 12:

Se X8 é alto e Se X7 é alto e Se X11 é baixo e Se X12 é alto então Classe = 2
[Acuracia: 0,5676 / Abrangência: 0,01653]

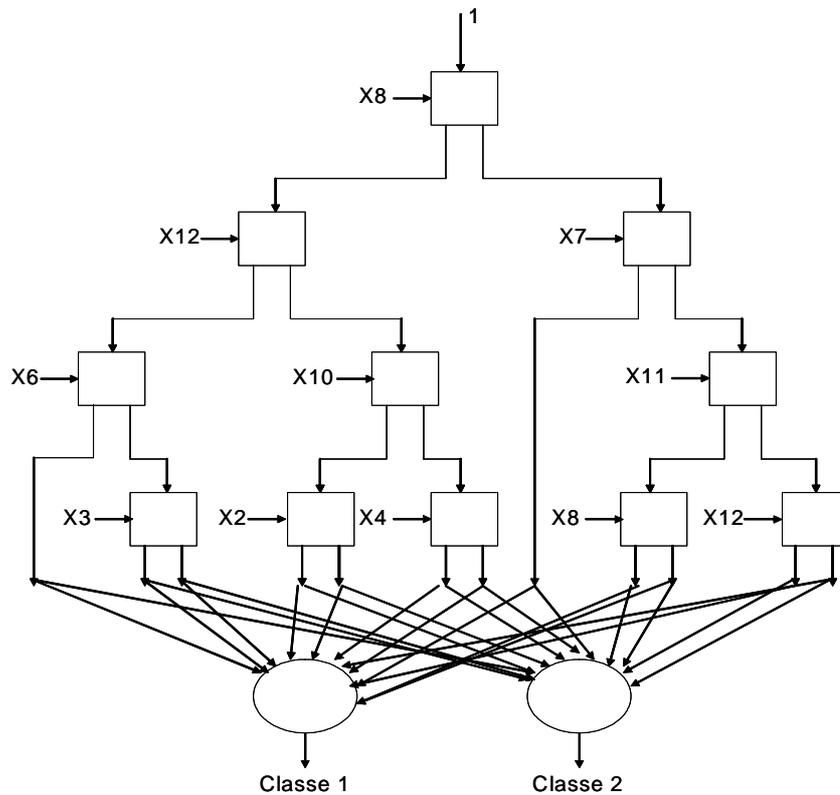


Figura 7.2 Estrutura completa em árvore do modelo NFHB-Class com estratégia de seleção adaptativa para o teste realizado com a rocha gnaisse.

7.6. *Resumo*

Os resultados encontrados no estudo de casos, mostraram a boa aplicabilidade dos sistemas investigados na tarefa de classificação das classes macros e das subclasses das classes macros.

Os ensaios realizados neste capítulo, apontam para um futuro promissor destes modelos, onde se pode destacar sua boa generalização, capacidade de gerar sua própria estrutura nos casos dos modelos NFHB-SubClass, NFHB-Class e rápida convergência. Além disso vislumbram-se outras aplicações desses modelos em outras áreas, tais como classificação de metais.

Capítulo 8

Conclusões e Sugestões para Trabalhos Futuros

8.1. *Conclusões*

O objetivo desse trabalho foi a criação, a partir dos modelos NFHB-Class com estratégias de seleção de características fixa e adaptativa, de outros modelos hierárquicos, especificamente para a tarefa de classificação de imagens de rochas de classes macros e de subclasses das classes macros e extração de regras fuzzy.

A pesquisa desenvolveu-se primeiramente em determinar um conjunto de descritores de imagens capaz de identificar as classes e subclasses das imagens das rochas de forma eficaz. Para isso foram estudados descritores de textura tais como: matrizes de co-ocorrência, coeficiente de Hurst, coeficiente de variação espacial, histograma de somas e diferenças e entropia da imagem.

A próxima etapa foi aplicar os modelos NFHB-Class, que são modelos capazes de gerar as suas próprias estruturas sem a necessidade de determinar as suas arquiteturas, e as redes neurais para a classificação das classes macros das imagens das rochas e para a classificação das subclasses de cada uma das classes macros. Foi feita então uma análise comparativa das classificações com essas duas técnicas. Os resultados encontrados com os modelos NFHB-Class mostraram-se, em todos os casos, sempre superiores às redes neurais.

Após a utilização dos modelos NFHB-Class, buscou-se desenvolver um modelo capaz de realizar a classificação das classes macros e das suas subclasses. Foram desenvolvidos, então, três novos modelos denominados: NFHB-SubClass, RN- NFHB-SubClass e RN-Hierárquico-SubClass. Todos os modelos realizam a classificação de forma hierárquica. Primeiramente há um modelo, pai ou raiz, que determina a classe macro a qual a rocha pertence, e em seguida, subordinados ao modelo macro, existem outros modelos que determinam as subclasses a qual as rochas pertencem.

O modelo NFHB-SubClass é capaz de criar toda a sua estrutura de forma automática, tendo em vista que é composto de um modelo NFHB-Class para determinar a classe macro das rochas e outros modelos NFHB-Class para identificar as subclasses das imagens das rochas.

Os modelo RN-NFHB-SubClass e RN-Hierárquico-SubClass não são capazes de criar sua estrutura de forma automática. Para o modelo RN-NFHB-SubClass é necessário criar uma rede neural que será destinada a classificação macro das imagens das rochas, logo há a necessidade de determinar a arquitetura da rede neural. A subclassificação é feita através de modelos NFHB-Class. Esse modelo então pode ser considerado de semi-automático. Já para o caso do modelo RN-Hierárquico-SubClass, é necessário a determinação da arquitetura de todas as redes neurais envolvidas no modelo. Uma rede

neural é criada, no topo da hierarquia, para realizar a classificação macro das imagens das rochas e outras redes neurais são criadas para realizar a classificação das subclasses das imagens.

Os novos modelos foram testados com as imagens de rochas gnaisse, basalto, diabásio e riolito, juntamente com suas subclasses e, em todos os casos, o modelo NFHB-SubClass se mostrou superior aos modelos RN-NFHB-SubClass e RN-Hierárquico-SubClass.

O desempenho de todos os modelos apresentados também se mostrou bastante satisfatório. Em todos os casos, os modelos convergiram para uma ótima solução de classificação, além da extração de regras fuzzy nos modelos NFHB-Class, NFHB-SubClass e RN-NFHB-SubClass, em uma ordem de grandeza de tempo inferior a 1 minuto.

O número de regras extraídas se mostram adequadas para aplicações de extração de conhecimento. As regras fuzzy obtidas após a fase de aprendizado foram avaliadas por meio de medidas de acurácia fuzzy e abrangência fuzzy. Essas medidas fornecem uma informação clara da precisão e alcance de cada regra gerada.

Os resultados de classificação encontrados pelos modelos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass são bastante semelhantes aos encontrados por um especialista em rochas. O especialista em rochas, por exemplo, tem dificuldades em distinguir as classes das rochas diabásio e basalto, da mesma forma que os três sistemas criados nessa tese.

A seção 8.2, a seguir, apresenta sugestões para trabalhos futuros, visando manter uma continuidade para aprimorar ainda mais os resultados de classificação das imagens de rochas.

8.2. *Trabalhos Futuros*

As propostas para posterior desenvolvimento de trabalhos futuros são apresentadas a seguir.

- Testar os modelos para novas classes de rochas e com outros conjuntos descritores de textura, avaliando o desempenho dos três novos modelos desenvolvidos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass.
- Testar os três novos modelos desenvolvidos NFHB-SubClass, RN-NFHB-SubClass e RN-Hierárquico-SubClass em outras aplicações, tais como metais, com o objetivo de classificar os diferentes tipos de materiais baseados nas texturas dos grãos que compõem os metais.
- Criar um modelo hierárquico focado para a análise microscópica das rochas, onde se pode descrever com maiores detalhes as feições mineralógicas texturais e estruturais das rochas. Esse novo modelo seria capaz de segmentar e classificar os grãos que compõem a rochas.

A Figura 8.1 ilustra uma seção delgada de rocha vista em uma análise microscópica, juntamente com um exemplo de particionamentos recursivos BSP (*Binary Space Partitioning*). A idéia inicial seria utilizar um particionamento recursivo para segmentar os grão da imagem. Em seguida, já com a imagem segmentada, utilizar o modelo NFHB-Class para classificar cada grão previamente segmentado. Após cada grão segmentado e

classificado, o sistema seria capaz de informar a classe e a sub classe a qual rocha como um todo pertence.

A classificação macroscópica juntamente com a classificação microscópica traria mais confiabilidade ao sistema, uma vez que, realiza as mesmas etapas compreendidas na petrografia, com exceção apenas da análise química, que foge do escopo dessa metodologia.

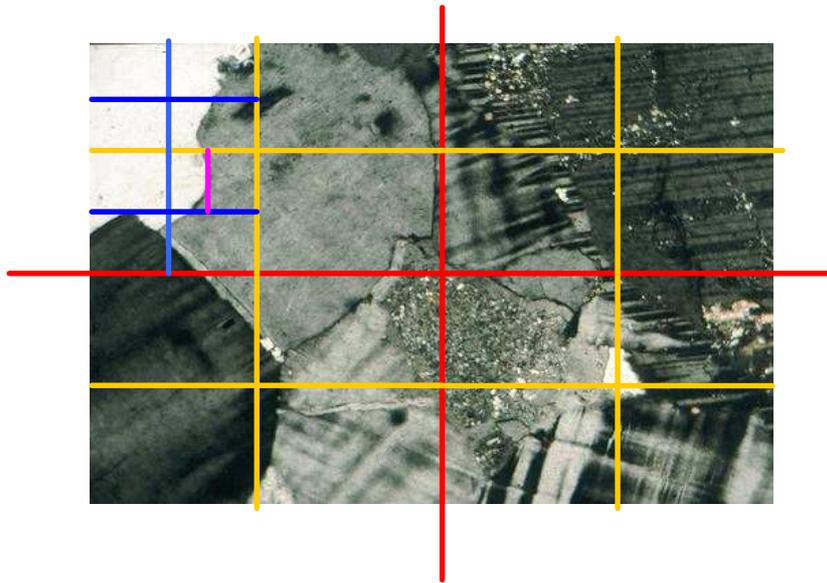


Figura 8.1 Imagem de uma seção delgada de rocha, vista sob um microscópio óptico, e com particionamento recursivo.

Referências Bibliográficas

- [1] Abel, M. (2001). “Estudo da Perícia em Petrografia Sedimentar e sua Importância para a Engenharia do Conhecimento”. Universidade Federal do Rio Grande do Sul. Tese de Doutorado.
- [2] Gonçalves, L.B., Leta, F.R. and Valente, S.C. (2009). “Macroscopic Rock Texture Image Classification using an Hierarchical Neuro-Fuzzy System”, 16th International Conference on Systems, Signals and Image Processing, IWSSIP, Chalkida, Greece, June, accepted.
- [3] Gonçalves, L.B. and Leta, F.R. (2009). “An Intelligent Computer Vision System to Rock Classification in Oil and Gas Industry”. COBEM 20th International Congress of Mechanical Engineering November 15-20, 2009. Gramado-RS, Brazil, accepted.
- [4] Gonçalves, L.B. and Leta, F.R. (2010). “Macroscopic Rock Texture Image Classification using a Hierarchical Neuro-Fuzzy Class Method”. Mathematical Problems in Engineering. Hindawi Publishing Corporation.
- [5] Gonçalves, L. B. (2001). “Modelos Neuro-Fuzzy Hierárquicos BSP para Classificação de Padrões e Extração de Regras Fuzzy em Banco de Dados”. Dissertação de Mestrado. Departamento de Engenharia Elétrica. PUC-Rio.
- [6] Lanas, A. I. (2000). “Sistemas Neuro-Fuzzy Hierárquicos BSP para Previsão e Extração de Regras Fuzzy em Aplicações de Mineração de Dados”. Tese de Mestrado. DEE-Puc-Rio.

-
- [7] Neural Network Modeling for Windows 95/98/2000/XP`. Qnet 2000.
<http://qnetv2k.com/>
- [8] Souza, F. J. (1999). “Modelos Neuro-Fuzzy Hierárquicos”. Tese de Doutorado. DEE.
PUC-Rio.
- [9] Hall, A. (1987). “Igneous Petrology”. Longman Sci. Tech., London, 573p.
- [10] Carmichael, I.S.E., Turner, F.J. and Verhoogen, J. (1974). “Igneous Petrology”.
McGraw-Hill, London, 739p.
- [11] Sial, A.N. and McReath, I. (1984). “Petrologia Ígnea”. SBG/CNPq/Bureau Gráfica e
Editora Ltda, Salvador, v.1, 180p.
- [12] <http://www.alphagranitos.com.br/produtos.htm>
- [13] <http://www.forumaquario.com.br/phpBB2/viewtopic.php?t=30464>
- [14] http://trabalhodegeografiadalulu.blogspot.com/2009_06_01_archive.html
- [15] http://serrafinasp.blogspot.com/2009/04/melanophryniscus-moreirae_22.html
- [16] [http://geomuseu.ist.utl.pt/MINGEO2010/Questionarios/
Petrologia%20e%20petrografia/Visualiza%20E7%E3o%20-%20rochas%20EDgneas/
Sienito%20nefel%20ednico.jpg](http://geomuseu.ist.utl.pt/MINGEO2010/Questionarios/Petrologia%20e%20petrografia/Visualiza%20E7%E3o%20-%20rochas%20EDgneas/Sienito%20nefel%20ednico.jpg)
- [17] <http://www.rc.unesp.br/museudpm/rochas/magmaticos/diorito.html>
- [18] [http://geomuseu.ist.utl.pt/MINGEO2010/Aulas%20praticas/TEMA%203%20-
%20Petrografia/Imagens%20e%20Fotos%20Petrologia/ROCHAS%20CDGNEAS%20\(C
olec%20E7%E3o%20das%20Aulas\)/MESO%20A%20MELANOCRATAS/DIORITO%20G
%20FINO.JPG](http://geomuseu.ist.utl.pt/MINGEO2010/Aulas%20praticas/TEMA%203%20-%20Petrografia/Imagens%20e%20Fotos%20Petrologia/ROCHAS%20CDGNEAS%20(Colec%20E7%E3o%20das%20Aulas)/MESO%20A%20MELANOCRATAS/DIORITO%20G%20FINO.JPG)

-
- [19] <http://commons.wikimedia.org/wiki/File:Gabro.JPG>
- [20] <http://rusoares65.pbworks.com/Wiki-conceito-Gabro>
- [21] <http://lurra.wikispaces.com/file/view/gabro.jpg/68842911/gabro.jpg>
- [22] http://www.ulbra.br/mineralogia/conceito_rochas.htm
- [23] <http://www.rc.unesp.br/museudpm/rochas/magmaticos/peridotito.html>
- [24] <http://cidadaniaecologica9.blogspot.com/2010/03/as-pedras-respiram-co2-e-vital.html>
- [25] http://1papacaio.com.br/modules/Sala_aula/public/nmimage.php?z=../gallery/pesquisa/ciencias/reino_mineral/riolito.jpg&width=346&height=283
- [26] <http://luizmenezes.com.br/galeria-de-minerais/r-s/>
- [27] <http://netciencias.blogspot.com/>
- [28] <http://www.rc.unesp.br/museudpm/rochas/magmaticos/traquito.html>
- [29] <http://medlibrary.org/medwiki/Andesite>
- [30] <http://pessoa.fct.unl.pt/cpb/estagio/materiais/UniSupVis/Exercicio1/Hot%20Pot%202.htm>
- [31] http://www.isansmile.com/Theearth/3_22.htm
- [32] <http://ventor.com.sapo.pt/page29.htm>
- [33] <http://www.rc.unesp.br/museudpm/banco/introducao.html>
- [34] <http://oguiageografico.wordpress.com/2008/09/16/a-estrutura-da-terra/>
- [35] <http://www.rc.unesp.br/museudpm/rochas/magmaticos/lamprofiro.html>

[36] <http://www.geoturismobrasil.com/geologia%20tur.htm>

[37] Shand, S. J. (1943). "Eruptive Rocks". T. Murby, London. 2nd Edn.

[38] Fredlander, C. and Niggli, P. (1931). "Beitrag zur Petrographie der Vogesen". Schw. Mineralog.-Petrograph. Mitteil., vol. II, Pt. 2, pp. 365–411.

[39] Cox, K., Bell, J.D. and Pankhurst, R.J. (1979). "The Interpretation of Igneous Rocks". Allen & Unwin, London, 450p.

[40] Streckeisen, A. L. (1974). "Classification and Nomenclature of Plutonic Rocks". Recommendations of the IUGS Subcommittee on the Systematics of Igneous Rocks. Geologische Rundschau. Internationale Zeitschrift für Geologie. Stuttgart. Vol.63, p.773-785.

[41] Streckeisen, A. L. (1978). "Classification and Nomenclature of Volcanic Rocks, Lamprophyres, Carbonatites and Melilite Rocks". Recommendations and Suggestions. IUGS Subcommittee on the Systematics of Igneous Rocks. Neues Jahrbuch für Mineralogie, Abhandlungen, Vol. 141, 1-14.

[42] Le Maitre, R.W. (2002). "Igneous Rocks: A Classification and Glossary of Terms". Recommendations of International Union of Geological Sciences Subcommittee on the Systematics of Igneous Rocks. Cambridge University Press, 236pp.

[43] Mackenzie, W.S., Donaldson, C.H. and Guilford, C. (1993). "Atlas of igneous rocks and their textures". Longman Scientific & Technical, 148p.

[44] Winge, M. (1996). Petrologia metamórfica - Notas de aula. Publicado na Internet em: <http://www.unb.br/ig/cursos/met1/index.htm>.

-
- [45] Fontes, M.P.F. (1994). “Introdução ao estudo de minerais e rochas”. Viçosa, Imprensa Universitaria da U.F.v., 23p. (Apostila, 182).
- [46] <http://e-geo.ineti.pt/bds/geobases/petrografia/rochas.aspx?ID=20>
- [47] <http://www.rc.unesp.br/museudpm/rochas/metamorficas/anfibolito.html>
- [48] <http://www.sobiologia.com.br/conteudos/Solo/Solo6.php>
- [49] <http://www.rc.unesp.br/museudpm/rochas/metamorficas/ardosia.html>
- [50] <http://www.rc.unesp.br/museudpm/rochas/metamorficas/eclogito.html>
- [51] <http://pt.wikipedia.org/wiki/Eclogito>
- [52] <http://www.tiosam.net/enciclopedia/?q=Pedra-sab%C3%A3o>
- [53] <http://www.catep.com.br/dicas/PEDRAS%20DE%20REVESTIMENTO.htm>
- [54] <http://www.dicionario.pro.br/dicionario/index.php/Filito>
- [55] <http://pt.wikipedia.org/wiki/Filito>
- [56] <http://www.rc.unesp.br/museudpm/rochas/metamorficas/gondito.html>
- [57] <http://www.rc.unesp.br/museudpm/rochas/metamorficas/itabirito.html>
- [58] <http://www.rc.unesp.br/museudpm/rochas/metamorficas/quartzito.html>
- [59] <http://www.rc.unesp.br/museudpm/rochas/metamorficas/serpentinico.html>
- [60] <http://www.parquenoudar.com/pt/modules/smartsection/print.php?itemid=146>
- [61] http://campus.fortunecity.com/bryant/377/rochasmetamorficas/imagens_e_curiosidades.html

-
- [62] <http://www.rc.unesp.br/museudpm/rochas/metamorficas/milonito.html>
- [63] <http://blass.com.au/definitions/hornfels>
- [64] <http://commons.wikimedia.org/wiki/File:Granulito.jpg>
- [65] Turceyan, M. and Jain, A. K. (1993). “Handbook of Pattern Recognition and Computer Vision”. chapter Texture Analysis, pages 235–276. World Scientific Publishing Company.
- [66] IEEE Standard 610.4-1990, (1990). “IEEE Standard Glossary of Image Processing and Pattern Recognition Terminology”. IEEE Press, New York.
- [67] Jain, A.K. (1988). “Fundamentals of Image”. Processing. Prentice-Hall, New York.
- [68] Muhamad, A. K.; Deravi, F. (1994). “Neural network for the Classification of Image Texture”. Engineering Application and Artificial Intelligence. V 7, n.4, p. 381-393.
- [69] Raghu, P.P.; Poongo; and Yegnanarayana, B. (1995). “A combined neural network approach for texture classification”. Neural Networks, v. 8, n. 6, p. 975-987.
- [70] Augusteijn, M. F., Clemens, L. E. and Shaw, K. A. (1995). “Performance evaluation of texture measure for ground cover identification in satellite images by means of a neural network classifier”. IEEE Transaction on Geoscience and Remote Sensing, v. 33, n. 33, p. 616-625.
- [71] Martins, M. P. (2003). “Classificador neural de atributos de textura para busca e recuperação de imagens de sensoriamento remoto”. 151 p. Dissertação de Mestrado em Computação Aplicada. Instituto Nacional de Pesquisas Espaciais, São José dos Campos, (INPE-5522-TDI/519).

-
- [72] Shisong, Y. and Chih-Cheng, H. (2002). "Texture classification in remotely sensed images". In: IEEE Southeast Conference. 5 – 7 April 2002, Columbia, SC. Proceedings of IEEE Southeast p. 62 – 66.
- [73] Lelong, C.C.D. and Thong-Chane, A. (2003). "Application of textural analysis on very high resolution panchromatic images to map coffee orchards in Uganda", In: IGARSS 2003 - International Geoscience And Remote Sensing Symposium, Proceedings of IGARSS 2003, v. 2, p. 1007 – 1009.
- [74] Pesaresi, M. (1999). "Textural classification of very high-resolution satellite imagery: Empirical estimation of the interaction between window size and detection accuracy in urban environment", In: ICIP99 - International Conference on Image Processing, Kobe. Proceedings of ICIP99, Kobe , v. 1, p. 114 – 118.
- [75] Jain, A. K. and Farrokhnia, F. (1991). "Unsupervised texture segmentation using Gabor filters". Pattern Recognition, V. 24, n. 12, p. 1167-1186.
- [76] Chang, T., and Kuo, C. C. (1993). "Texture Analysis and Classification with Tree-structure Wavelet Transform". IEEE Transactions on Image Processing, vol. 2. (n° 4).
- [77] Sachin, V. P., Dhawan, A. P. and Relue, P. A. (2003). "Classification of Melanoma using Tree Structured Wavelet Transforms". Computer Methods and Programs in Biomedicine (n° 72), pp. 223 - 239.
- [78] Zouridakis, G., Doshi, M. and Mullani, N. (2004). "Early Diagnosis of Skin Cancer Based on Segmentation and Measurement of Vascularization and Pigmentation in Nevoscope Images". Proceedings of The 26th Annual international Conference of the IEEE EMBS.

-
- [79] Sikorski, J. (2004). "Identification of Malignant Melanoma by Wavelet Analysis". Proceedings of student/Faculty Research Day, CSIS, Pace University .
- [80] Bauer, C., Theis, F. J., Baumler, W. and Lang, E. W. (2003). "Local Features in Biomedical Image Clusters Extracted with Independent Component Analysis". IEEE Transactions.
- [81] Ercal, F., Chawla, A., Stoecker, W. V., Lee, H. and Moss, R. H. (1994). "Neural Network Diagnosis of Malignant Melanoma from Color Images". IEEE Transaction on Biomedical Engineering, vol. 41 (n° 9).
- [82] Marquez, G. and Wang, L. V. (2000). "Characterization of Skin Lesion Texture in Diffuse Reflectance Spectroscopic Images". Biomedical Engineering Program.
- [83] Chang, T. and Kuo, C. C. (1992). "Texture Classification with Tree-Structured Wavelet Transform". Signal and Image Processing Institute.
- [84] Yuan, X., Yang, Z., Zouridakis, G. and Mullani, N. (2006). "SVM - Based Texture Classification and Application to Early Melanoma Detection". Proceedings of the 28th IEEE - EMBS.
- [85] Lepistö, L., Kunttu, I., Autio, J. And Visa, A. (2003). "Rock Image Classification Using Non-Homogenous Textures and Spectral Imaging". Spectral Imaging, WSCG SHORT PAPERS proceedings, WSCG'2003, Plzen, Czech Republic.
- [86] Launeau, P., Cruden, C.A. and Bouchez, J. L. (1994). "Mineral recognition in digital images of rocks: a new approach using multichannel classification". Can Mineral 32: 919–933.

