

Ajalmar Rêgo da Rocha Neto

*SINPATCO - Sistema Inteligente para  
Diagnóstico de Patologias da Coluna Vertebral*

Fortaleza - Ceará

28 de Abril de 2006

Ajalmar Rêgo da Rocha Neto

*SINPATCO - Sistema Inteligente para  
Diagnóstico de Patologias da Coluna Vertebral*

Esta dissertação é apresentada à Pós-Graduação em Engenharia em Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará como requisito parcial para obtenção do grau de Mestre em Engenharia de Teleinformática.

Orientador:

Prof. Paulo César Cortez - Dr

Co-orientador:

Prof. Guilherme de Alencar Barreto - Dr

UNIVERSIDADE FEDERAL DO CEARÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA

Fortaleza - Ceará

28 de Abril de 2006

Dissertação de Mestrado sob o título *SINPATCO - Sistema Inteligente para Diagnóstico de Patologias da Coluna Vertebral*, defendida por Ajalmar Rêgo da Rocha Neto, aluno do Curso de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará e aprovada em 28 de abril de 2006, em Fortaleza, Estado do Ceará, pela banca examinadora constituída pelos doutores:

Prof. Paulo Cesar Cortez - Dr  
Universidade Federal do Ceará

Prof. Guilherme de Alencar Barreto - Dr  
Universidade Federal do Ceará

Prof. Helano de Souza Castro - PhD  
Universidade Federal do Ceará

Prof. Allan Kardec Duailibe Barros Filho -  
Dr  
Universidade Federal do Maranhão

Este trabalho é dedicado à minha mãe, **Angêla Maria Soares de Moura**, pelo exemplo de vida, dedicação aos filhos e por apostar em meu potencial e por ter mostrado à família que podemos vencer os obstáculos da vida, e a **Maria dos Remédios**, pelo apoio e incentivo aos meus estudos.

## *Agradecimentos*

Este momento é especial pois me permite agradecer aos colaboradores deste trabalho. Foram horas de estudo e dedicação e durante todo esse tempo muitas pessoas amigas e outras até então desconhecidas colaboraram para que eu pudesse chegar neste momento. Não poderia deixar de agradecer a estas pessoas e pedir perdão por alguém que eu tenha esquecido de mencionar. Gostaria de agradecer:

- a Deus que me orienta em todos os momentos;
- aos meus pais pela educação, pelos esforços para me oferecer o melhor e pelo amor incondicional;
- aos meus irmãos que sempre me apoiam;
- aos professores Paulo Cortez e Guilherme Barreto por serem essenciais na elaboração deste trabalho;
- ao doutor Henrique da Mota pela grande contribuição e auxílio na construção e correção deste trabalho;
- a Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) por possibilitar que este trabalho fosse realizado;
- aos professores Allan Kardec, Helano Castro e Mario Fialhos pelas sugestões e correções;
- aos demais professores da UFC, secretárias da pós-graduação e a todos os funcionários do departamento pela amizade e colaboração durante o decorrer do mestrado;
- a todos que de alguma forma contribuíram para a realização deste trabalho.

## *Resumo*

Esta dissertação apresenta os resultados de um sistema de auxílio ao diagnóstico médico implementado através de classificadores estatísticos e neurais. O Sistema Inteligente para Diagnóstico de Patologias da Coluna Vertebral (SINPATCO) é composto por três subsistemas, a saber: interface gráfica, classificação de patologias e extração de conhecimento. O módulo de interface gráfica permite uma interação amigável com o especialista médico. O módulo de classificação automática de patologias é implementado por diferentes algoritmos, tais como discriminantes linear e quadrático, *Naive Bayes*, K-Vizinhos mais Próximos (KNN), rede MLP, rede SOM e rede GRNN. O módulo de extração de conhecimento é responsável pela extração de regras proposicionais a partir dos classificadores treinados, a fim de elucidar para o médico ortopedista como o classificador chega ao diagnóstico final.

Em particular, o módulo de classificação de patologias da plataforma SINPATCO utiliza atributos biomecânicos recentemente propostos para efetuar a categorização de um paciente em três classes: pacientes normais, pacientes com espondilolistese e pacientes com hérnia de disco. Os diversos classificadores supracitados são comparados com relação à taxa de acerto, número de falsos positivos, número de falsos negativos e sensibilidade a amostras discrepantes (*outliers*).