-
- [87] Lepistö, L., Kunttu, I. and Visa, A. (2005). "Rock image classification using color features in Gabor space". *Journal of Electronic Imaging*, Volume 14, Issue 4, 040503 (3 pages).
- [88] Autio, J., Luukkanen, S., Rantanen, L., and Visa, A. (1999) "The Classification and Characterisation of Rock Using Texture Analysis by Co-occurrence Matrices and the Hough Transform". *International Symposium on Imaging Applications in Geology*, pp. 5-8, Belgium.
- [89] Lepistö, L., Kunttu, I., Autio, J. and Visa, A., (2004) "Rock image retrieval and classification based on granularity". *Proceedings of the 5th International Workshop on Image Analysis for Multimedia Interactive Services, WIAMIS 2004, Lisboa, Portugal, 21-23 April 2004*, pp. 4 s.
- [90] Starkey, J. and Samantary, A. K. (1993). "Edge detection in petrographic images". *J Microsc* 172:263–266.
- [91] Ross, B. J., Fueten, F. and Yashkir, D. Y. (2000). "Edge Detection of Petrographic Images Using Genetic Programming". *Proceedings of the Genetic and Evolutionary Computation Conference*.
- [92] Ross, B. J., Fueten, F. and Yashkir, D. Y. (2001). "Automatic Mineral Identification Using Genetic Programming". *Machine Vision and Applications*.
- [93] Thompson, S. Fueten, F. and Bockus, D. (2001). "Mineral identification using artificial neural networks and the rotating polarizer stage". *Computers & Geosciences* Volume 27, Issue 9, Pages 1081-1089.

-
- [94] Fueten, F. and Mason, J. (2007). "An artificial neural net assisted approach to editing edges in petrographic images collected with the rotating polarizer stage". *Computers & Geosciences* Volume 33 , Issue 9, Pages 1176-1188.
- [95] Gonzales, R.C. and Wintz, P. (1987). "Digital Image Processing". 2nd ed.: Adison-WesleyPublishing Company.
- [96] Chen, C.H. (1990). "Texture unit, texture spectrum, and texture analysis". *IEEE Transactions on Geoscience and Remote Sensing*, 28(4):509-512.
- [97] Hsu, S. Y. Texture-tone analysis for automated land-use mapping. *Photogrammetric Engineering and Remote Sensing*, v. 44, n. 11, p. 1393-1404, 1978.
- [98] Irons, J. R. and Petersen, G. W. (1981) "Texture transforms of remote sensing data". *Remote Sensing of Environment*, v. 11, n. 5, p. 359-370.
- [99] Connors R.W. and Harlow C.A. (1980). "A Theoretical Comparison of Texture Alogrithms". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2(3): 204~222.
- [100] Sonka, M., Hlavac, V. and Boyle, R. (1999). "Image Processing, Analysis, and Machine Vision". 2nd ed. Vol. 1. Pacific Grove, CA, USA: Brooks/Cole Publishing Company. 770.
- [101] Morquin, D. Ghalia, M. B. and Bose, S. (2003). "An integrated neural network-based vision system for automated separation of clods from agricultural produce". *Engineering Applications of Artificial Intelligence* Volume 16, Issue 1, Pages 45-55.

-
- [102] Haralick, R.M., Shanmugan, K. and Dinstein, I. (1973). "Textural Features for Image Classification". IEEE Transactions on Systems, Man and Cybernetics. SMC-3(6): p. 610-621.
- [103] Conci, A., Azevedo, E. and Leta, F. (2008). "Computação Gráfica – Teoria e Prática". Volume 2. Editora Campus.
- [104] Honda, M.O. (2001). "Elaboração de uma Base de Conhecimentos para Auxílio ao Diagnóstico através da Comparação Visual de Imagens Mamográficas". Escola de Engenharia de São Carlos. SP - Brazil. p. 81.
- [105] Unser, M. S. (1986). "Difference Histograms of Texture Classification". IEEE Trans. Pattern Analysis and Machine Intelligence, PAMI, v.8, n.1, p.118-125.
- [106] Watt, A. and Policarco, F. (1998). "The Computer Image". Addison Wesley Pub. 784 p.
- [107] Nunes, E. O. and Conci, A. (2005) "O Coeficiente de Hurst e o Coeficiente de Variação Espacial na Segmentação de Texturas Multiespectrais", Anais do DINCON 2005, 4º Congresso Temático de Aplicações de Dinâmica e Controle da Sociedade Brasileira de Matemática Aplicada e Computacional, Série Arquimedes, Eds. J.M.Balthazar, G.N. da Silva, M.Tsuchida, M.. Boaventura, L.S.Goes & J.D.S. Silva, v. 4, pp. 1067- 1075.
- [108] Parker, J. R. (1997). "Algorithms for Image Processing and Computer Vision". John Wiley & Sons, Toronto. Pp. 432.
- [109] Duda, R. O. and Hart, P. E. (1973). "Pattern Classification and Scene Analysis". A Wiley-interscience publication. John Wiley & Sons.

-
- [110] Metha, M., Agrawal, R. and Rissanen, J. (1996). "SLIQ: A Fast Scalable Classifier for Data Mining", EDBT-96, Avignon, France.
- [111] Shafer, J., Agrawal, R. and Metha, M. (1996). "SPRINT: A Scalable Parallel Classifier for Data Mining" VLBD-96, Bombay, India.
- [112] Weiss, S. M. and Kulikowsky, C. A. (1991). "Computer Systems that Learn: Classification and Prediction Methods from Statistics, Neural Networks, Machine Learning, and Expert Systems". San Mateo, Calif.: Morgan Kaufmann.
- [113] Holsheimer, M. and Kersten, M. (1995). "A Perspective on Databases and Data Mining". 1st Conference on KDD, Montreal.
- [114] Chen, M. S., Han, J. and Yu, P. S. (1996). "Data Mining: An Overview from Database Perspective", IEEE Trans. on Knowledge and Data Engineering, Vol. 8, No. 6, pp. 866-883.
- [115] Srikant, R. and Agrawal, R. (1995). "Mining Generalized Association Rules". VLDB'95, Proceedings of 21th International Conference on Very Large Data Bases, September 11-15, Zurich, Switzerland.
- [116] Neumann, J. (1998). "Classification and Evaluation of Algorithms for Rule Extraction From Artificial Neural Networks". Center for Cognitive Science, University of Edinburgh. http://www.cogsci.ed.ac.uk/~jne/rule_extraction/rulex.html
- [117] Andrews, R. and Geva, S. (1996). "Rules and Local Function Networks". In Proceedings of the Rule Extraction From Trained Artificial Neural Networks Workshop, pages 1-15. Queensland University of Technology.

-
- [118] Mitchell, T. M. (1986). "Machine Learning: A Guide to Current Research". The Kluwer International Series in Engineering and Computer Science: Secs 12.
- [119] Mitchell, T. M. (1996). "Machine Learning". McGraw-Hill Series in Computer Science.
- [120] Freitas, A. A., and Lavington, S. H. (1998). "Mining Very Large Databases with Parallel Processing". Kluwer Academic Publishers.
- [121] Quinlan, J. R. (1993). "C4.5: Programs for Machine Learning"
http://www.mkp.com/books_catalog/1-55860-238-0.asp
- [122] Quinlan, J. R. (1987). "Simplifying Decision Trees". International Journal of Machine Learning Studies, 27, 221-234.
- [123] Janikow, C. Z. (1995). "A Genetic Algorithm for Optimizing the Fuzzy Component of Fuzzy Decision Trees". GA for Patter Recognition , S. Pal & P. Wang (eds.), CRC Press, pp. 253-282.
- [124] Janikow, C. Z. (1996). "Learning from Imperfect Examples in Decision Trees". Proceedings of the International Conference on Computers and Their Applications, pp. 71-74. Invited by Prof. Bouchon-Meunier.
- [125] Janikow, C. Z. (1996). "Exemplar Learning in Fuzzy Decision Trees". Proceedings of FUZZ-IEEE 1996, pp. 1500-1505. Invited by Prof. Bouchon-Meunier.
- [126] Ripley (1996). "Pattern Recognition and Neural Networks and Venables and Ripley Modern Applied Statistics with S-Plus".
<http://129.186.1.21/~dicook/stat501/97/lectures/4.17.html>

-
- [127] Breiman, L., Friedman, J. H., Olshen, R. and Stone, C. J. (1984). "Classification and Regression Trees". Wadsworth, Inc., Belmont, California.
- [128] JaniKow, C. Z. (1999). "Fuzzy Partitioning with FID3.1". Proceedings of the 18th International Conference of the North America Fuzzy Information Society.
- [129] Haykin, S. (2001). "Redes Neurais, princípios e prática". ARTMED Editora LTDA, Porto Alegre, RS, Brasil.
- [130] Mendes, V.B., Leta, F.R., Conci, A. and Gonçalves,L.B. (2010). "Detección de Posición Angular de Embarcaciones, Utilizando Técnicas de Visión Computacional y Redes Neurales Artificiales". Información Tecnológica. Volumen 21, número 5, accepted.
- [131] Freeman, J. A., and Skapura, D. M. (1992). Neural Networks: Algorithms, Applications and Programing Techniques, Addison-Wesley.
- [132] Andrews, R. and Geva, S. (1996). "Rules and Local Function Networks". In Proceedings of the Rule Extraction From Trained Artificial Neural Networks Workshop, pages 1-15. Queensland University of Technology.
- [133] Thrun, S. B. (1993). "Extracting Provably Correct Rules from Artificial Neural Networks". Technical report, Universitat Bonn, Institut fur Informatik III.
- [134] Johnson, G., Nealon, J. L. and Lindsay, R. O. (1996). "Using Relevance Information in the Acquisition of Rules from a Neural Network". In Proceedings of the Rule Extraction From Trained Artificial Neural Networks Workshop, pages 68-80. Queensland University of Technology.

-
- [135] Taha, I. and Ghosh, J. (1996). "Three Techniques for Extracting Rules from Feed Forward Net-works". In *Intelligent Engineering Systems Through Artificial Neural Networks*, volume 6, pages 23-28.
- [136] Taha, I. and Ghosh, J. (1996). "Symbolic Interpretation of Artificial Neural Networks". Technical report, The Computer and Vision Research Center, University of Texas, Austin.
- [137] E. Prop (1994). "RULENEG: Extracting Rules from a Trained Artificial Neural Network by Step-wise Negation". Semester Project, Queensland University of Technology.
- [138] Andrews, R. and Geva, S. (1994). "Rule Extraction from a Constrained Error Back propagation Network". In *Proceedings of the 5th ACNN*, pages 9-12. University of Qld, Brisbane.
- [139] Setiono, R. and Liu, H. (1995). "Understanding Neural Networks Via Rule Extraction". In *Proceedings of the 14th International Joint Conference on Artificial Intelligence*,, pages 480-485, Montreal, Canada.
- [140] Setiono, R. and Liu, H. (1996). "Symbolic Representation of Neural Network". *IEEE Computer* , pages 71-77.
- [141] Setiono, R. and Liu, H. (1997). "Neurolinear: From Neural Networks to Oblique Decision Rules". *Neurocomputing*, 17(1), 1-24.
- [142] Andrews, R. and Geva, S. (1995). "RULEX & CEBP Networks as the Basis for a Rule Refinement System". In J. Hallam, editor, *Hybrid Problems Hybrid Solutions*, pages 1-12. IOS Press.

-
- [143] McMillan, C., Mozer, M. and Smolensky, P. (1991). "The Connectionist Scientist Game: Rule Extraction and Refinement in a Neural Network". In Proceedings of the 13th Annual Conference of the Cognitive Science Society, pages 424-430. Hillsdale, NJ.
- [144] McMillan, C., Mozer, M. C. and Smolensky, P. (1992). "Rule Induction Through Integrated Symbolic and Sub Symbolic Processing". In J. E. Moody, S. J. Hanson, and R. P. Lippmann, editors, Advances in neural information processing systems, volume 4, pages 969-976. Morgan Kaufmann, San Matéo, CA.
- [145] Giles, C. and Omlin, C. (1993). "Extraction, Insertion and Refinement of Rules in Dynamically Driven Recurrent Networks". Connection Science, 5(3-4), 307-328.
- [146] Craven, M. and Shavlik, J. (1994). "Using Sampling and Queries to Extract Rules from Trained Neural Networks". In W. Cohen and H. Hirsh, editors, Machine Learning: Proceedings of the 11th International Conference, San Francisco, CA. Morgan Kaufmann.
- [147] Tickle, A. B., Orłowski, M. and Diederich, J. (1996). "Dedec: A Methodology for Extracting Rules from Trained Artificial Neural Networks". In Proceedings of the Rule Extraction From Trained Artificial Neural Networks Workshop, pages 90-102. University of Queensland.
- [148] Zadeh, L. A. (1965). "Fuzzy Sets, Information and Control". Vol. 8, pp. 338-353.
- [149] Lin, C. T. and Lee, C. S. G. (1995). "Fuzzy Adaptative Learning Control Network with On-line Neural Learning", Fuzzy Sets and Systems, n.71, pp.25-45.
- [150] Jang, J. S. R. (1993). "ANFIS: Adaptive-Network-Based Fuzzy Inference System", IEEE Transactions on Systems, Man, and Cybernetics, Vol.23, No.3, pp.665-685.

-
- [151] Carpenter, G. A., Grossberg, S. and Rosen, D. B. (1991). "Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system," *Neural Networks*, vol. 4, pp. 759-771.
- [152] Carpenter, G. A., Grossberg, S., Markuzon, N., Reynolds, J. H., and Rosen, D. B. (1993). "Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps". *IEEE Trans. Neural Networks*, vol. 3, no. 5, pp. 698-713.
- [153] Vuorimaa, P. (1994). "Fuzzy self-organizing map". *Fuzzy Sets and Systems* No.66, pp.223-231.
- [154] Jang, J. S. R. and Sun, C. T. (1995). "Neuro-Fuzzy Modeling and Control", *Proceedings of the IEEE*.
- [155] Figueiredo, K. (2003). "Agentes Inteligentes: Novos Modelos Neuro-Fuzzy Hierárquicos com Aprendizado Automático Baseado em Reinforcement Learning". Tese de Doutorado. DEE. PUC-Rio.
- [156] Kruse, R. and Nauck, D. (1995). "NEFCLASS-A Neuro-Fuzzy Approach for the Classification of Data", *Proc. of the ACM Symposium on Applied Computing*, Nashville.
- [157] Nauck, D. and Kruse, R. (1994). "NEFCON I: An X-Window Based Simulator for Neural Fuzzy Controllers". Department of Computer Science. Technical University of Braunschweig.
- [158] Nauck, D. and Kruse, R. (1994). "Neuro-Fuzzy Systems for Function Approximation". Faculty of Computer Science, Neural and Fuzzy Systems. Otto-von-Guericke University of Magdeburg.

-
- [159] Faloutsos, C. and Gaede, V. (1996). "Analysis of n-dimensional Quadrees Using the Hausdorff Fractal Dimension". Proceedings of the 22nd VLDB Conference Mumbai (Bombay), Índia.
- [160] Fahlman, S. E. (1998). "Faster-learning variations on backpropagation: na empirical study". Proc. Of the 1988 Connectionist Models Summer School, pages 38-51, Carnegie Mellon University.
- [161] Smith, J. R. and Chang, S. F. (1994). "Quad-Tree Segmentation for Texture-Based Image Query". Proceedings of the 2nd Annual ACM Multimedia Conference, San Francisco.
- [162] Gonçalves, L. B., Vellasco, M. M. B. R., Pacheco, M. A. C. and Souza, F. J. (2006). "Inverted hierarchical neuro-fuzzy BSP system: a novel neuro-fuzzy model for pattern classification and rule extraction in databases". IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, Volume: 36, Issue: 2, page(s): 236-248.
- [163] Barret, R., Berry, M., Chan, T. and Demmel, J. (1994). "Templates for the Solution of Linear Systems: Building Blocks for Iterative Methods", Website: <http://www.netlib.org>
- [164] Yager, R. R. and Filev, D. P. (1994). "Template-based Fuzzy Systems Modeling". J. Intell. And Fuzzy Syst., vol. 2, pp. 39-54.
- [165] Mardia, K. V., Kent, J. T. and Bibby, J. M. (1979) "Multivariate Analysis". Academic Press Inc. (London) Ltd.
- [166] Dash, M. and Lui, H. (1997). "Dimensionality Reduction for Unsupervised Data". Ninth IEEE International Conference on Tools with AI.

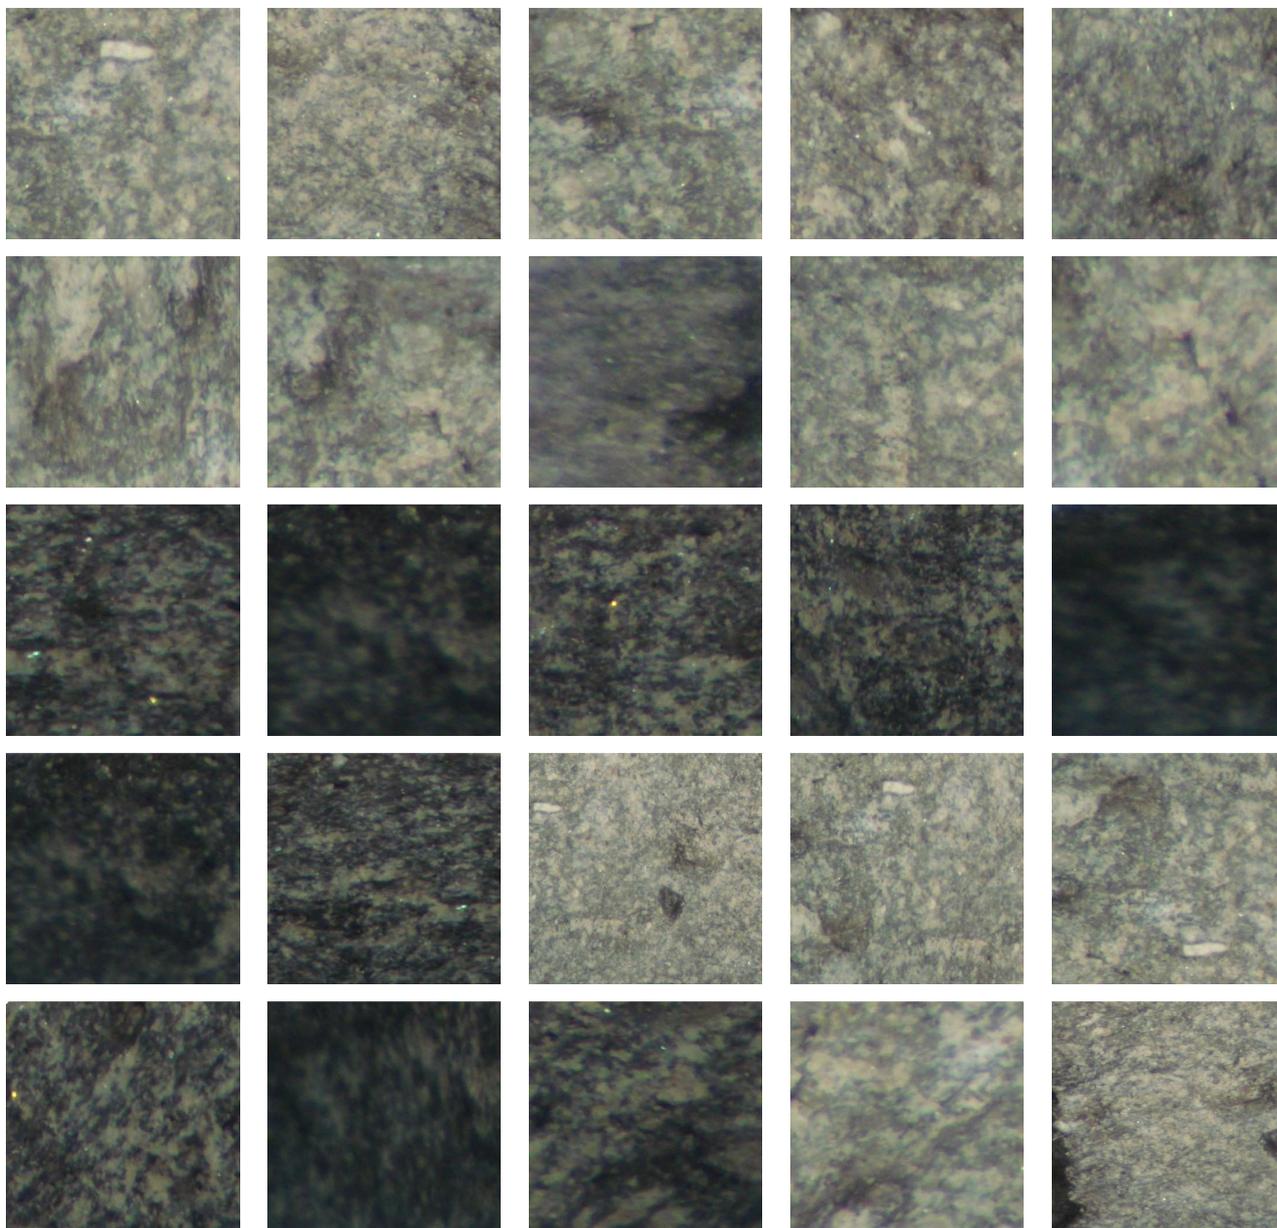
-
- [167] Back; A. D. and Trappenberg, T. P. (2001). "Selecting Inputs for Modeling Using Normalized Higher Order Statistics and Independent Component Analysis". IEEE Transactions in Neural Networks, vol. 12, no. 3, pp 612-617.
- [168] Santen, A., Koot, G. L. M. and Zullo, L. C. (1997). "Statistical data analysis of chemical plant". Computers Chem. Engng, vol.21, pp S1123-S1129.
- [169] Goldberg, D. E. (1989). "Genetic Algorithms in Search, Optimization, and Machine Learning". Addison-Wesley Publishing Company, Inc.
- [170] Koza, J. R. (1992). "Genetic Programming: On the Programming of Computers By Means of Natural Selection". Cambridge, MA. The MIT Press.
- [171] Back; A. D. and Trappenberg, T. P. (2001). "Selecting Inputs for Modeling Using Normalized Higher Order Statistics and Independent Component Analysis". IEEE Transactions in Neural Networks, vol. 12, no. 3, pp 612-617.
- [172] Jang, J. S. R. (1994). "Structure Determination in Fuzzy Modeling: A Fuzzy Cart Approach". Proceedings of IEEE International Conference on Fuzzy Systems. Orlando.
- [173] Veloso, P. (1984), "Estrutura de Dados". Editora Campos.
- [174] Klösgen, W. and Zytkow, J. M. (1996). "Knowledge Discovery in Databases Terminology. Advances in Knowledge Discovery and Data Mining", Usama. M. Fayyad, Gregory. Piatetsky-Shapiro, Padhraic Smyth, and Ramasamy Uthurusamy Editors, 573-592.

APÊNDICE

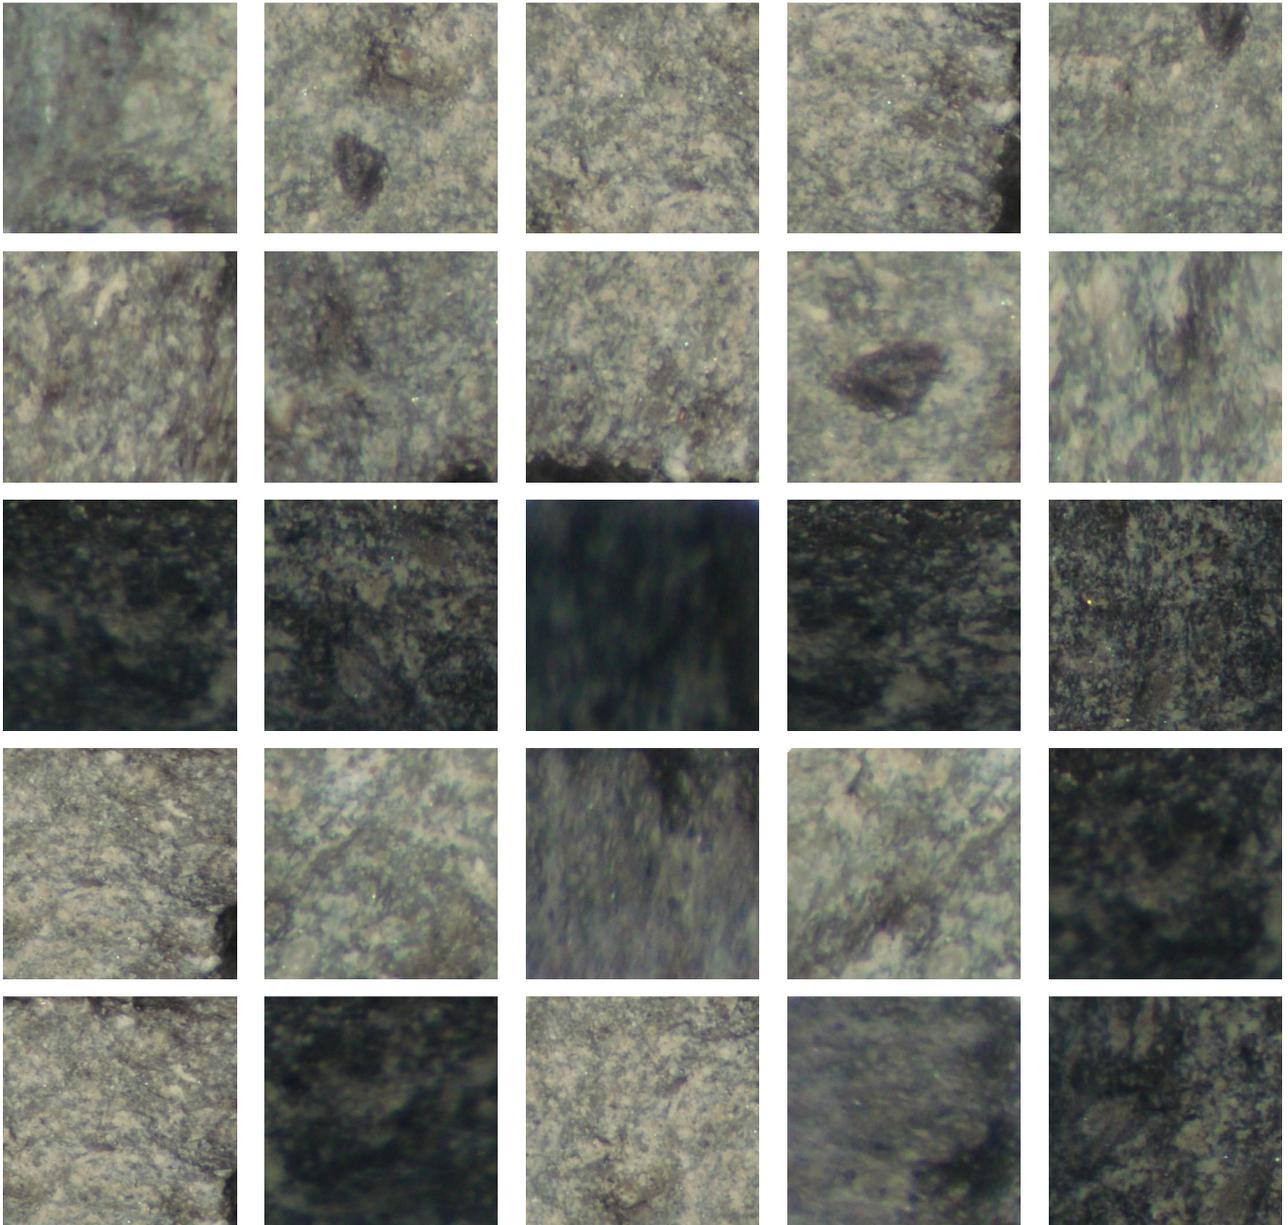
Imagens das Rochas Utilizadas para
Classificação de Textura

- Gnaiss

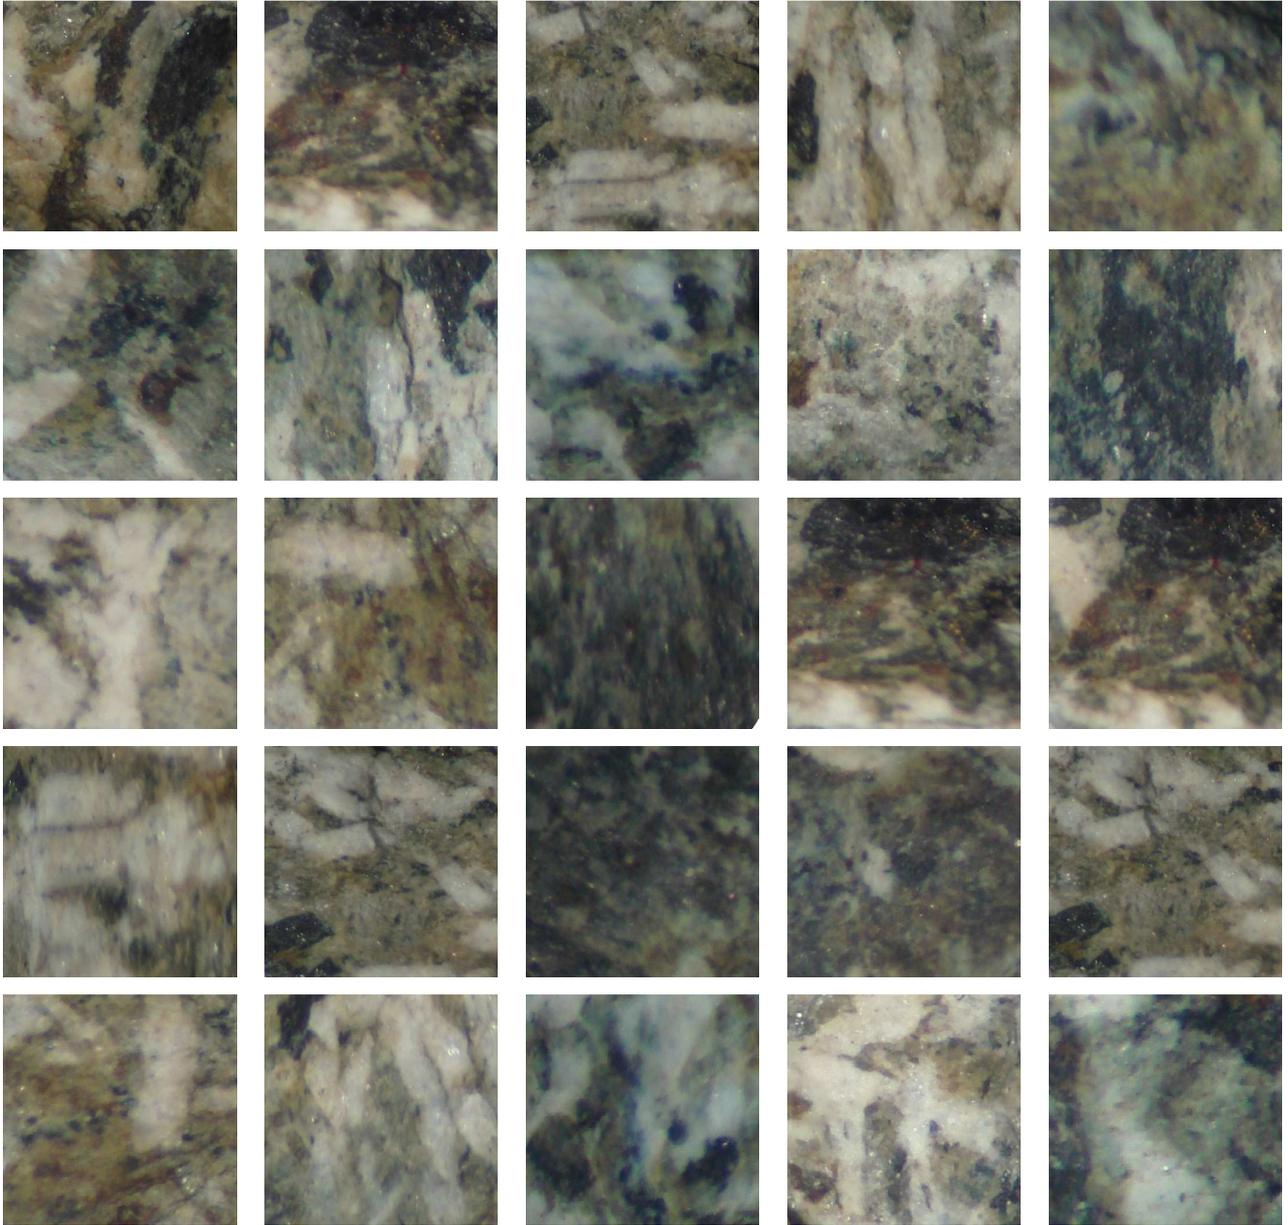
- Gnaiss granítico – Conjunto de Treinamento



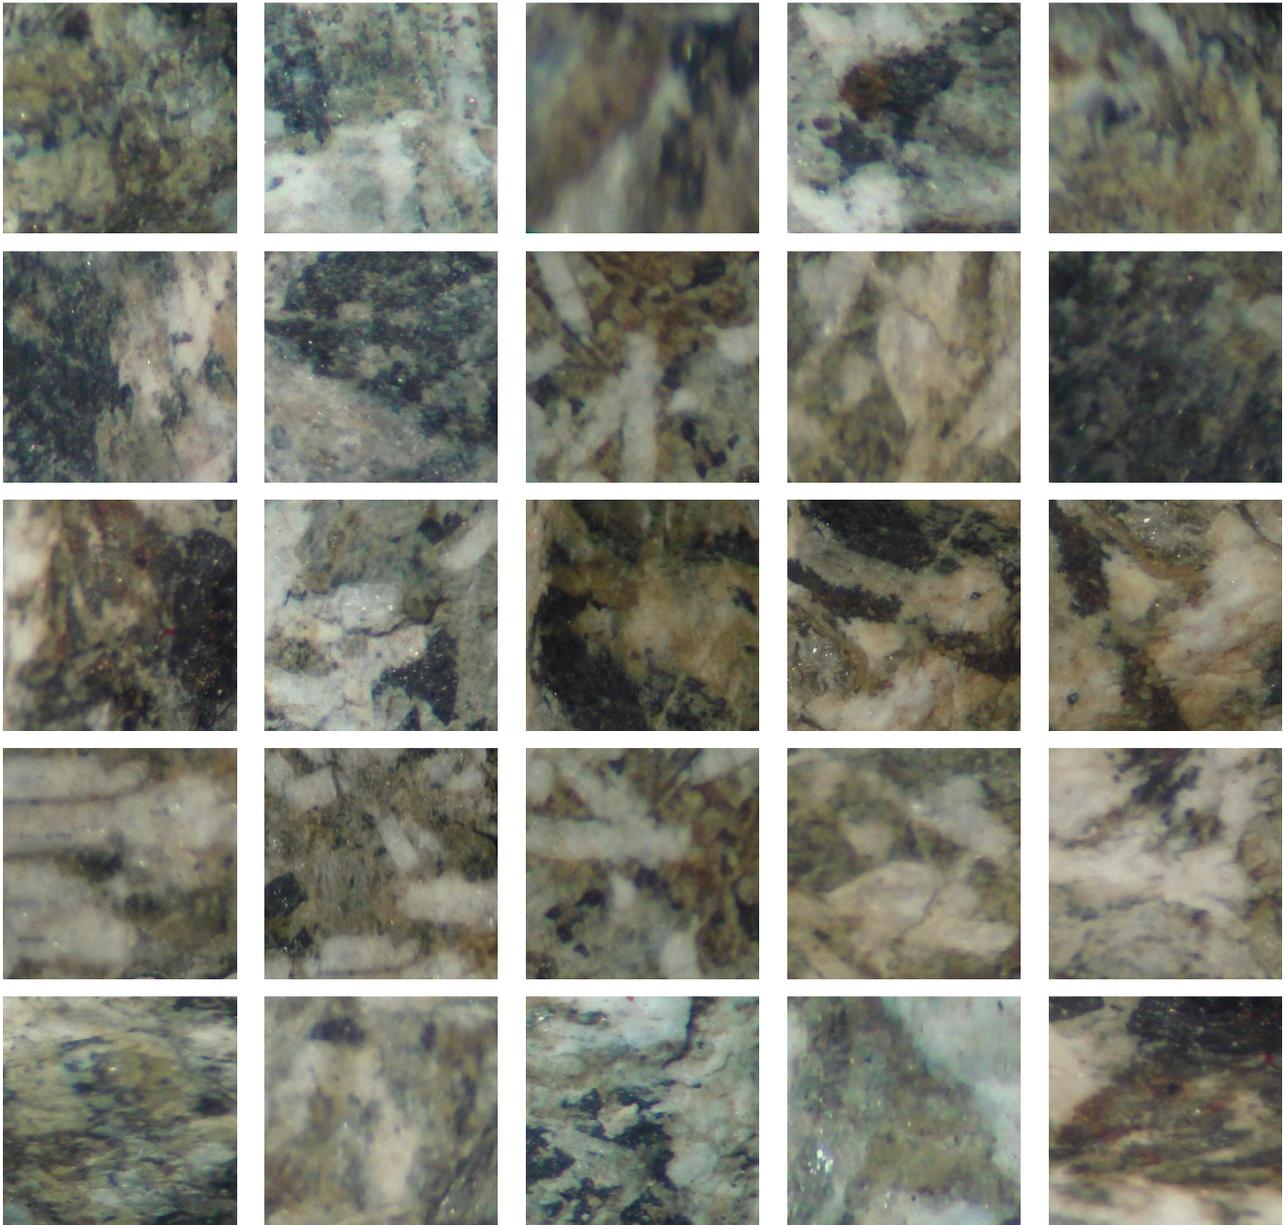
○ Gnaise granítico – Conjunto de Validação



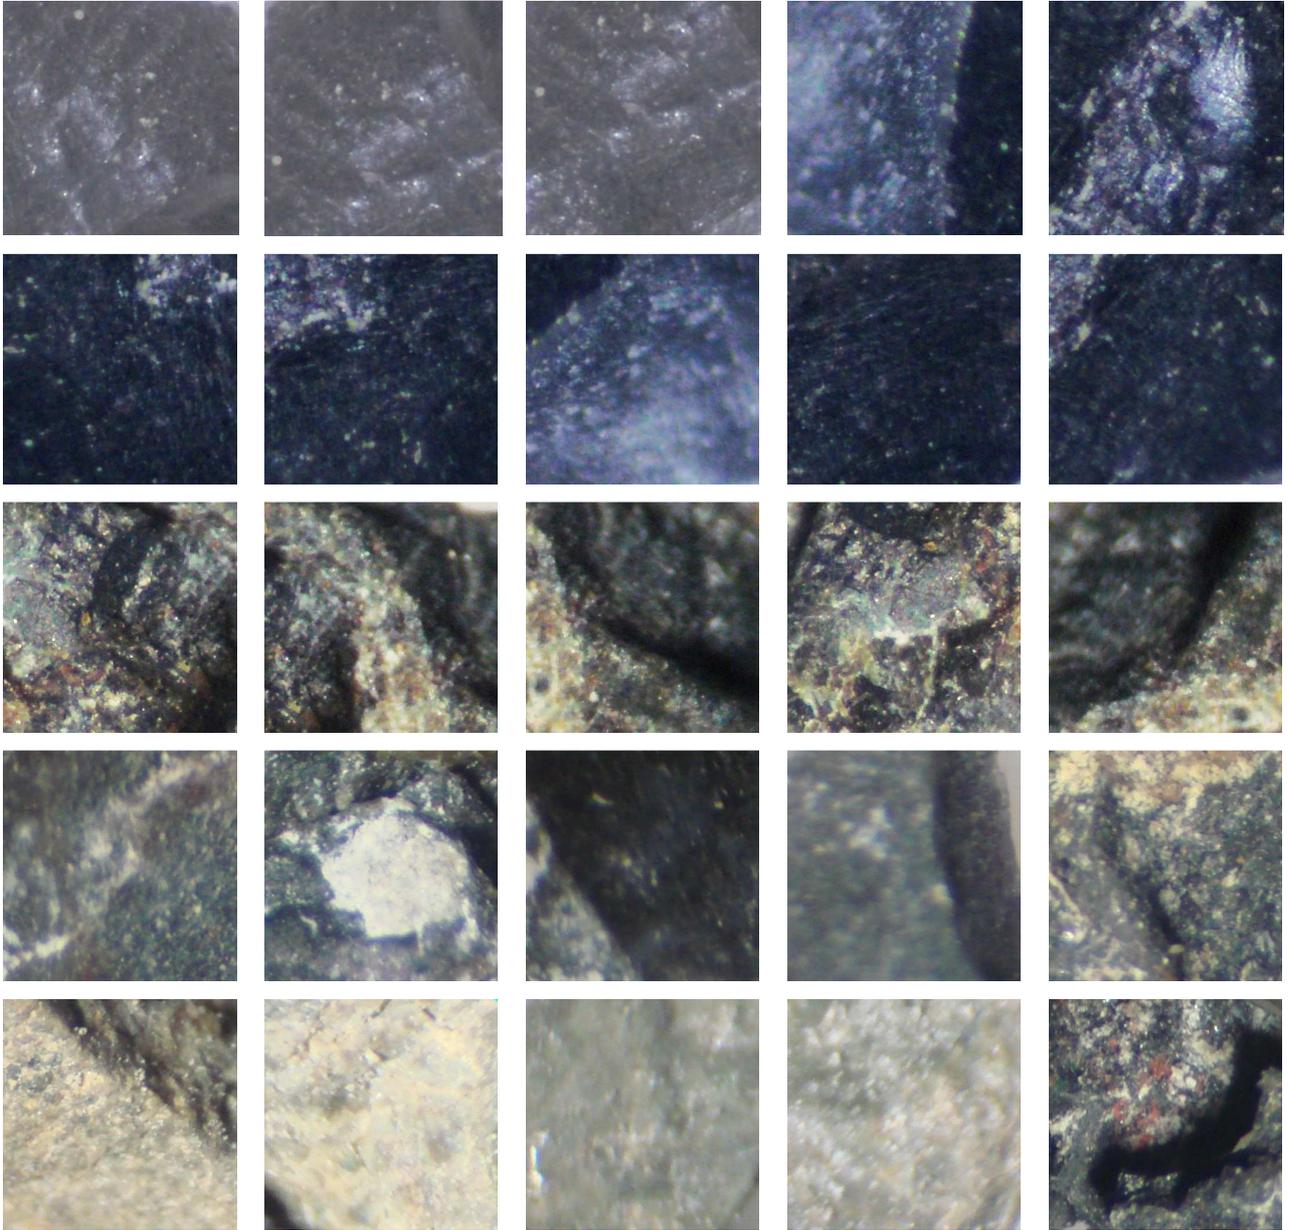
o Gnaiss leucocrático – Conjunto de Treinamento



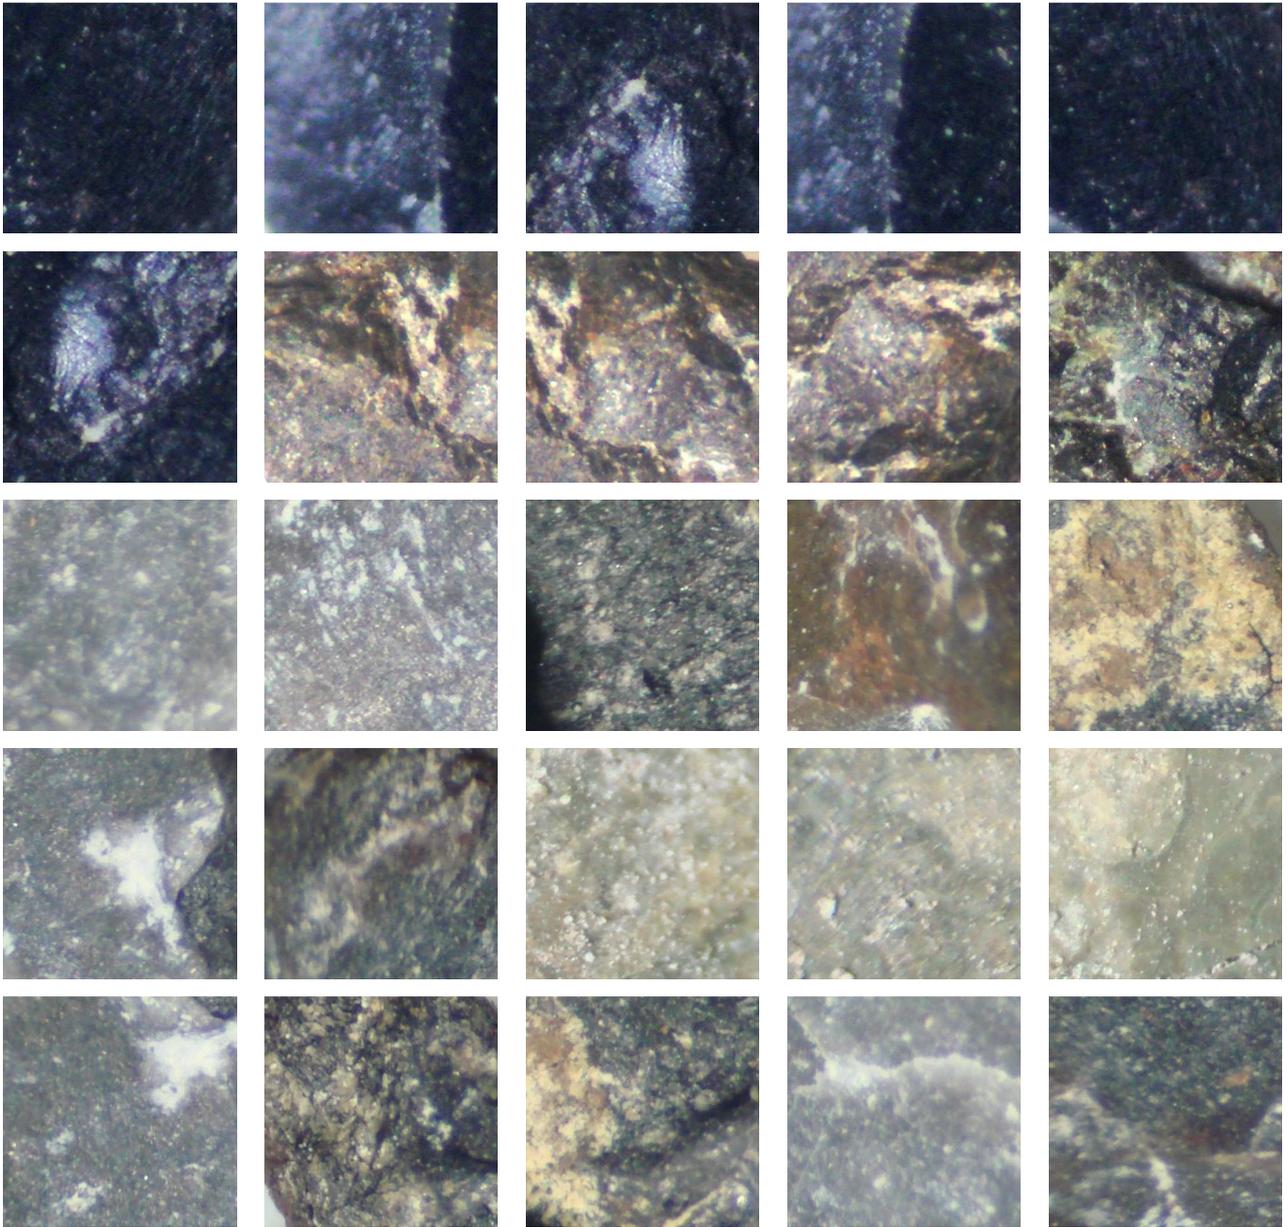
○ Gnaiss leucocrático – Conjunto de Validação