As contribuições deste trabalho são variadas, indo desde do fato de ser provavelmente o primeiro a usar um conjunto recente de atributos biomecânicos para projeto de classificadores na área de medicina ortopédica, passando pelo estudo comparativo do desempenho de vários classificadores, até a extração de regras a partir dos classificadores com melhor desempenho para explicar o diagnóstico obtido ao médico, para posterior avaliação. Até onde se tem conhecimento, a combinação destas três contribuições torna o sistema SINPATCO inovador na área de ortopedia médica, servindo de auxílio na atividade de diagnóstico e facilitando o trabalho dos profissionais dessa área.

Além servir como ferramenta de auxílio ao diagnóstico do médico especializado em ortopedia, o sistema SINPATCO pode ser usado por clínicos não-especialistas em ortopedia, a fim de minimizar a carência de ortopedistas em regiões remotas, agilizando o atendimento e o encaminhamento do paciente para centros mais desenvolvidos.

# Abstract

*This dissertation presents the results obtained from a computer-aided medical diagnostic system implemented through statistical and neural pattern classifiers. The Intelligent System for Diagnosis of Pathologies of the Vertebral Column (SINPATCO) has a modular architecture and is composed of three subsystems, namely: graphical interface, classification of pathology, and knowledge extraction. The graphical interface module allows a friendly man-machine interaction with the physician. The pathology classification module is implemented through different algorithms, such as linear and quadratic discriminants, Naive Bayes classifier, K Nearest Neighbors (KNN) classifier, Multilayer Perceptron (MLP) network, Self-Organizing Map (SOM) network, and Generalized Regression network (GRNN). The knowledge extraction module is responsible for rule extraction from trained neural network based classifiers, in order to elucidate the neural-based diagnostic to the orthopedist.*

*In particular, the pathology classification module of the SINPATCO platform uses recently proposed biomechanical attributes to categorize a patient into one out of three classes: normal subjects, subjects with spondilolistesis, and subjects with disk hernia. All the aforementioned classifiers are evaluated with respect their pathology recognition rate, number of false positive cases, number of false negative cases and sensitivity to outliers.*

*The contribution of this work is manifold. Starting from the fact that it is probably the first to use (within the orthopaedic medicine) a recently proposed set of biomechanical measurements for the design of classifiers, this work also evaluates several pattern classifiers in the diagnosis of pathologies of the vertebral column, and allows knowledge extraction from the trained classifiers in order to elucidate the obtained diagnostic to the physician. To the best of our knowledge, the combination of these three contributions makes the SINPATCO platform an innovative computer-aid tool for the orthopedist, facilitating the work of these professionals.*

*Despite the fact that the SINPATCO platform can serve as a computer-aided diagnostic tool in the orthopedic medicine, it can also be used by non-expert clinicians, in order to minimize the lack of orthopedists in remote regions, speeding up the treatment and the transferring of patients to more developed centers.*

# *Sumário*

<b>Lista de Figuras</b>	<b>x</b>
<b>Lista de Tabelas</b>	<b>xi</b>
<b>Lista de Abreviaturas e Siglas</b>	<b>xii</b>
<b>Lista de Símbolos</b>	<b>xiv</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Motivações da Dissertação . . . . .	2
1.2 Objetivo Geral da Dissertação . . . . .	5
1.3 Objetivos Específicos . . . . .	5
1.4 Hipóteses de Trabalho . . . . .	6
1.5 Organização da Dissertação . . . . .	6
1.6 Produção Científica . . . . .	7
<b>2 Coluna Vertebral e Patologias: uma Descrição Fisiológica</b>	<b>9</b>
2.1 A Coluna Vertebral . . . . .	9
2.1.1 Vértébras . . . . .	11
2.1.2 Discos Intervertebrais . . . . .	12
2.1.2.1 Compressão dos Discos Intervertebrais . . . . .	15
2.1.2.2 Hidratação dos Discos Intervertebrais . . . . .	16
2.1.3 Articulações . . . . .	16
2.1.4 As Facetas . . . . .	18