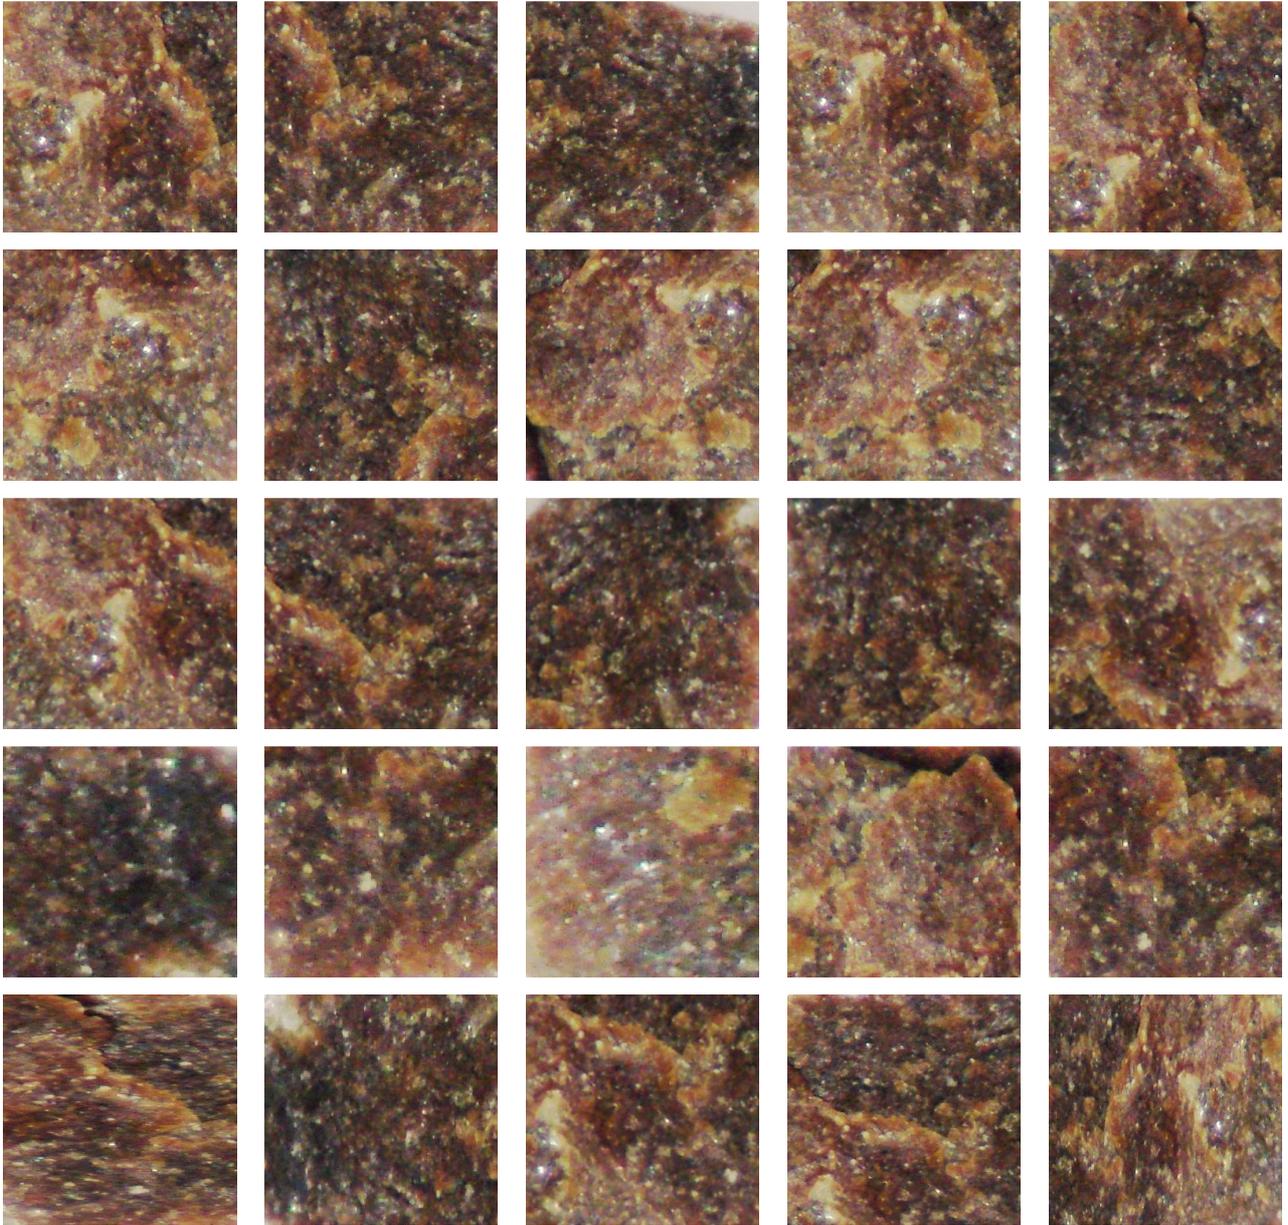
- Basalto
 - Basalto afanítico afírico – Conjunto de Treinamento



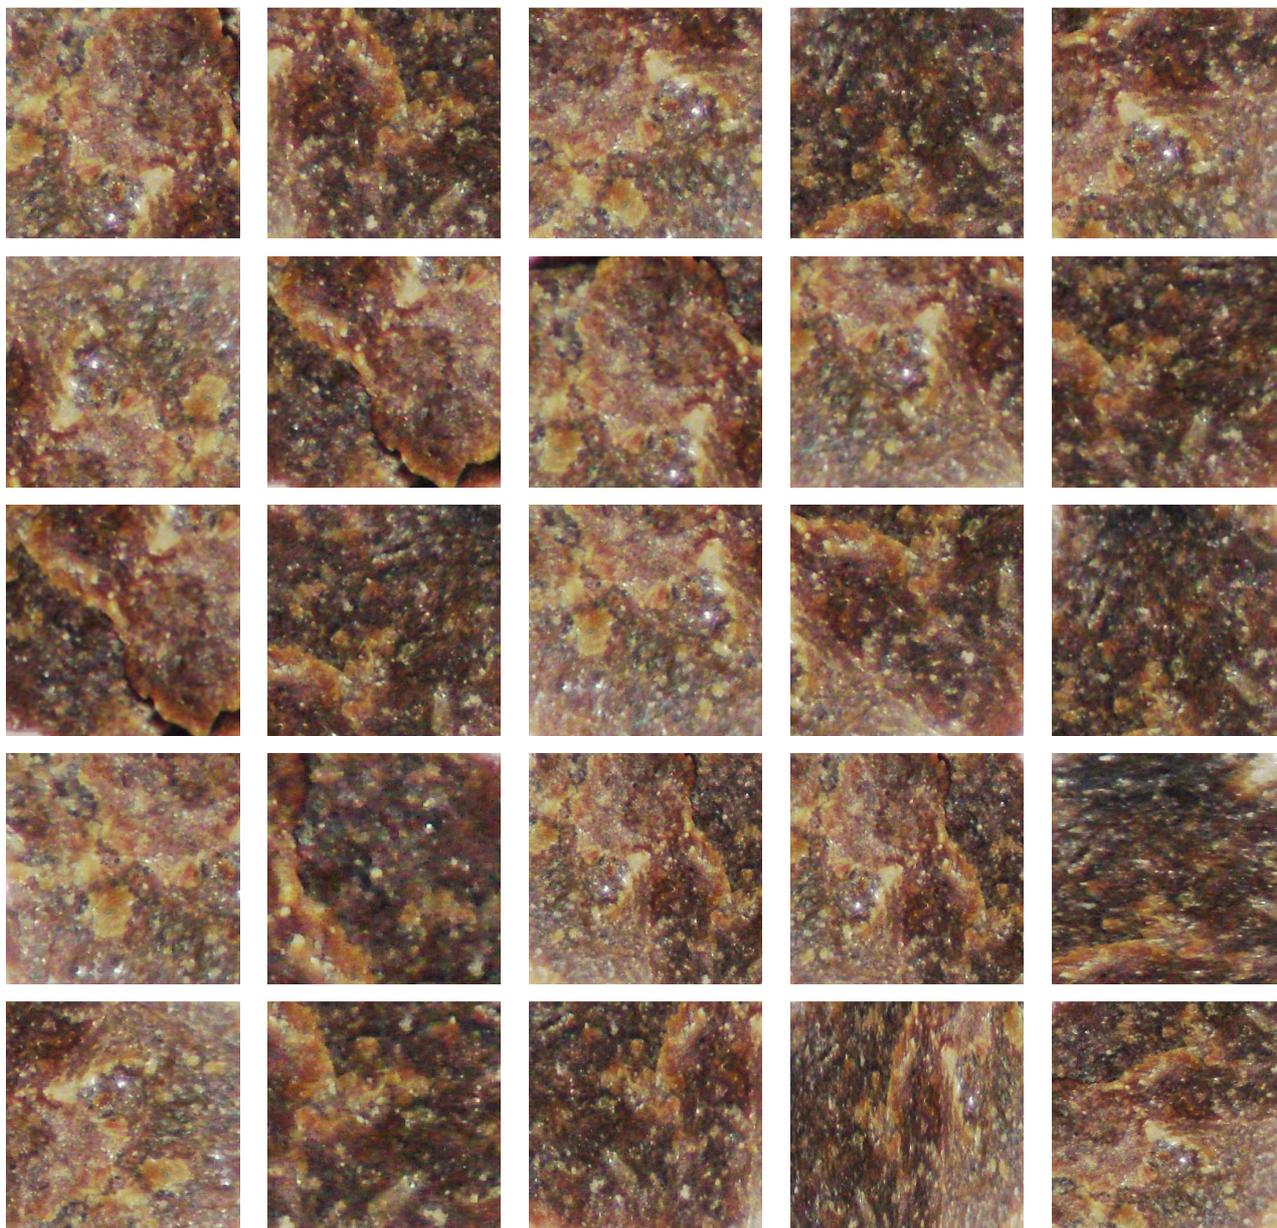
○ Basalto afanítico africano – Conjunto de Validação



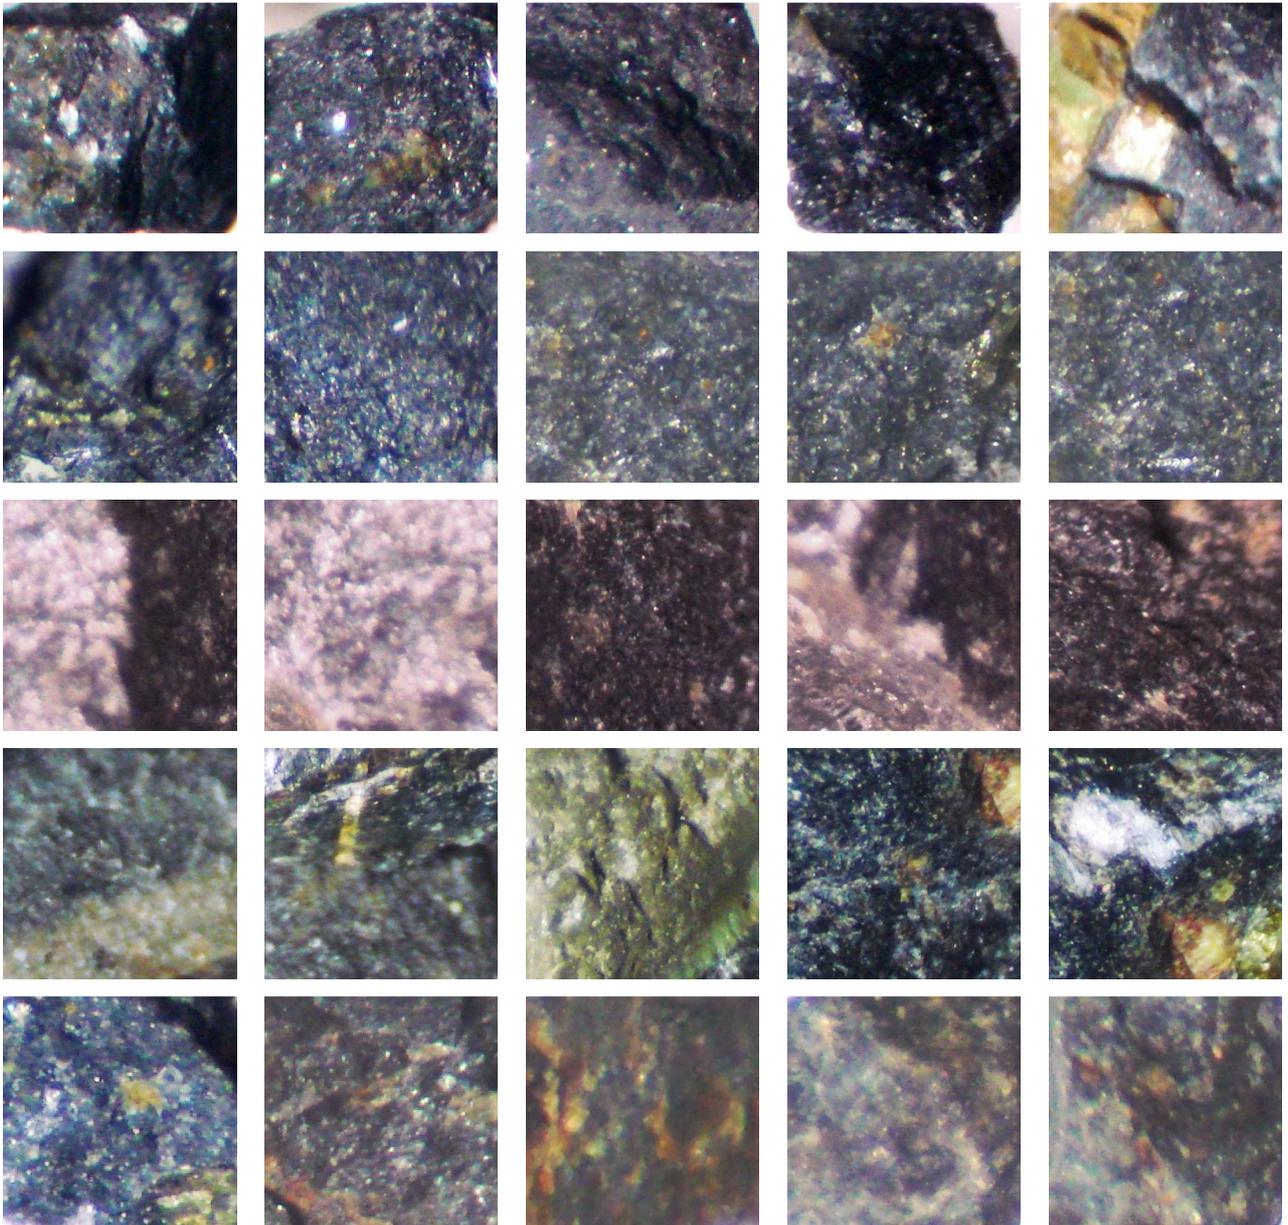
○ Basalto afanítico afírico oxidado – Conjunto de Treinamento



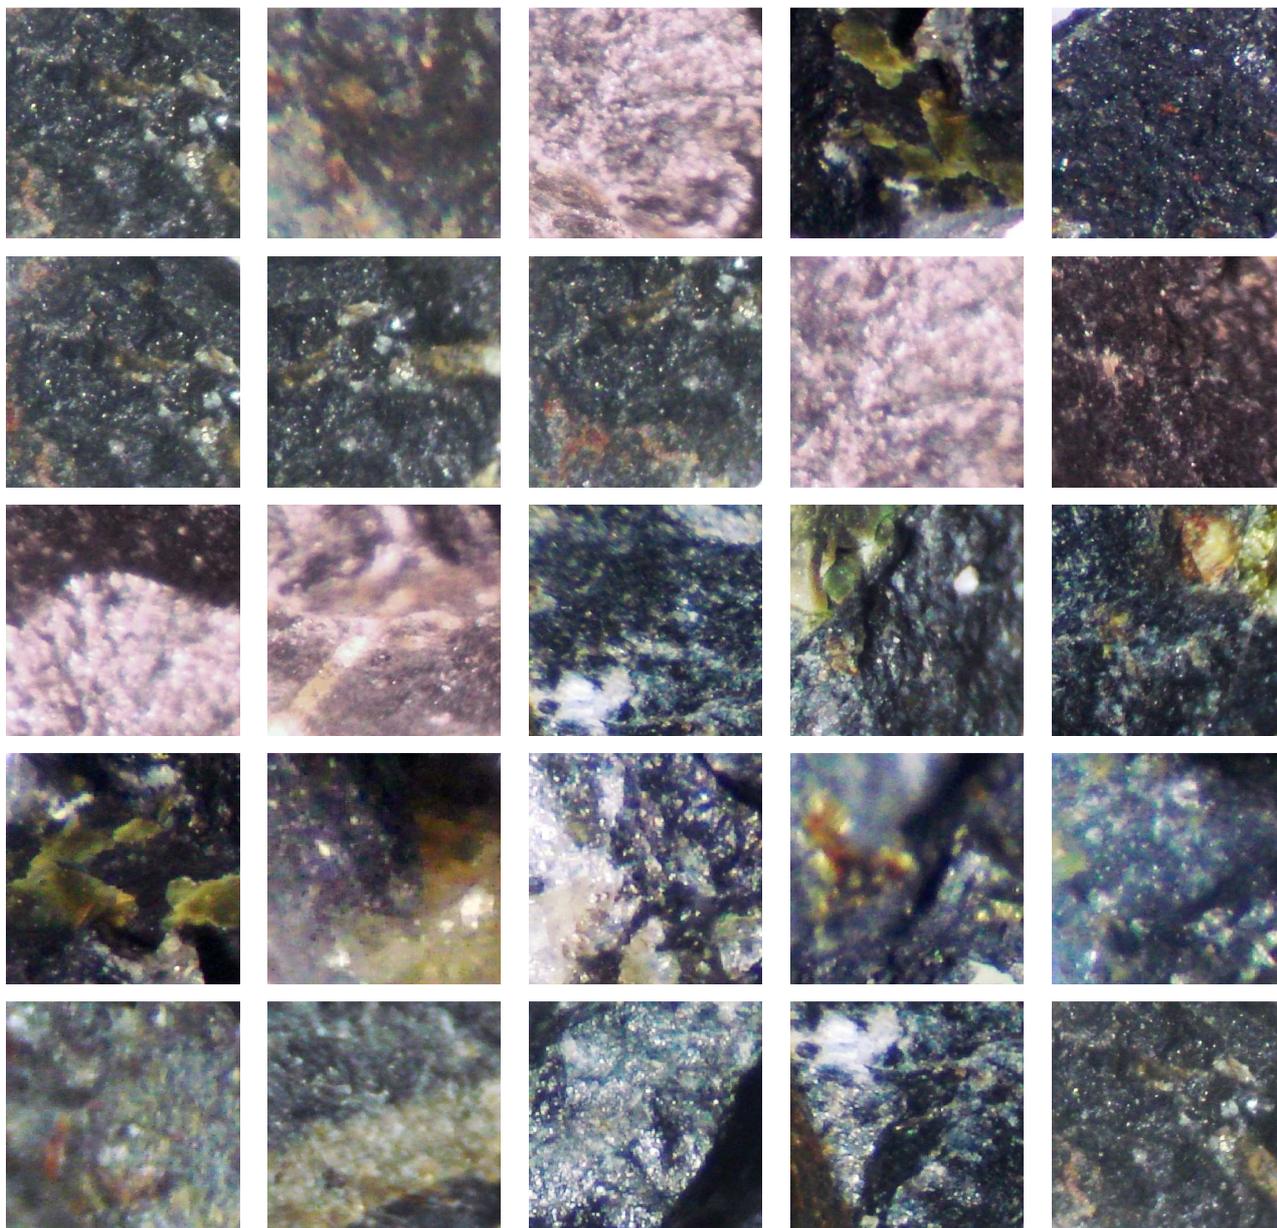
○ Basalto afanítico africano oxidado – Conjunto de Validação



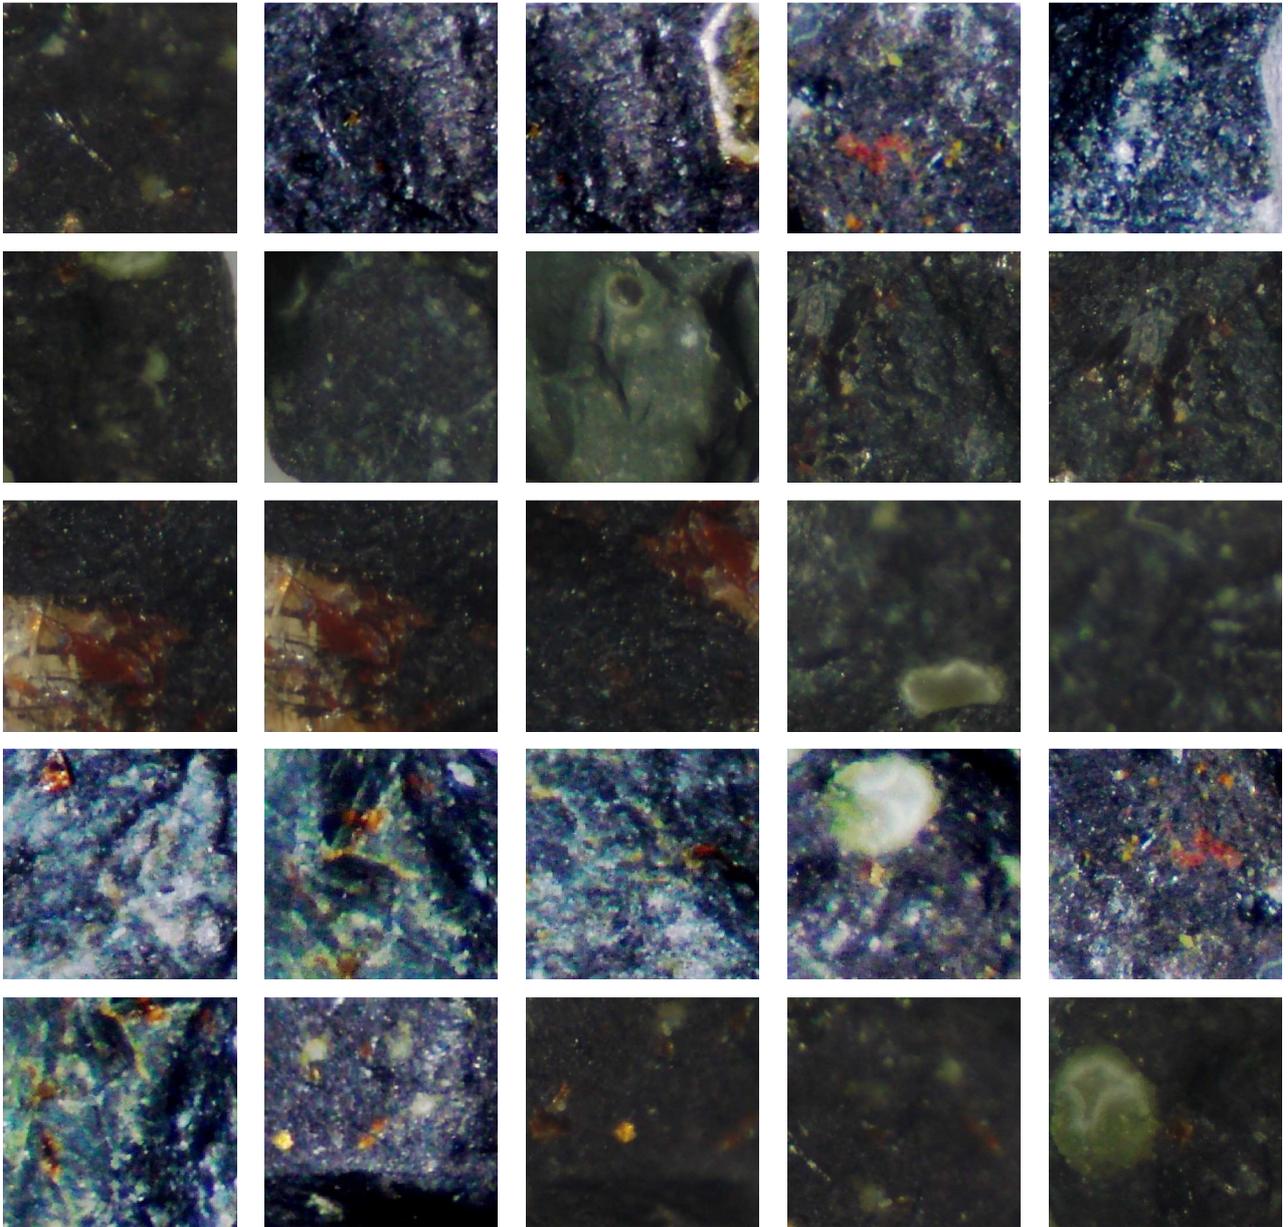
○ Basalto porfírico – Conjunto de Treinamento



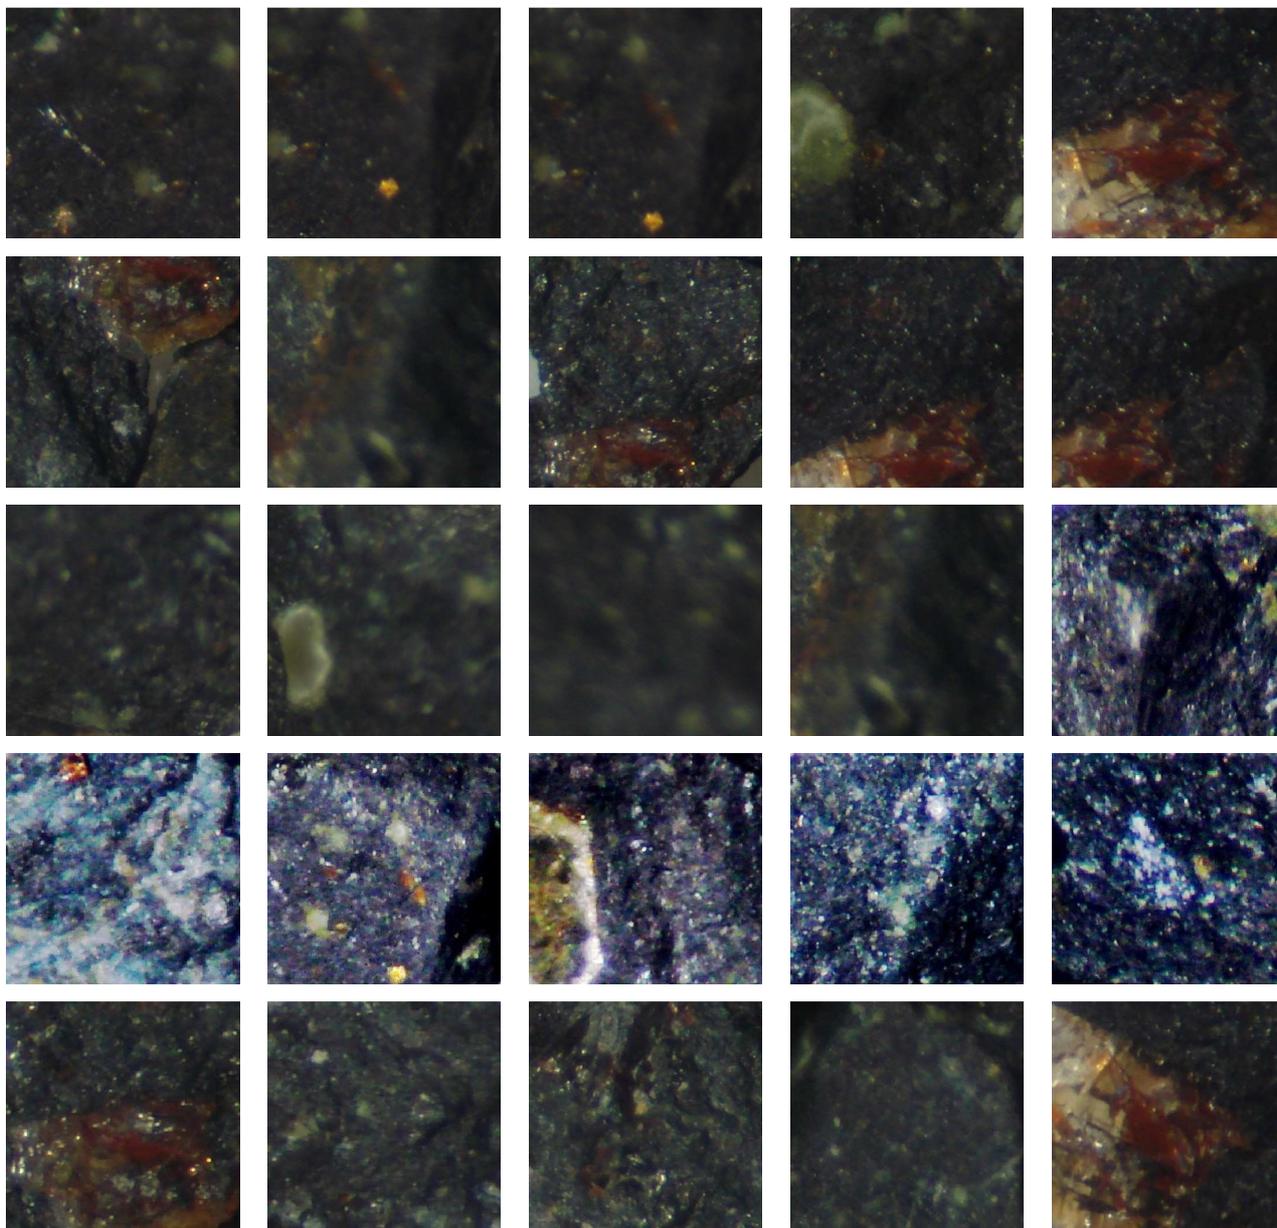
○ Basalto porfírico – Conjunto de Validação



○ Basalto porfírico amigdaloidal – Conjunto de Treinamento

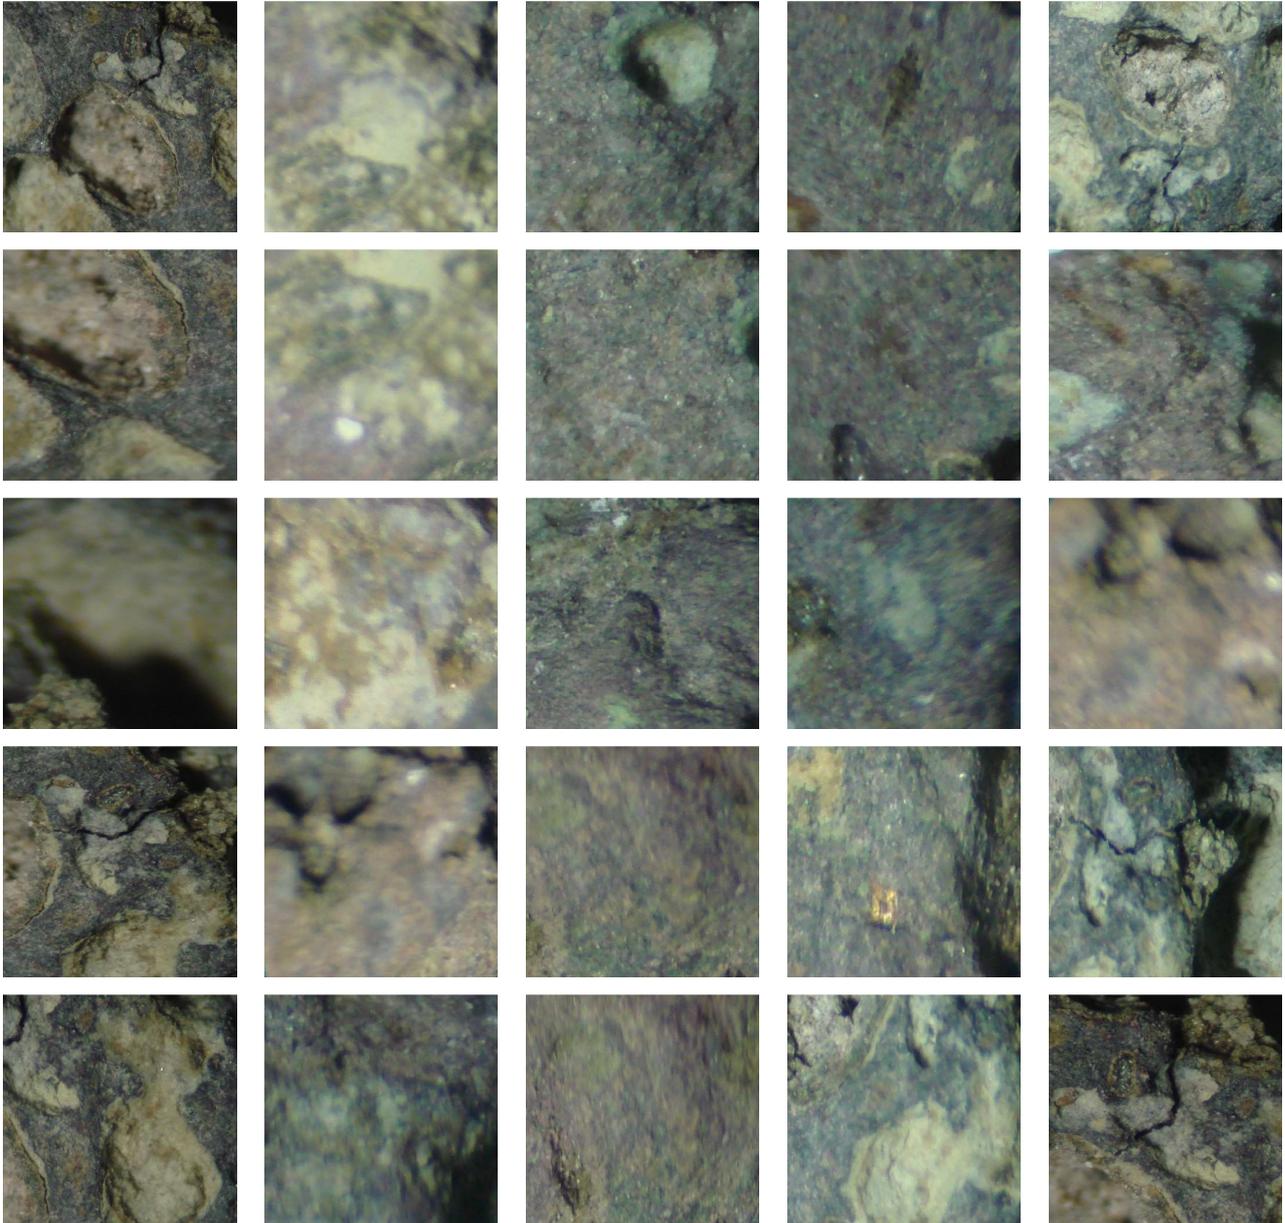


○ Basalto porfírico amigdaloidal – Conjunto de Validação

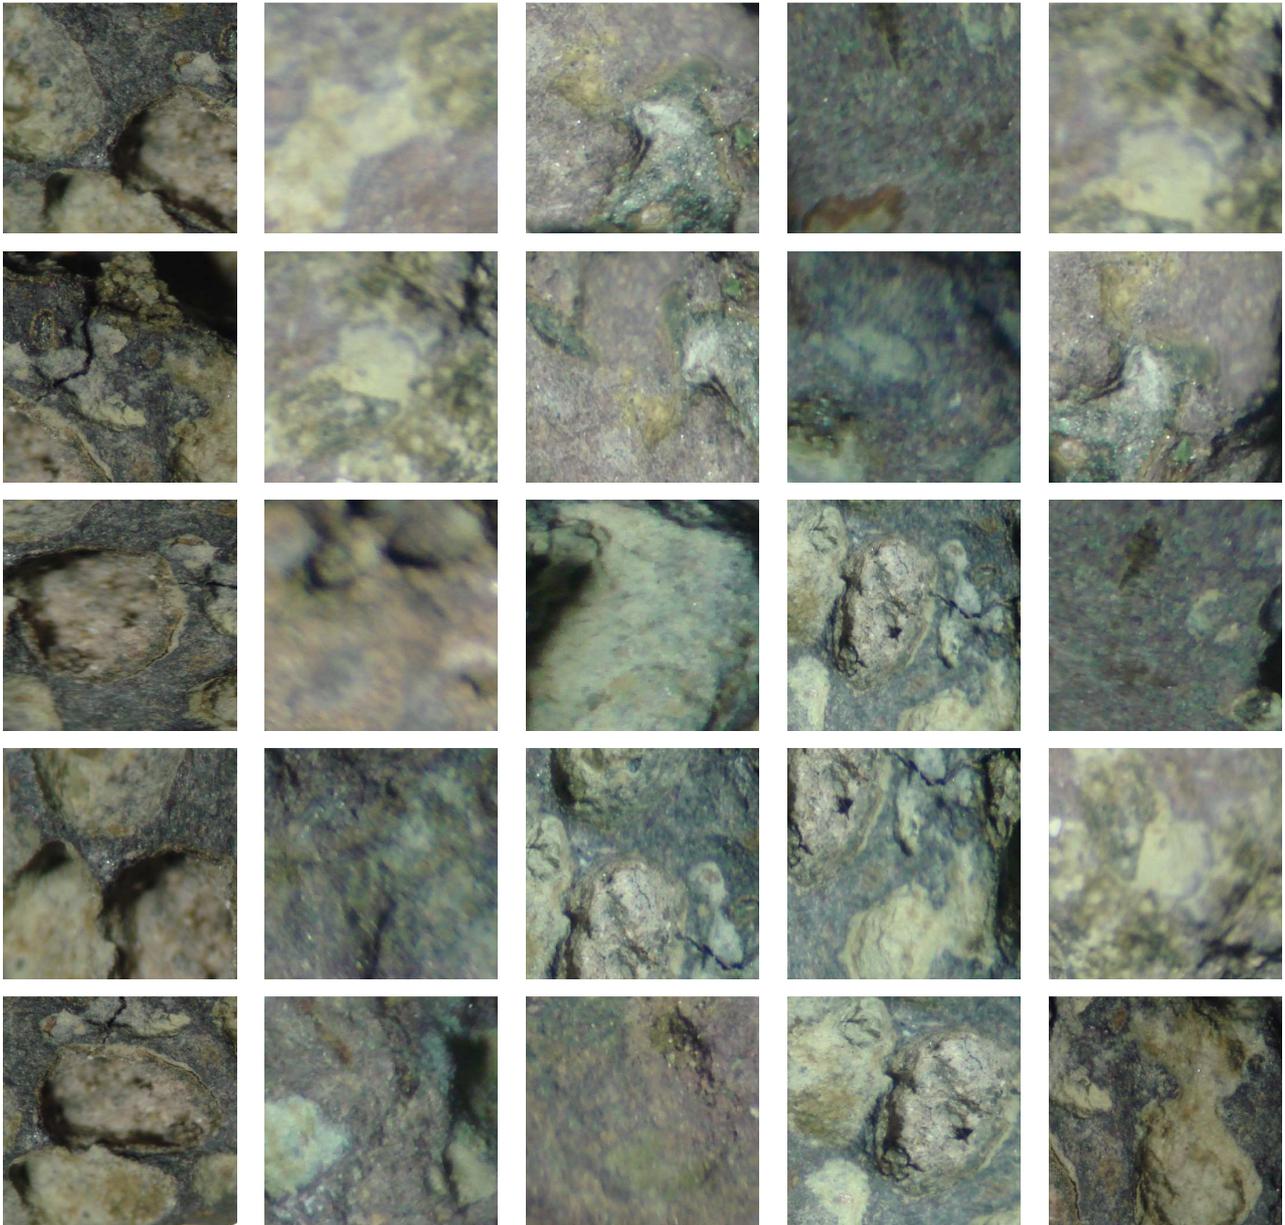


- Diabásio

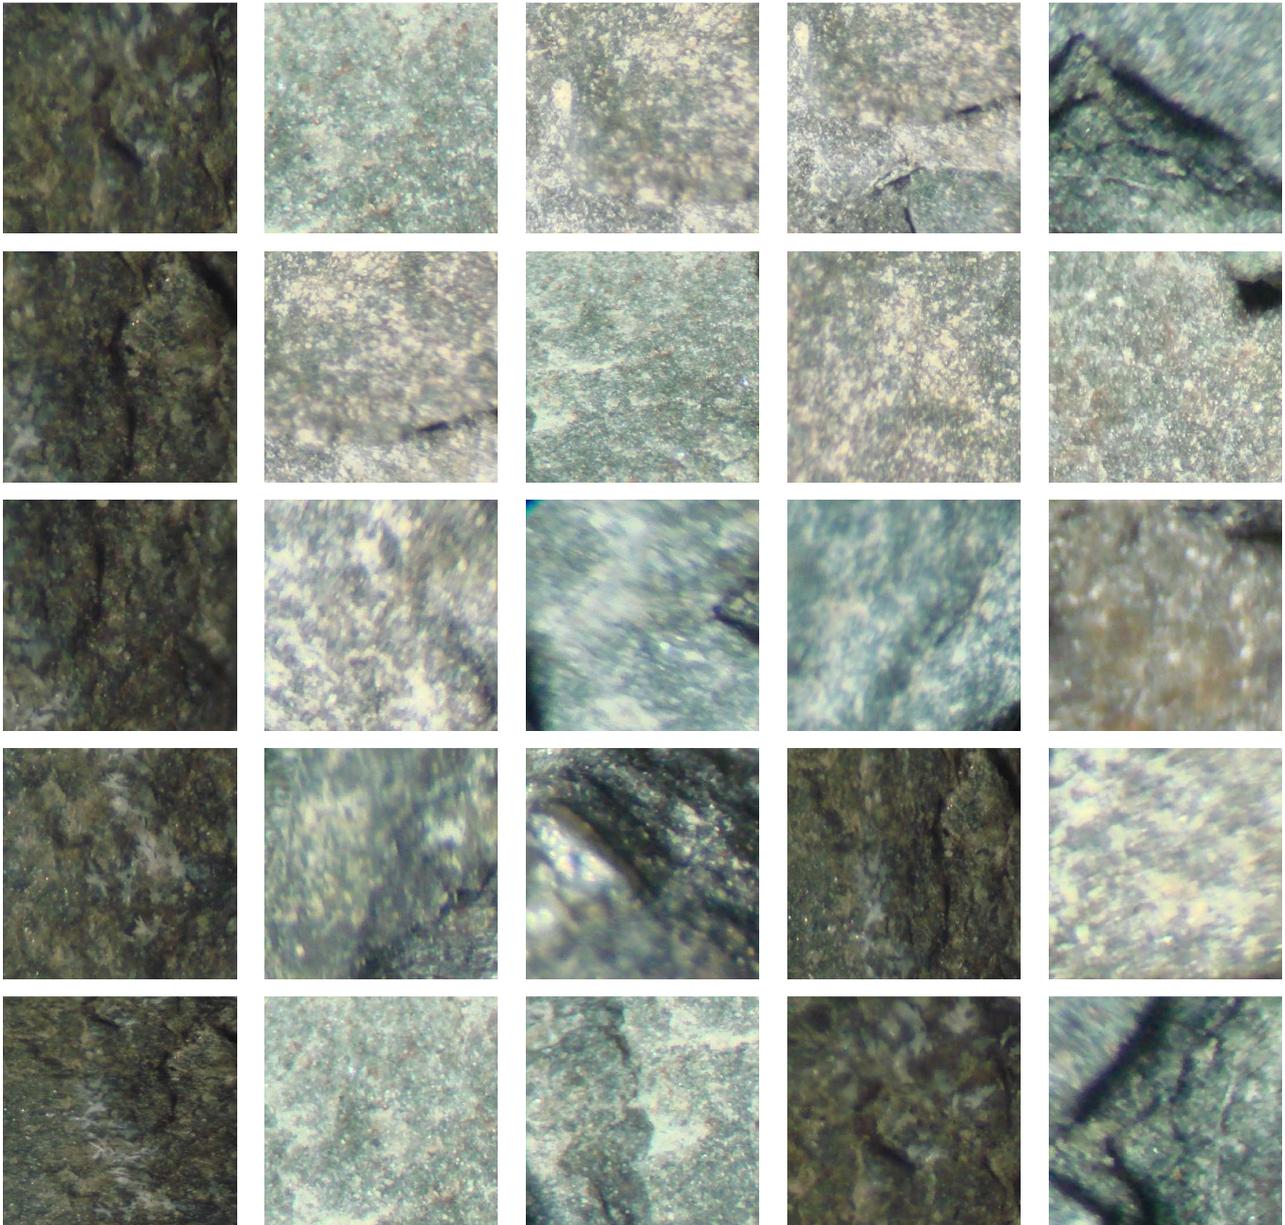
- Diabásio amigdaloidal alterado – Conjunto de Treinamento



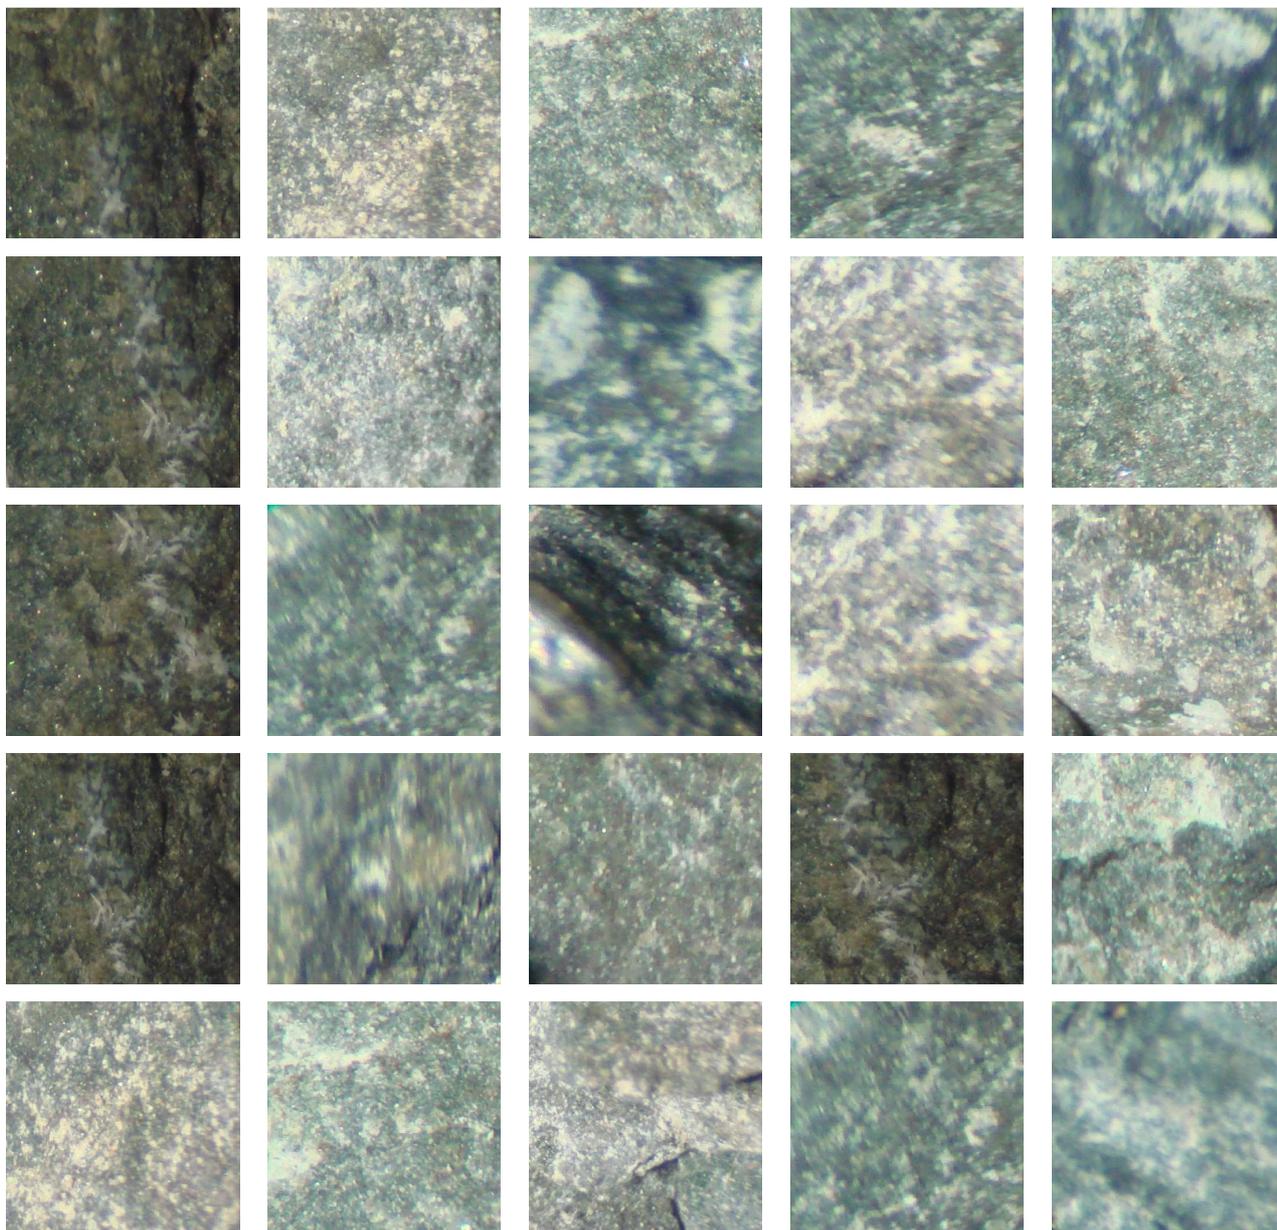
o Diabásio amigdaloidal alterado – Conjunto de Validação