---

2.1.5	Ligamentos . . . . .	18
2.2	Hérnia de Disco . . . . .	19
2.2.1	Causas da hérnia de Disco . . . . .	21
2.2.2	Diagnóstico da Hérnia de disco . . . . .	21
2.3	Espondilolistese . . . . .	22
2.3.1	Causas da espondilolistese . . . . .	23
2.3.2	Diagnóstico da espondilolistese . . . . .	23
2.4	Seleção de Características . . . . .	24
2.5	Extração de Características . . . . .	28
2.6	Conclusão . . . . .	28
<b>3</b>	<b>Reconhecimento de Padrões</b>	<b>29</b>
3.1	Conceitos Gerais . . . . .	29
3.2	Classificadores de Padrões . . . . .	32
3.2.1	Projeto de classificadores . . . . .	33
3.3	Classificadores Baseados em Estatística . . . . .	34
3.3.1	Discriminantes . . . . .	34
3.3.1.1	Discriminante Linear . . . . .	35
3.3.1.2	Discriminate Quadrático . . . . .	37
3.3.1.3	Regularização . . . . .	38
3.3.2	Classificador <i>Naive Bayes</i> . . . . .	39
3.3.3	Classificador <i>k</i> - Vizinhos mais Próximos . . . . .	40
3.4	Classificadores Baseados em Redes Neurais . . . . .	41
3.4.1	Rede Perceptron Multicamadas . . . . .	41
3.4.1.1	Treinamento da rede MLP . . . . .	42
3.4.1.2	Utilização da rede MLP em classificação de padrões . . . . .	45
3.4.2	Classificador Baseado na Rede Auto-Organizável de Kohonen . . . . .	46

---

3.4.2.1	Rede SOM em classificação de padrões . . . . .	49
3.4.3	Rede Neural Genérica para Regressão . . . . .	51
3.4.3.1	Sobre o Problema de Regressão Estatística . . . . .	51
3.4.3.2	Arquitetura da rede GRNN . . . . .	54
3.5	Conclusão . . . . .	55
<b>4</b>	<b>Extração e Representação do Conhecimento Embutido em Redes Neu- rais Artificiais Treinadas</b>	<b>56</b>
4.1	Taxonomia das Técnicas de Extração de Conhecimento de Redes Neurais Artificiais . . . . .	58
4.1.1	O poder de expressão . . . . .	58
4.1.2	A qualidade das regras . . . . .	59
4.1.3	A granularidade/translucência das regras . . . . .	59
4.1.4	A complexidade algorítmica . . . . .	60
4.1.5	A portabilidade . . . . .	60
4.2	Algoritmos para Extração de Regras . . . . .	61
4.2.1	Extração de Regras do Perceptron Multicamadas - Pedagógica . . .	61
4.2.2	Extração de Regras do Perceptron Multicamadas - Decomposicional	62
4.2.2.1	O algoritmo básico . . . . .	62
4.2.2.2	Extensão do Algoritmo para Domínios Contínuos . . . . .	66
4.2.3	Extração de Regras da Rede SOM - Decomposicional . . . . .	69
4.3	Simplificação de Regras . . . . .	70
4.4	Fidelidade <i>versus</i> Exatidão das Regras . . . . .	71
4.5	Conclusão . . . . .	73
<b>5</b>	<b>SINPATCO e Resultados</b>	<b>75</b>
5.1	Metodologia . . . . .	77
5.2	Resultados de Classificação . . . . .	79

---

5.3	Resultados de Extração de Regras . . . . .	87
<b>6</b>	<b>Conclusões e Trabalhos Futuros</b>	<b>90</b>
6.1	Conclusão . . . . .	90
6.2	Trabalhos Futuros . . . . .	91
	<b>Referências</b>	<b>93</b>
	<b>Apêndice A - Base de Dados</b>	<b>98</b>

## *Lista de Figuras*

2.1	segmentos da coluna vertebral. . . . .	10
2.2	estrutura de uma vértebra típica. . . . .	11
2.3	visão superior de um segmento lombar. . . . .	13
2.4	coluna vertebral, com rotulação das vértebras. . . . .	14
2.5	indivíduo com hérnia de disco. . . . .	20
2.6	indivíduo com espondilolistese. . . . .	22
2.7	indivíduo saudável. . . . .	23
2.8	ângulo de incidência pélvica. . . . .	25
2.9	ângulo de versão pélvica. . . . .	26
2.10	declive sacral. . . . .	27
3.1	modelo para o reconhecimento (semi-)automático de padrões. . . . .	31
3.2	classificador de correlação-máxima. . . . .	35
3.3	arquitetura geral de uma rede neural supervisionada. . . . .	42
3.4	projeção implementada pela rede SOM. . . . .	48
3.5	arquitetura geral da GRNN. . . . .	54
4.1	aproximação da disjunção (OU) pela rede neural. . . . .	64
4.2	rede neural modelada para resolver o problema OU EXCLUSIVO. . . . .	64
4.3	proporção direta e reversa. . . . .	67
4.4	norma qualitativa. . . . .	67
5.1	interface gráfica do SINPATCO. . . . .	76
5.2	acerto médio no teste para os classificadores. . . . .	87

## *Lista de Tabelas*

4.1	operadores da algebra booleana. . . . .	68
4.2	tabela de compromisso da precisão <i>versus</i> exatidão. . . . .	71
5.1	número de amostras do conjunto $S$ por percentagem. . . . .	78
5.2	explanação da matriz de confusão. . . . .	79
5.3	resultado geral da rede MLP. . . . .	80
5.4	matriz de confusão da rede MLP. . . . .	81
5.5	resultado geral do $k$ -NN. . . . .	81
5.6	matriz de confusão do $k$ -NN. . . . .	82
5.7	resultado geral do <i>Naive Bayes</i> . . . . .	82
5.8	matriz de confusão do Naive Bayes. . . . .	82
5.9	resulado geral da rede SOM. . . . .	83
5.10	matriz de confusão da rede SOM. . . . .	83
5.11	resultado geral do GRNN. . . . .	84
5.12	matriz de confusão da rede GRNN. . . . .	84
5.13	resultado geral Discriminante Linear (covariância <i>pooled</i> ). . . . .	85
5.14	resultado geral Discriminante Quadrático (covariância por classe). . . . .	85
5.15	resultado geral comparativo entre classificadores. . . . .	86
5.16	variância de acerto médio no teste. . . . .	86
5.17	relação falso positivo/negativo <i>versus</i> classificador. . . . .	86
5.18	resultado regras rede SOM. . . . .	88

## *Lista de Abreviaturas e Siglas*

API	<i>Application Program Interface</i>
GRNN	<i>General Regression Neural Network</i>
DETI	Departamento de Engenharia em Teleinformática
EEG	Eletroencefalograma
GARO	<i>Group of Applied Research in Orthopaedics</i>
HRL	<i>Horizontal Reference Line</i>
HTML	<i>Hipertext Markup Language</i>
IA	Inteligência Artificial
IC	Inteligência Computacional
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Square Error</i>
LVQ	<i>Learning Vector Quantization</i>
KNN	<i>K-Nearest Neighbors</i>
RBF	<i>Radial Basic-Functions.</i>
RNA	Redes Neurais Artificiais.
PDF	<i>Probability Density Function</i>
PI	<i>Pelvic Incidence</i>
PT	<i>Pelvic Tilt</i>
RP	Reconhecimento de Padrões
SOM	<i>Self-Organizing Map</i>

<b>SS</b>	<i>Sacral Slope</i>
<b>TAC</b>	Tomografia Axial Computadorizada
<b>UFC</b>	Universidade Federal do Ceará
<b>VRL</b>	<i>Vertical Reference Line</i>
<b>WTA</b>	<i>Winner Take All</i>

## *Lista de Símbolos*

$\tilde{C}_i$	Matriz de Covariância
<b>dim</b>	Dimensão ou Tamanho de um Espaço
<b>E</b>	Estimativa
<b>e</b>	Erro
<b>h</b>	Função de Vizinhança
$i^*$	Índice do Neurônio Vencedor
<b>x</b>	Padrão ou Vetor Característico
<b>max</b>	Função Máximo
<b>min</b>	Função Mínimo
<b>N</b>	Número de Amostras
$\mathfrak{R}$	Números Reais
<b>W</b>	Classe ou Agrupamento
<b>w</b>	Peso dos Neurônios
<b>y</b>	Saída do Neurônio
$\varpi$	Função de Ativação
$\delta$	Gradiente
$\mu$	Centro de Massa
$\eta$	Função Decaimento Exponencial Aprendizagem
$\nu$	Função Decaimento Exponencial Vizinhança
$\varpi$	Função de Ativação