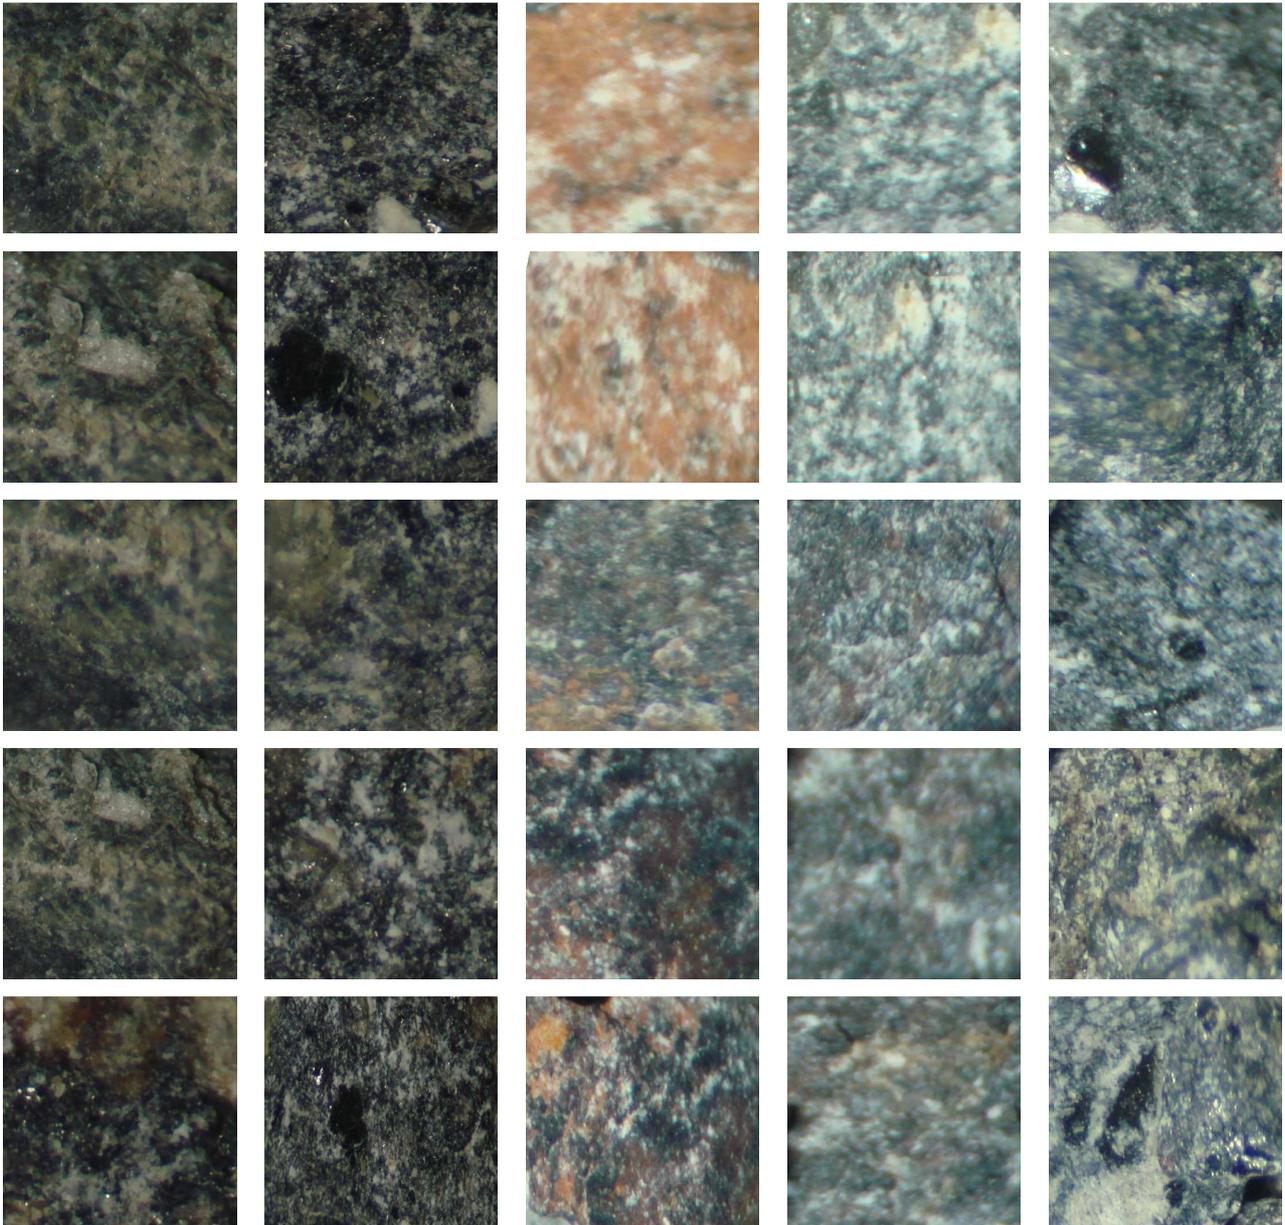
o Diabásio equigranular – Conjunto de Treinamento



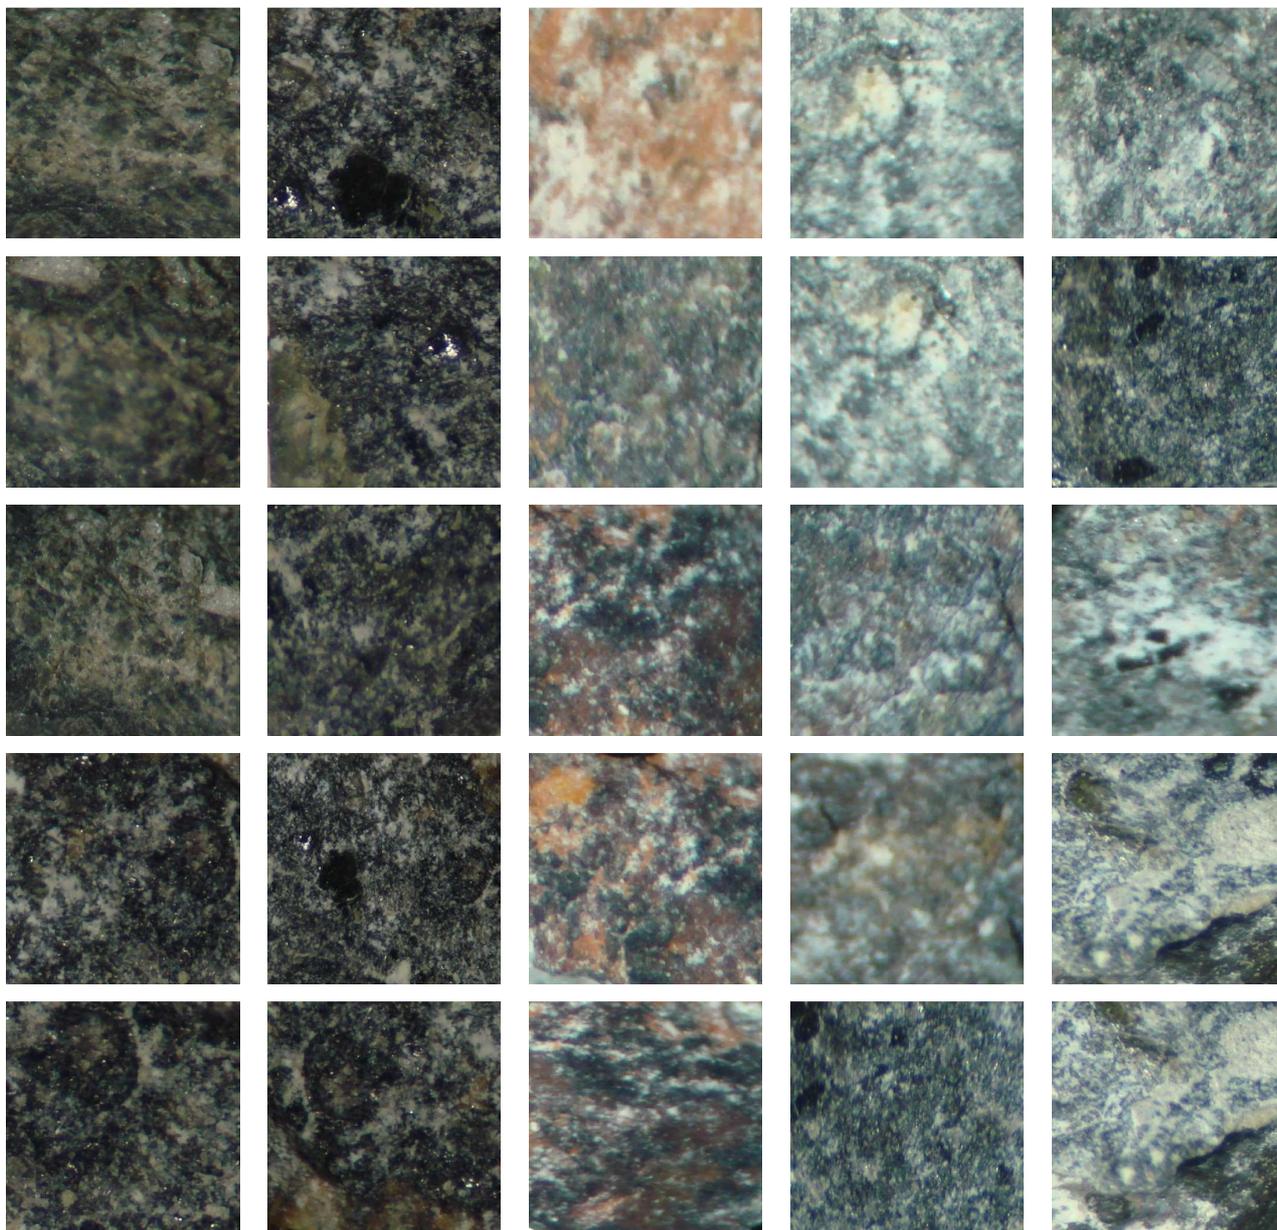
o Diabásio equigranular – Conjunto de Validação



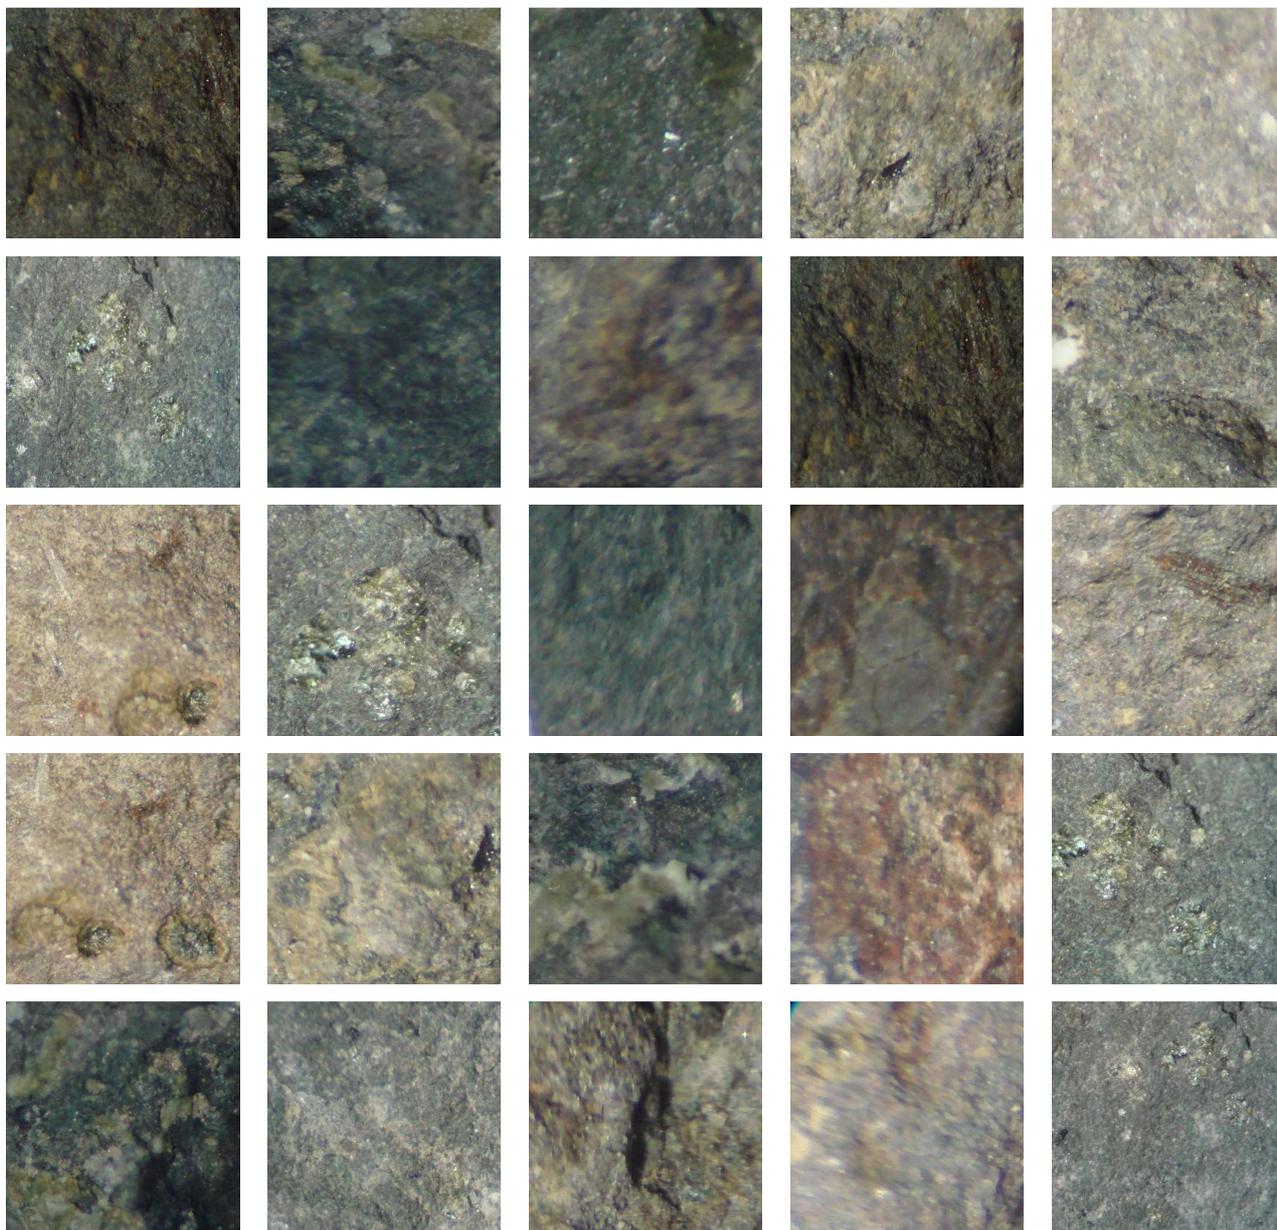
○ Diabásio porfirítico – Conjunto de Treinamento



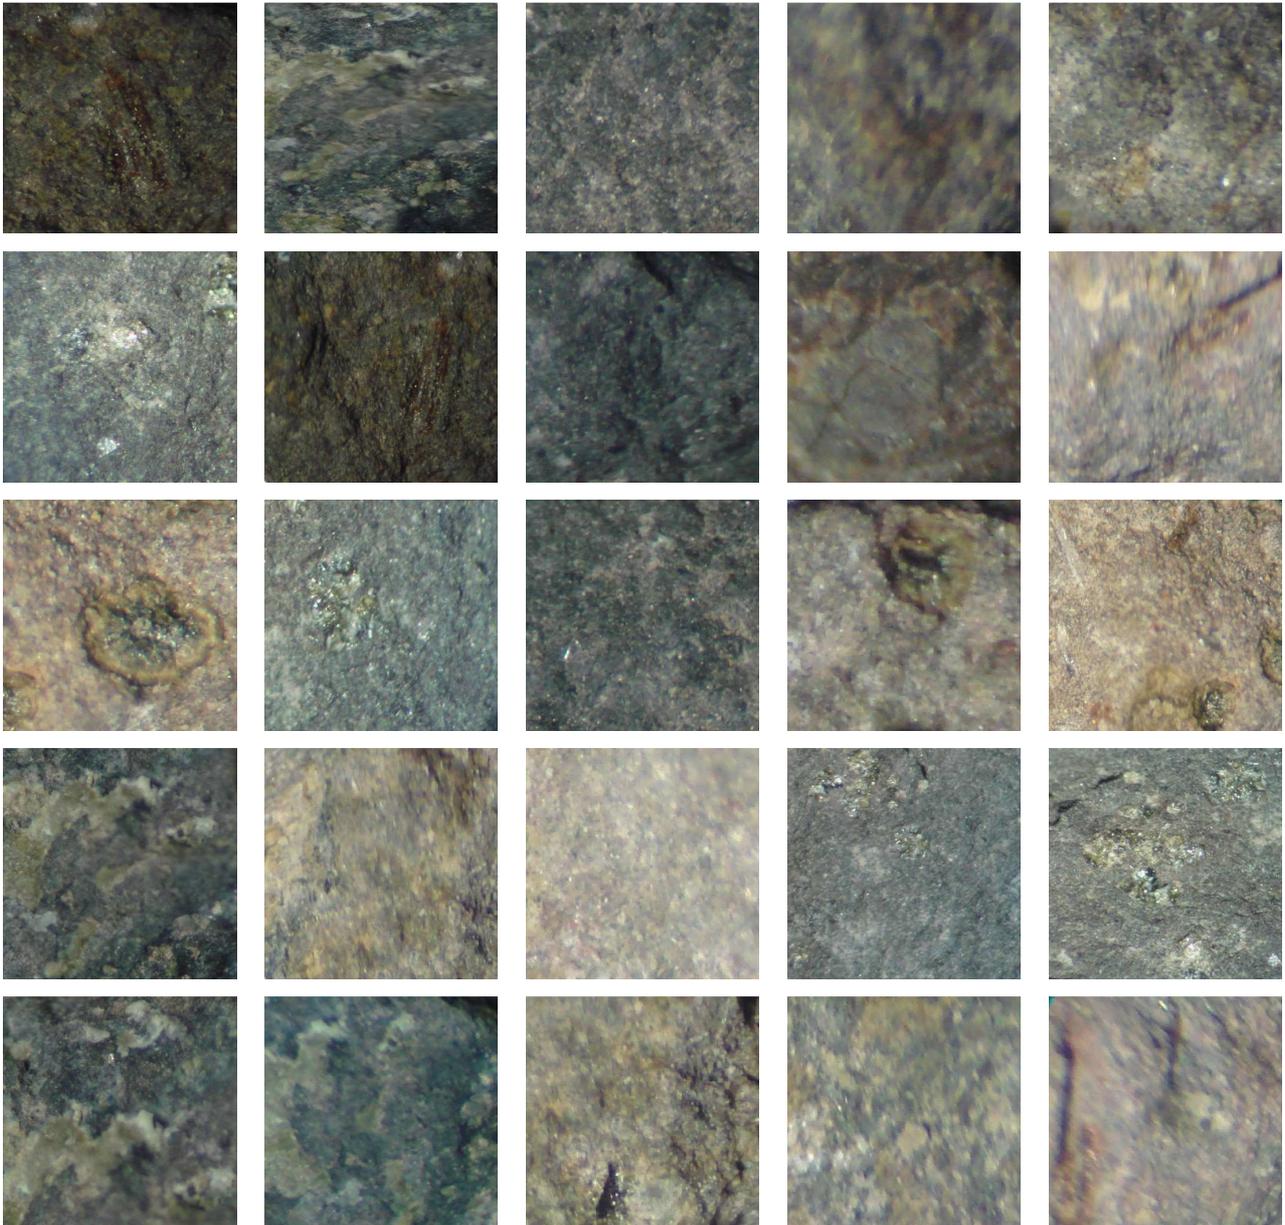
o Diabásio porfirítico – Conjunto de Validação