$\sigma$	Desvio Padrão
$\sigma^2$	Variância
$\Phi$	Projeção Não-linear

# 1 *Introdução*

A razão de ser da Inteligência Artificial (IA) como modelos computacionais do funcionamento da mente e do raciocínio humano está na simulação pelo computador de decisões e ações inteligentes que até recentemente só poderiam ser executadas por seres humanos, como fala, movimento, reconhecimento de rostos, entre outras habilidades. Os primeiros produtos bem-sucedidos da IA, na figura dos sistemas especialistas, contribuem de forma decisiva para a disseminação de aplicações de IA na prática, em diversos ramos da ciência e do conhecimento. Hoje, o uso da Inteligência Artificial está presente, de variadas formas, em nossas vidas. Por exemplo, seu uso pode ser voltado para auxílio na tomada de decisão médica, diagnóstico de doenças, controle de tráfego aéreo, controle de robôs, jogos de computadores, controle de temperatura em geladeiras e ar-condicionados, reconhecimento de padrões, para citar apenas algumas poucas aplicações.

Em paralelo ao crescimento da IA clássica veio o desenvolvimento de outras ferramentas computacionais, tais como Redes Neurais Artificiais, Lógica Fuzzy e Algoritmos Genéticos, ampliando as possibilidades de algoritmos para implementação de sistemas inteligentes. Estas técnicas constituem a área de Inteligência Computacional (IC), que difere da IA clássica por apresentarem inerentemente mecanismos de computação numérica, paralela-distribuída e não-linear, enquanto as técnicas de IA são fortemente baseadas em processamento simbólico, seqüencial e linear da informação. Apesar da flexibilidade e do poder computacional oriundo da computação paralela e distribuída, algoritmos de IC, em geral, não se prestam a uma interpretação intuitiva de seus resultados por parte do usuário. Já algoritmos de IA, por serem baseados em regras lógicas clássicas e procedimentos heurísticos (intuitivos), normalmente expõem o conhecimento utilizado e a solução do problema de forma clara.

Outras técnicas numéricas que merecem destaque nesta dissertação pertencem à teoria de discriminantes estatísticos. Estatística Clássica. Tais algoritmos estatísticos baseiam-se em considerações feitas sobre as distribuições de probabilidade dos dados, de forma a estabelecer fronteiras de decisões entre as várias classes às quais os dados pertencem.

As fronteiras de decisão podem ser lineares ou não, dando origem a diversos algoritmos de classificação de padrões, tais como os hoje clássicos discriminante linear de Fisher, discriminante quadrático, Naive Bayes e K-Vizinhos-Mais-Próximos (KNN). As principais vantagens destas técnicas está no seu forte embasamento matemático, sendo por isso bastante utilizadas em tarefas de classificação de padrões.

## 1.1 Motivações da Dissertação

Aplicações de técnicas de Inteligência Artificial, Inteligência Computacional e Discriminantes Estatísticos na área médica e biológica têm aumentado bastante nos últimos anos, com destaque importante àquelas que empregam Redes Neurais Artificiais (RNA). Este destaque pode se justificar por algumas características que redes neurais possuem, tais como resolver problemas de classificação de padrões e aproximação de funções não-lineares e de elevada dimensionalidade, construir diretamente a fronteira de decisão a partir de um conjunto de dados e fazer poucas ou nenhuma suposição a cerca da distribuição de probabilidades dos dados. Uma outra explicação, pode residir na capacidade de diagnóstico humano, que é significativamente pior que a dos sistemas de diagnóstico neural sob condições adversas, tais como estresse, fadiga e pouco conhecimento técnico (BRAUSE, 1999).

Alguns trabalhos de revisão do estado da arte sobre aplicações de redes neurais em medicina são apresentados por REGGIA (1993), PAPIK et al. (1998) e RAMESH et al. (2004). No estudo de PAPIK et al. (1998) são descritas várias aplicações de RNAs, as quais se distribuem em vários campos: cardiologia, análise de ECGs, gastroenterologia, pulmonologia, oncologia, neurologia, análise de EEGs, otorrinolaringorologia, ginecologia e obstetrícia, oftalmologia, radiologia, patologia, citologia, genética, bioquímica dentre outras. Em um outro estudo, relacionado à utilização de RNAs nas áreas médica e biológica, mostra-se a distribuição de um número significativo de artigos (mais de 800) produzidos nos anos de 2000 e 2001 em mais de 40 países (ROBERT et al., 2004).