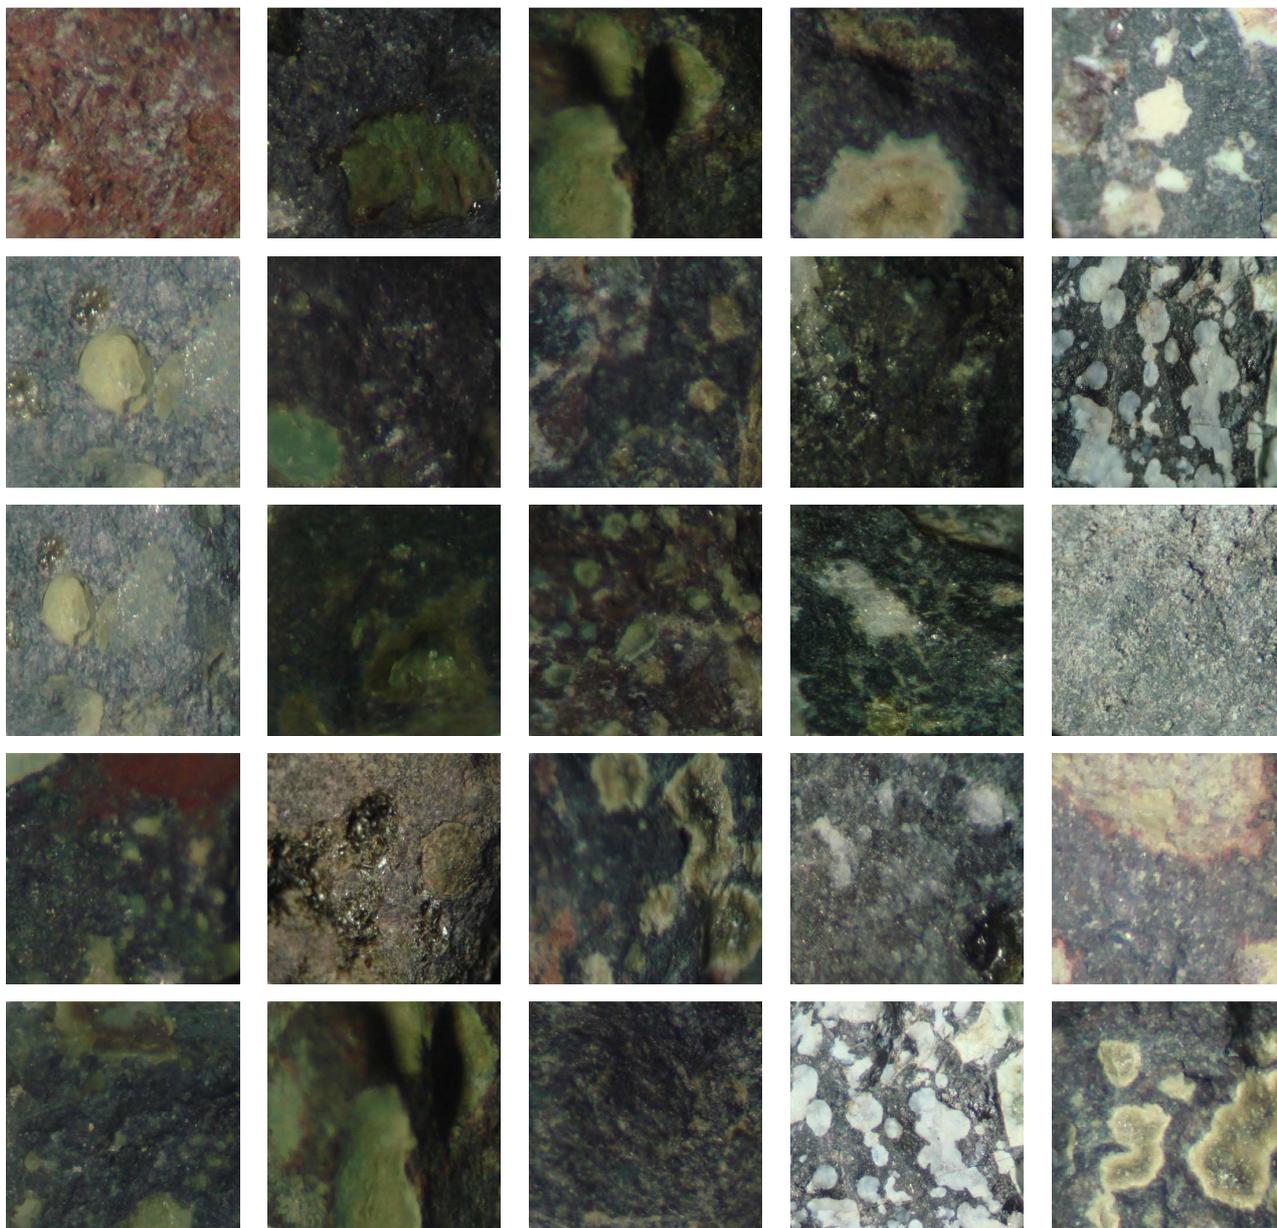
o Diabásio porfirítico alterado – Conjunto de Treinamento



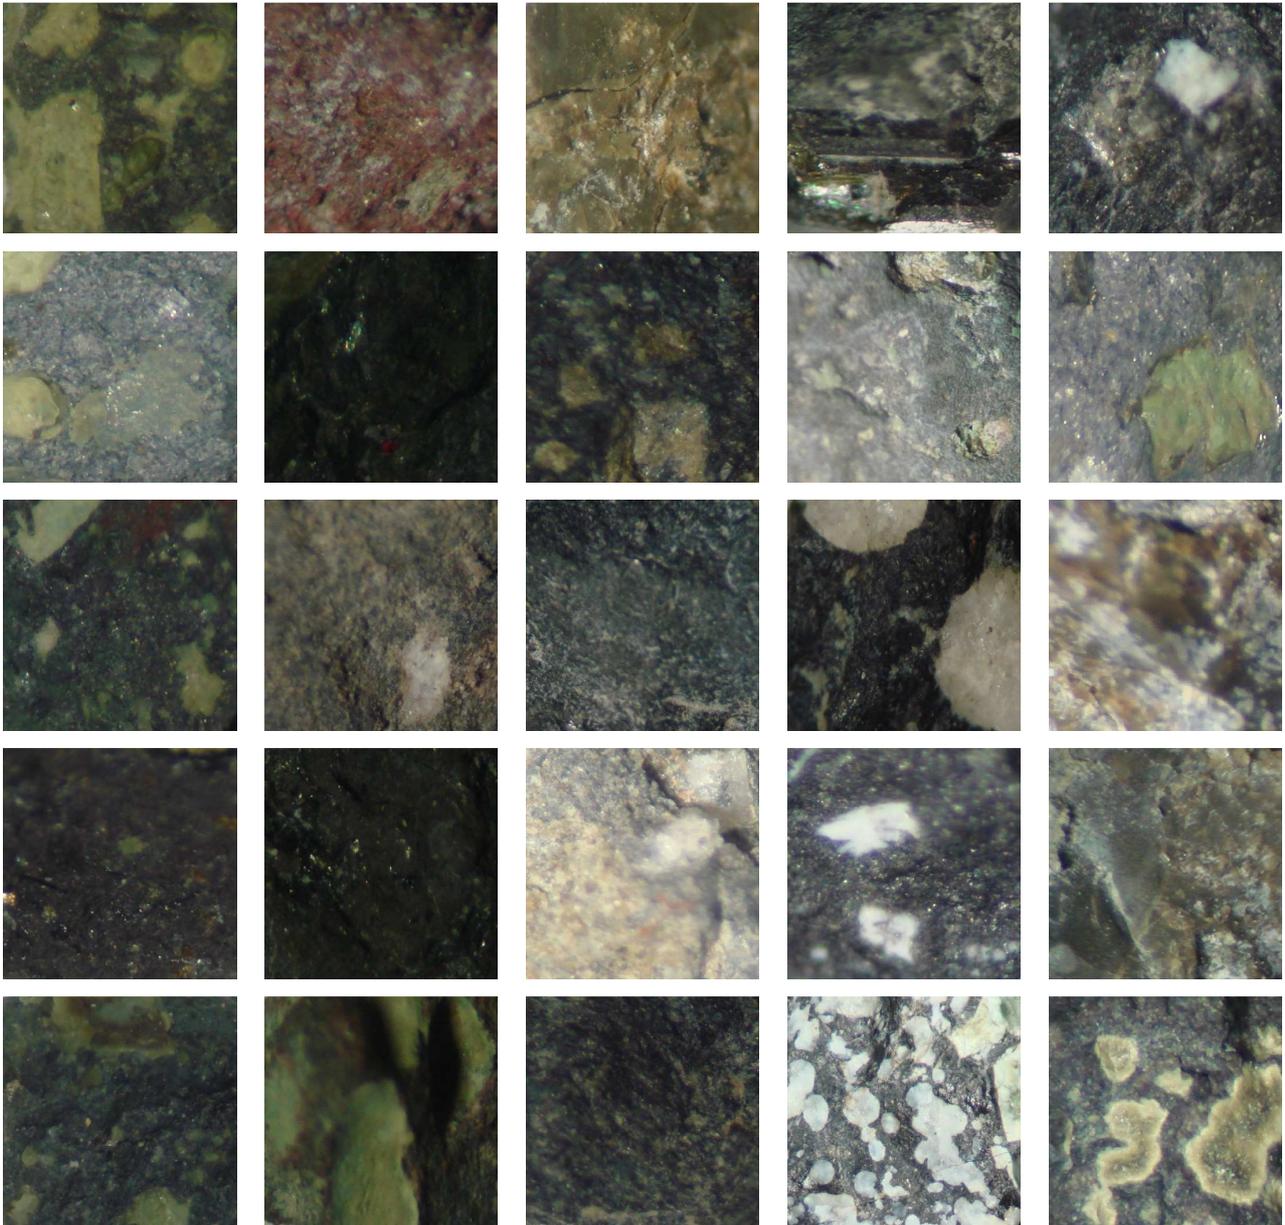
o Diabásio porfírico alterado – Conjunto de Validação



o Diabásio porfirítico amigdaloidal – Conjunto de Treinamento

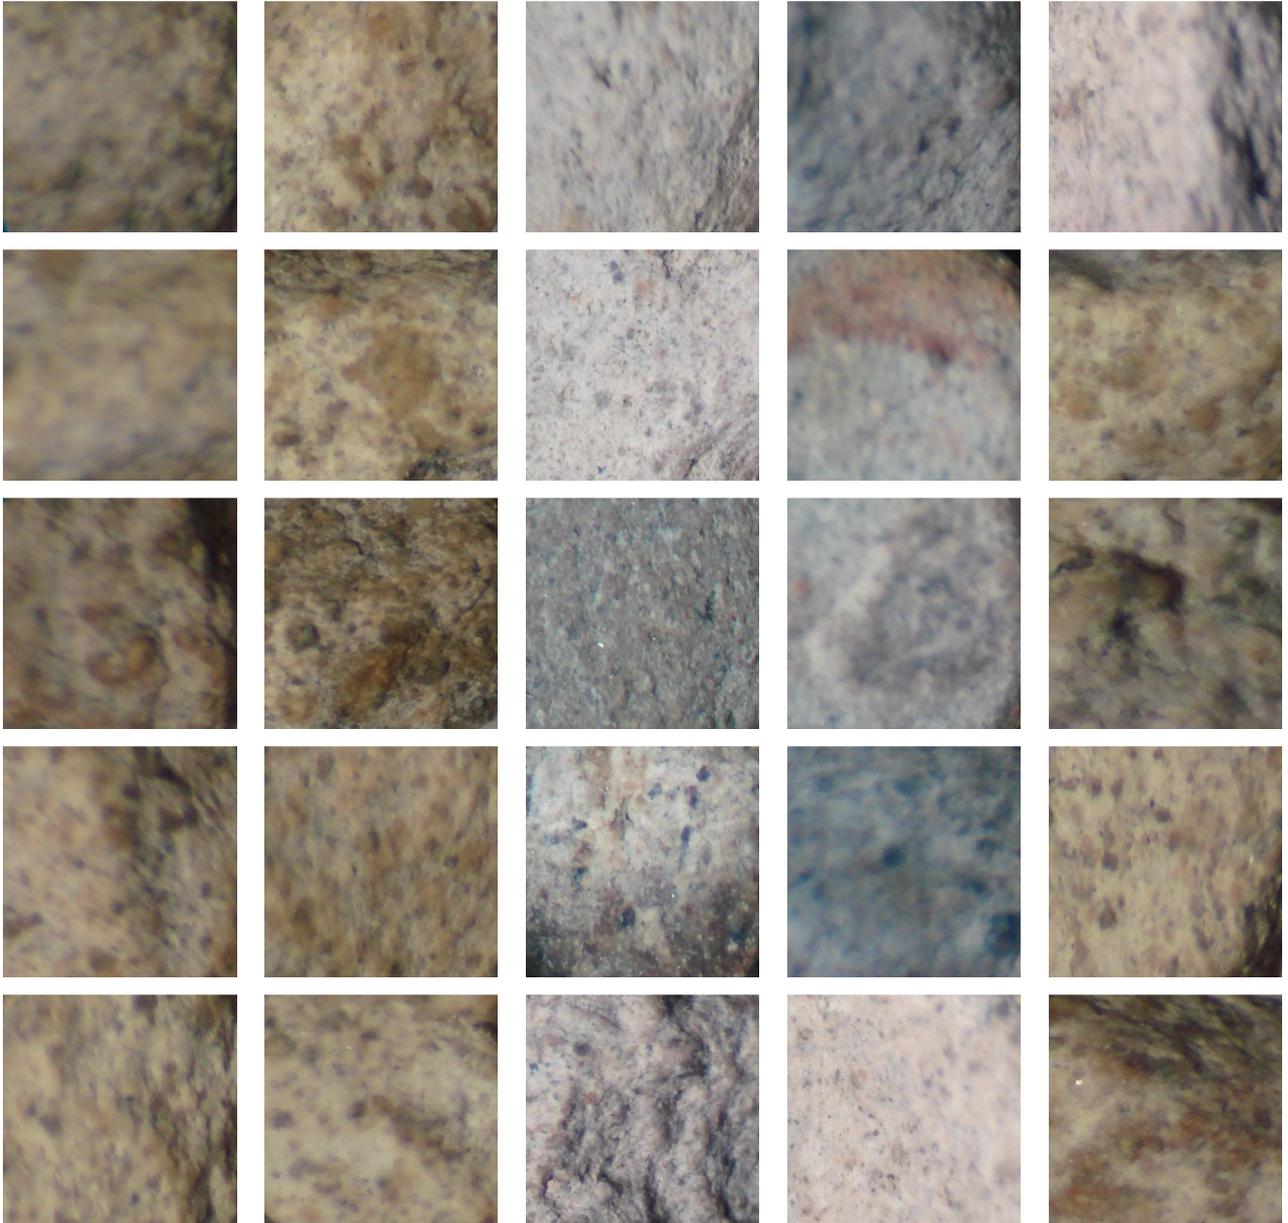


○ Diabásio porfirítico amigdaloidal – Conjunto de Validação



- Riolito

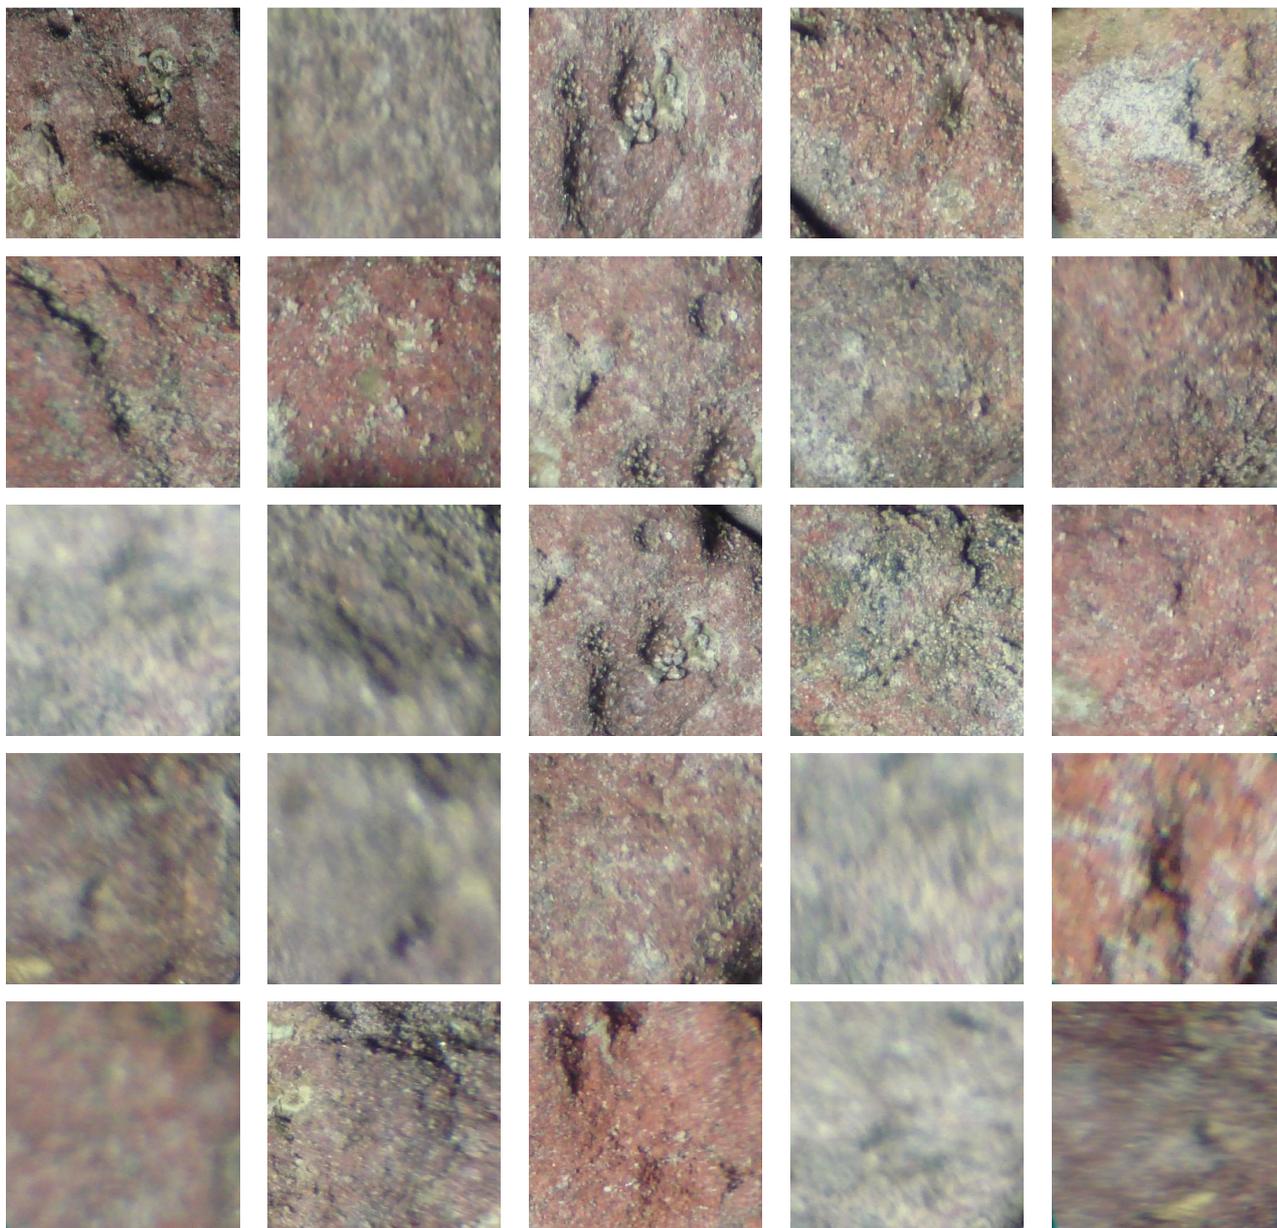
- Riolito alterado – Conjunto de Treinamento



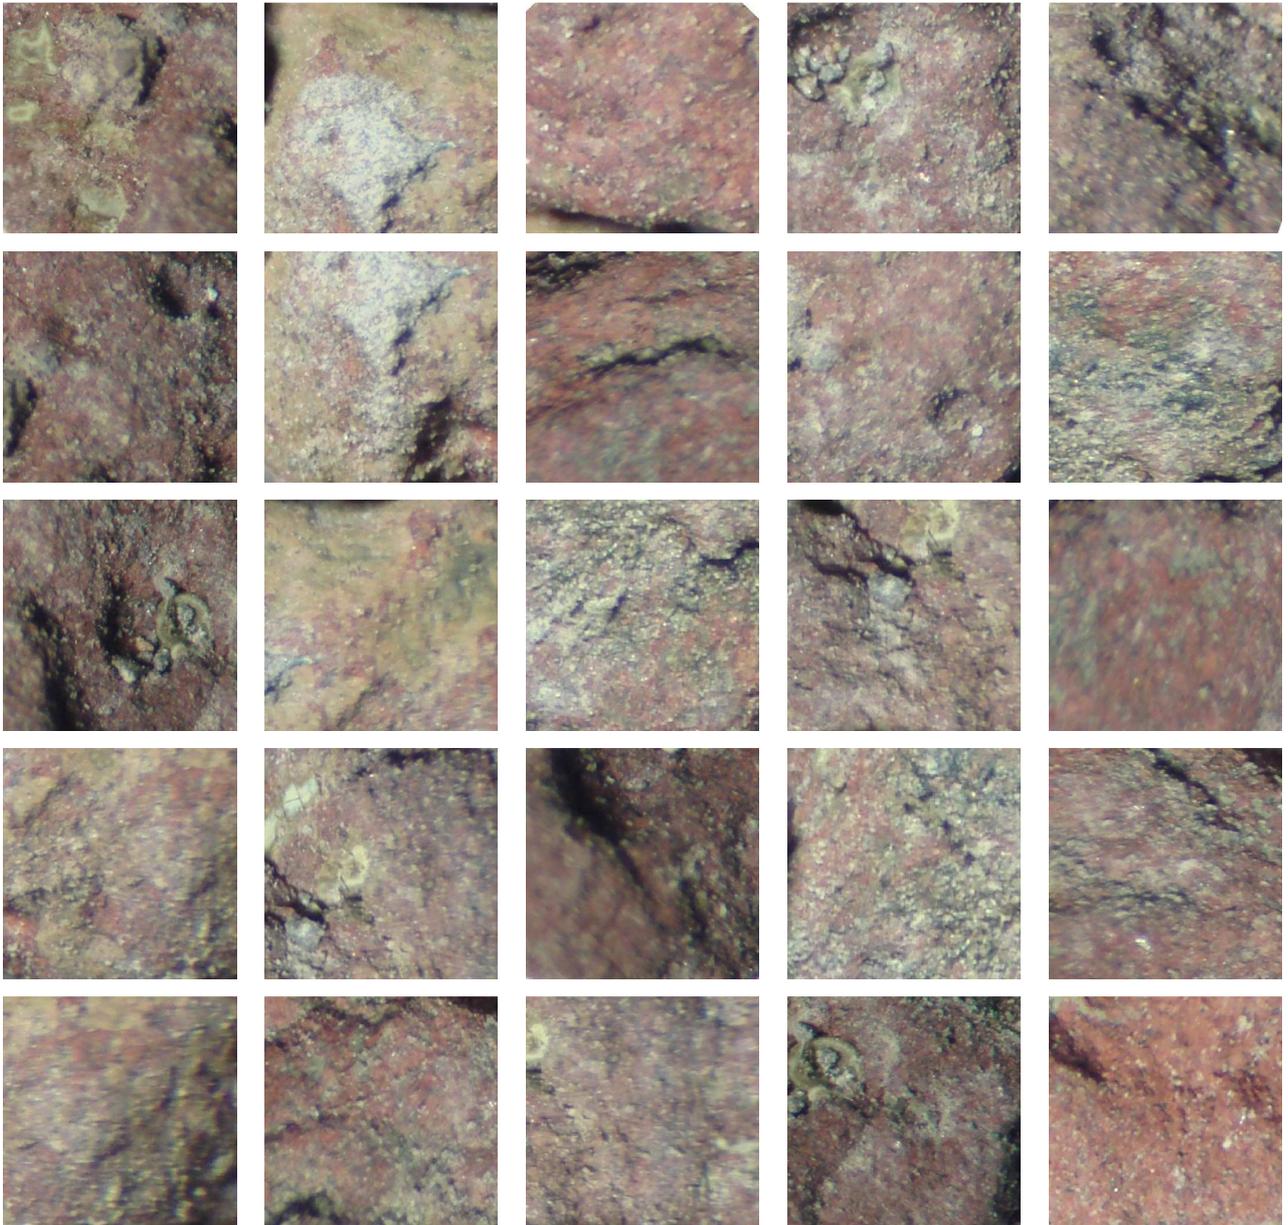
○ Riolito alterado – Conjunto de Validação