Além dos trabalhos descritos anteriormente, pesquisas recentes na literatura mostram a utilização de RNAs na recuperação de imagens da coluna vertebral com base em conteúdo (ANTANI et al., 2003), na classificação de modalidades de imagens médicas (FLOREA et al., 2004) e na classificação de indivíduos em normais ou anormais para a patologia osteófito (CHERUKURI et al., 2004). Encontra-se ainda um estudo que mostra a utilização de redes neurais para o diagnóstico de anemias, thalassemias e leucemias. Em conjunto,

neste estudo, verifica-se uma revolução em termos de diagnóstico de câncer, especialmente em hematologia, pois há uma introdução da primeira abordagem baseada em *microarray* (técnica para análise de genes com base em bioinformática) para o diagnóstico molecular (ZINI, 2005).

De uma forma mais específica, verifica-se na literatura que na área ortopédica existem poucos trabalhos aplicados ao problema de diagnóstico de patologias, seja envolvendo classificadores baseados em redes neurais artificiais, seja envolvendo classificadores estatísticos convencionais. A justificativa para este fato pode residir na inexistência de um conjunto específico de medidas quantitativas que permitam formalizar o problema de diagnóstico de patologias como um problema de classificação de padrões.

Recentemente, um grupo de especialistas em ortopedia e biomecânica consegue estabelecer um conjunto de atributos biomecânicos relacionados a dores e deformidades da coluna vertebral (LABELLE; ROUSSOULY; BERTHONNAUD, 2005; FIÉRE; DA MOTA, 2001; BERTHONNAUD et al., 2001). Em seguida, este grupo realiza medidas dos atributos recém-definidos em vários paciente, formando assim um banco de dados com casos clínicos relevantes para o estudo. Este banco de casos clínicos é então utilizado nesta dissertação para projetar classificadores de padrões para patologias da coluna vertebral, tais como hérnia de disco e espondilolistese. É importante enfatizar que esta é a primeira utilização destes atributos para este fim que se tem conhecimento, sendo por isto uma das principais contribuições deste trabalho.

Outros trabalhos encontrados na literatura que têm relevância para esta dissertação utilizam redes neurais para realizar inferências e para fazer prognóstico em ortopedia, relacionados a ferimentos na medula espinhal (OHNO-MACHADO; ROWLAND, 1999), para predição de reabilitação e uso de recursos hospitalares que são aplicados a um conjunto de pacientes ortopédicos (GRIGSBY; KOOKEN; HERSHBERGER, 1994). Uma revisão geral dos trabalhos que aplicam redes neurais na área de biomecânica clínica é realizado por SCHOLLHORN (2004).

Uma importante constatação, feita no trabalho de DREISEITL e BINDER (2005), demonstra a confiança aplicada pelos médicos nos sistemas computacionais de apoio à tomada decisão. Neste trabalho há uma investigação sobre a reação de médicos quando os sistemas de suporte à decisão contradizem o seu diagnóstico. Verifica-se que os especialistas são bastante suscetíveis a aceitar as recomendações destes tipos de sistemas. Em consequência deste estudo, os autores do artigo concluem que a razão desta confiança pode estar na garantia de qualidade e a validação de tais sistemas pela comunidade médica.

Vale resaltar que além de redes neurais outras técnicas de IC, tais como algoritmos genéticos e lógica fuzzy, têm contribuído para a área de classificação e diagnóstico médico (TSAKONAS et al., 2003; STEIMANN, 2001; KUNCHEVA; STEIMANN, 1999). Este crescente interesse tem também possibilitado a sinergia destas técnicas através da exploração em conjunto de seus pontos positivos, dando margem ao surgimento de sistemas híbridos que mesclam técnicas de IA clássica e IC. Este tipo de sistema surge da tentativa de unir os pontos fortes de cada técnica de acordo com a necessidade do problema sendo tratado.