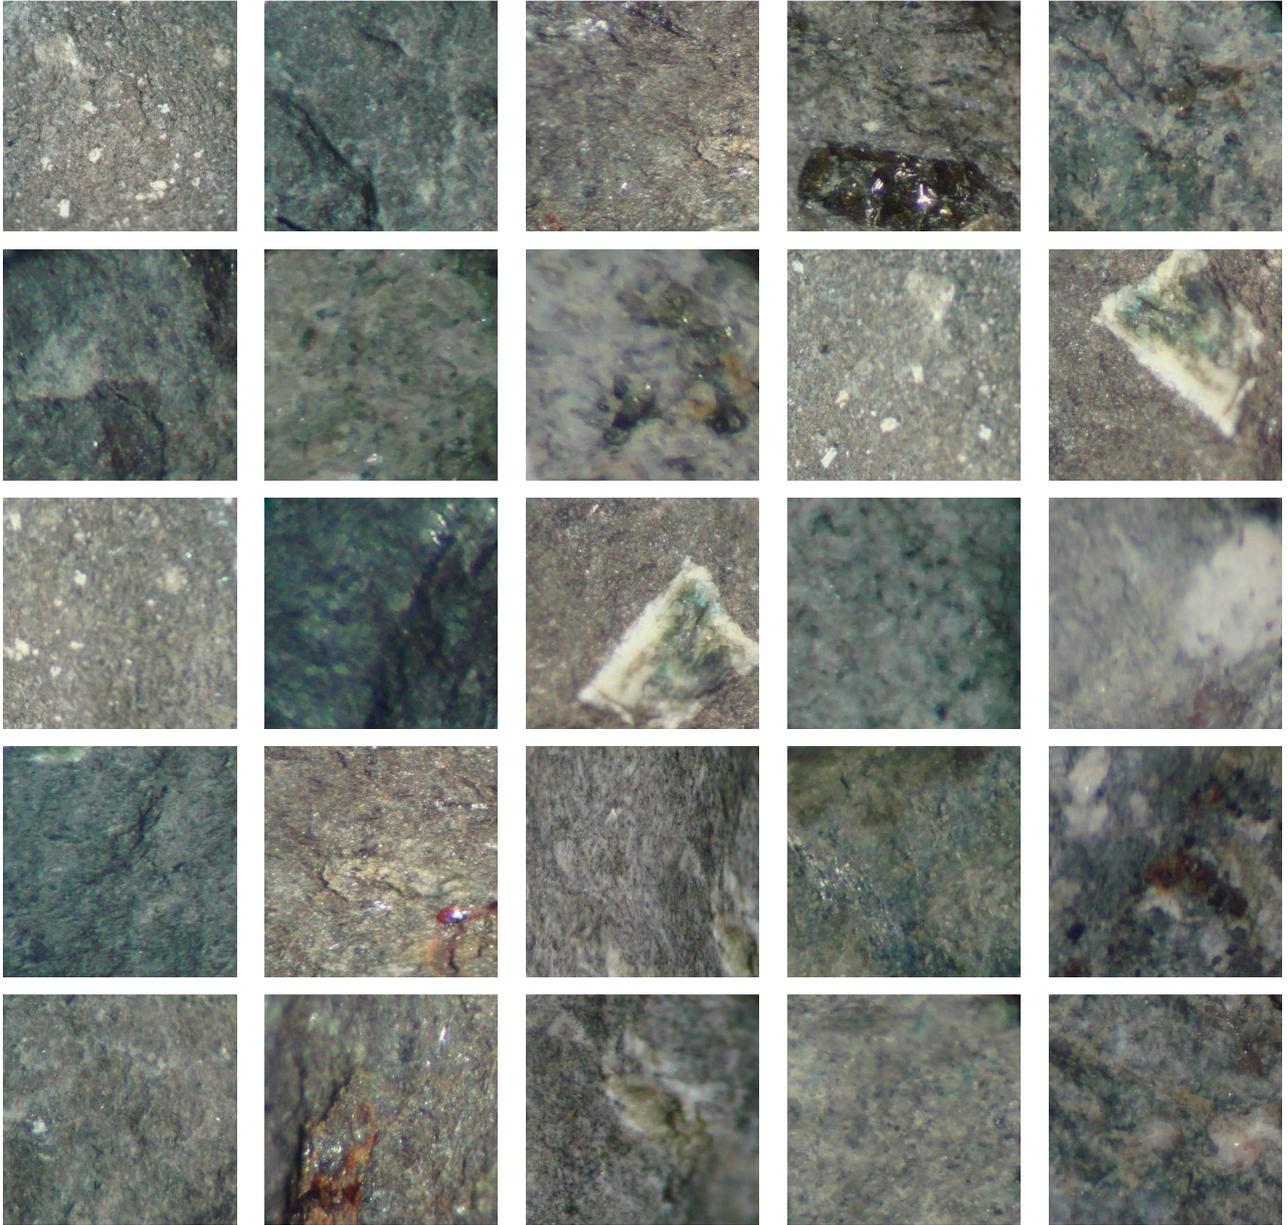
○ Riolito amigdaloidal – Conjunto de Treinamento



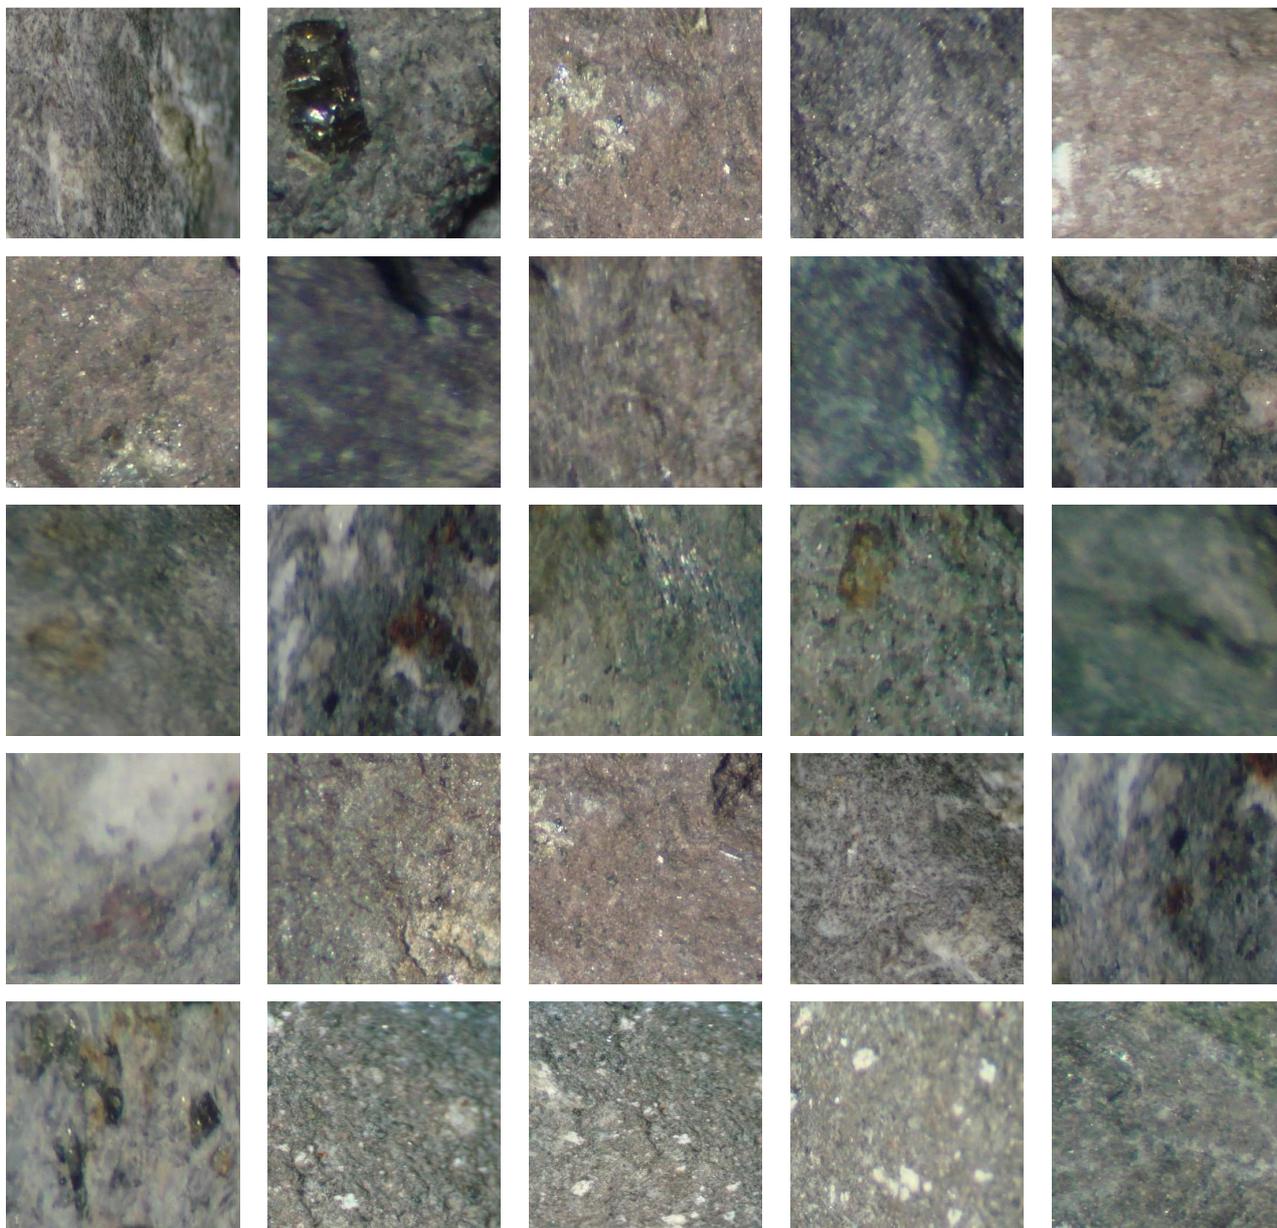
○ Riolito amigdaloidal – Conjunto de Validação



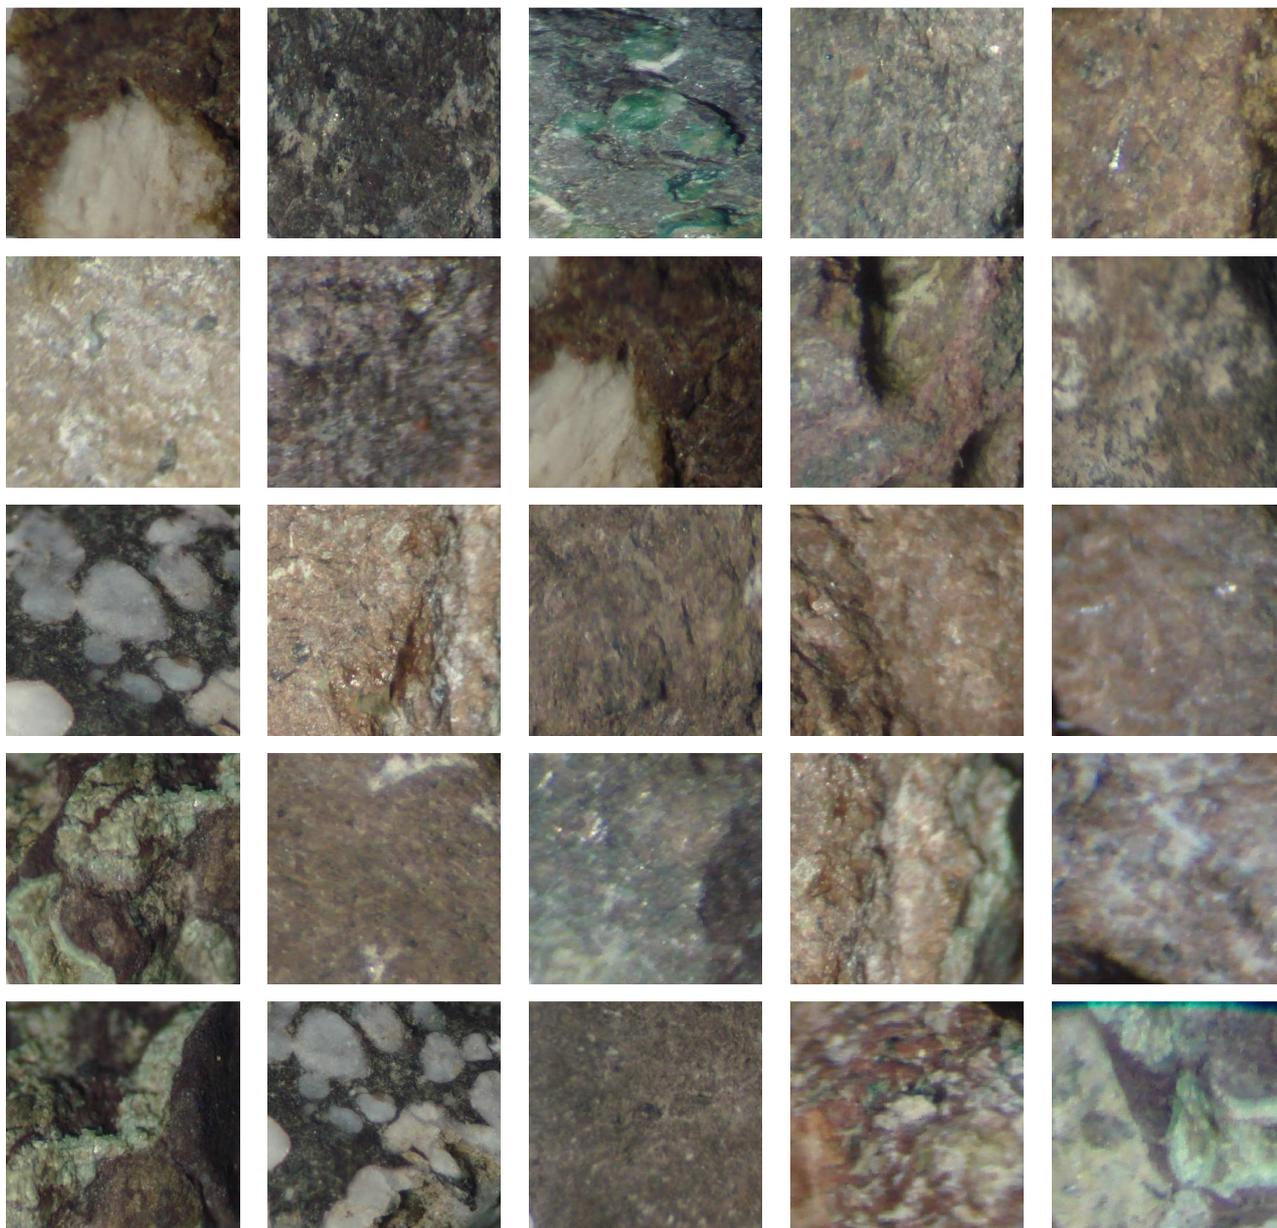
○ Riolito porfirítico – Conjunto de Treinamento



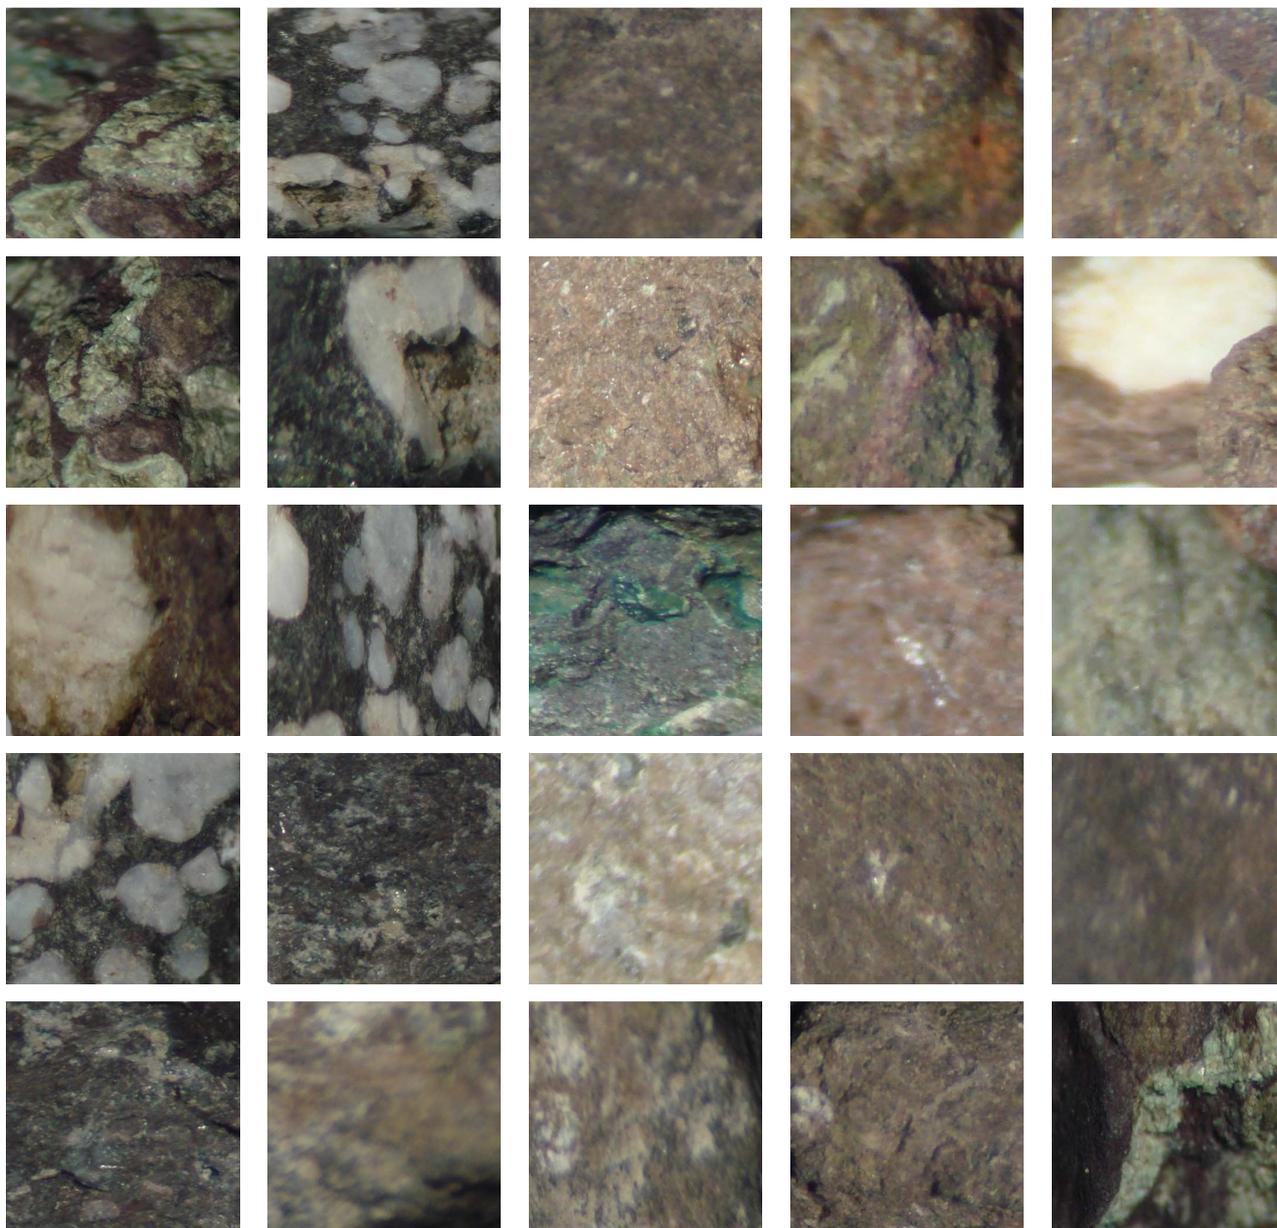
○ Riolito porfirítico – Conjunto de Validação



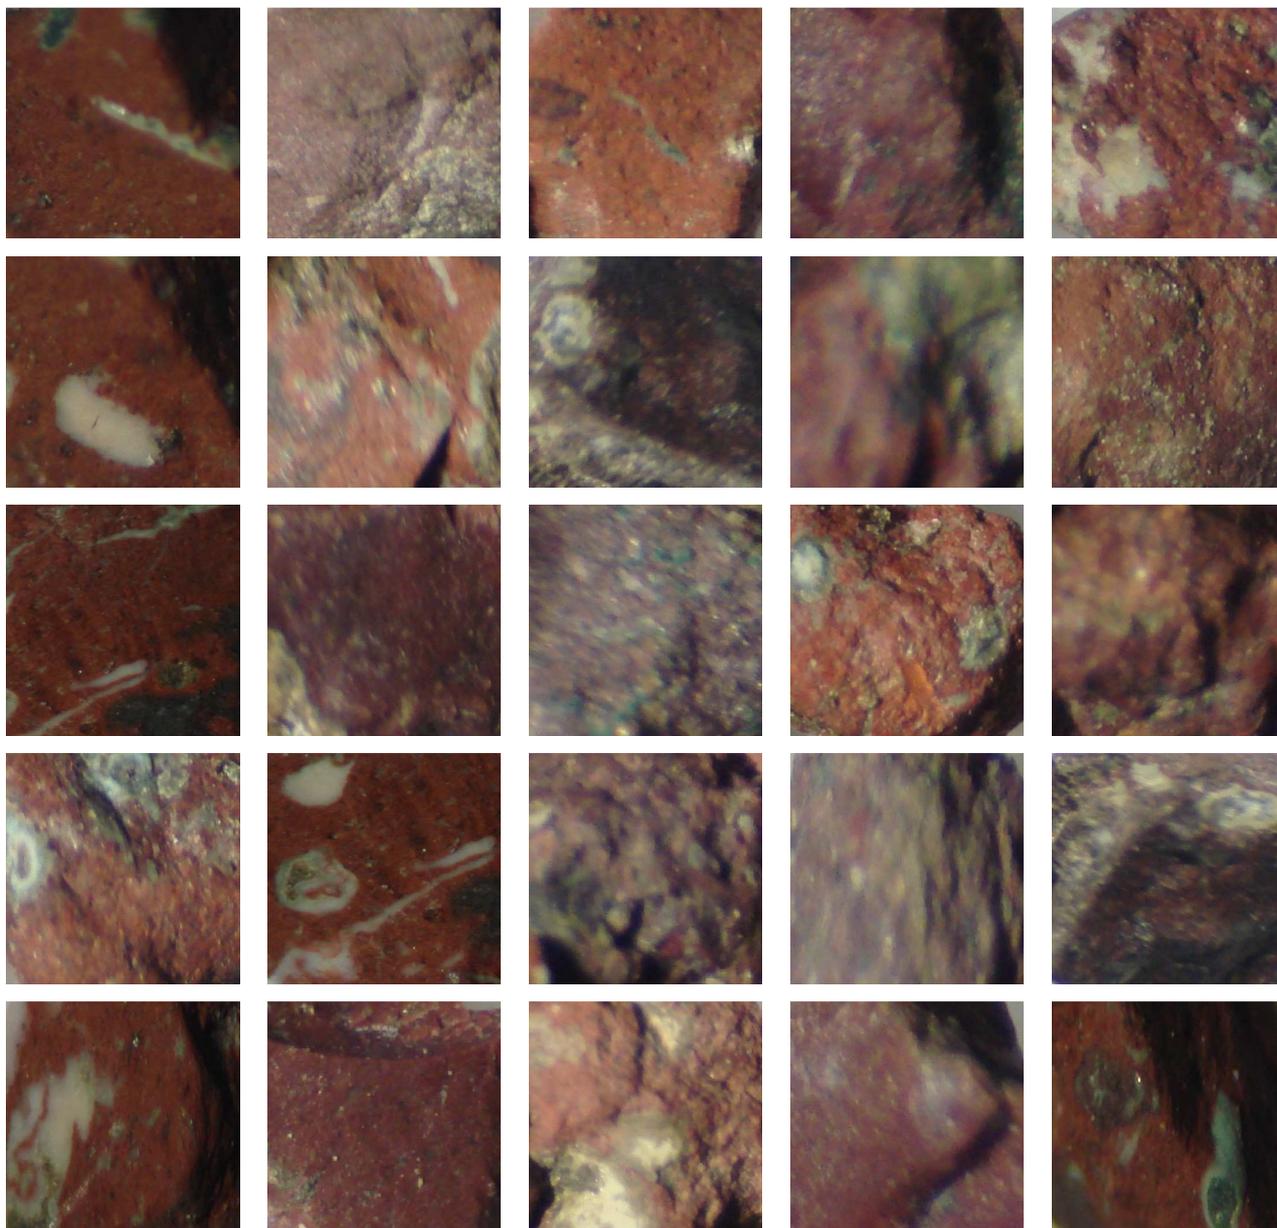
○ Riolito porfirítico amigdaloidal – Conjunto de Treinamento



○ Riolito porfirítico amigdaloidal – Conjunto de Validação



○ Riolito porfirítico amigdaloidal venulado – Conjunto de Treinamento



○ Riolito porfirítico amigdaloidal venulado – Conjunto de Validação