Em sistemas que auxiliam no diagnóstico médico, as informações fornecidas pela rede neural em sua essência não costumam apresentar explicação alguma sobre como se chega a determinado resultado, comportamento muitas vezes referido como *caixa-preta*. Contudo, médicos usuários de sistemas de apoio a decisão requerem com frequência uma explanação de como determinado resultado é obtido. Para este fim, diversas técnicas de extração de regras a partir de redes neurais treinadas têm sido propostas para elucidar o conhecimento embutido em seus pesos e esclarecer a inferência realizada pelas redes neurais (CASTRO; MANTAS; BENITEZ, 2002; TSUKIMOTO, 2000; ZHOU; CHEN; CHEN, 2000; SETIONO, 1997). Nesta dissertação, algumas destas técnicas serão discutidas oportunamente e utilizadas para extrair regras de inferência para o diagnóstico de patologias obtido a partir de classificadores neurais treinados.

Conforme mencionado anteriormente, não foram encontrados na literatura trabalhos envolvendo classificadores de padrões para patologias da coluna vertebral, tais como hérnia de disco e espondilolistese. Desta forma, com base em um conjunto de atributos biomecânicos esta dissertação pretende fazer uma ampla análise comparativa do desempenho de vários classificadores de padrões, estatísticos ou neurais, a fim de avaliar a plausibilidade desses atributos como grandezas capazes de discriminar patologias da coluna.

Do exposto em parágrafos anteriores, esta dissertação se propõe a apresentar um sistema de auxílio ao diagnóstico médico implementado através de classificadores estatísticos e neurais. O Sistema Inteligente para Diagnóstico de Patologias da Coluna Vertebral (SINPATCO) é composto por três subsistemas, a saber: interface gráfica, classificação de patologias e extração de conhecimento. O módulo de interface gráfica permite uma interação amigável com o especialista médico. O módulo de classificação automática de patologias é implementado por diferentes algoritmos, tais como discriminantes linear e quadrático, *Naive Bayes*, K-Vizinhos mais Próximos (KNN), rede MLP, rede SOM e rede

GRNN. O módulo de extração de conhecimento é responsável pela extração de regras proposicionais a partir dos classificadores treinados, a fim de elucidar para o médico ortopedista como o classificador chega ao diagnóstico final.

Em particular, o módulo de classificação de patologias do sistema SINPATCO utiliza atributos biomecânicos recentemente propostos para efetuar a categorização de um paciente em três classes: pacientes normais, pacientes com espondilolistese e pacientes com hérnia de disco. Os diversos classificadores supracitados são comparados com relação à taxa de acerto, número de falsos positivos, número de falsos negativos e sensibilidade a amostras discrepantes (*outliers*).

As contribuições deste trabalho são variadas, indo desde do fato de ser o primeiro a usar um conjunto recente de atributos biomecânicos para projeto de classificadores na área de medicina ortopédica, passando pelo estudo comparativo do desempenho de vários classificadores, até a extração de regras a partir dos classificadores com melhor desempenho para explicar o diagnóstico obtido ao médico, para posterior avaliação. Até onde se tem conhecimento, a combinação destas três contribuições torna o sistema SINPATCO inovador na área de ortopedia médica, servindo de auxílio na atividade de diagnóstico e facilitando o trabalho dos profissionais dessa área.

Além de servir como ferramenta de auxílio ao diagnóstico do médico especializado em ortopedia, o sistema SINPATCO pode ser usado por clínicos não-especialistas em ortopedia, a fim de minimizar a carência de ortopedistas em regiões remotas, agilizando o atendimento e o encaminhamento do paciente para centros mais desenvolvidos.

## 1.2 **Objetivo Geral da Dissertação**

Em seu sentido mais amplo, o principal objetivo deste trabalho é desenvolver um sistema capaz de auxiliar o médico na tomada de decisão, servindo como ferramenta de auxílio ao diagnóstico de patologias da coluna vertebral. Além do auxílio à tomada de decisão, o sistema proposto pode ajudar na formação de profissionais especialistas na área ortopédica.

## 1.3 **Objetivos Específicos**

Em seu sentido mais específico, esta dissertação tem os seguintes objetivos particulares:

- Contribuir com um levantamento bibliográfico abrangente sobre o tema de interesse desta dissertação, enfatizando a ausência de trabalhos voltados para o diagnóstico automático de patologias da coluna vertebral;
- Avaliar a plausibilidade de se usar um conjunto de atributos biomecânicos recentemente proposto na literatura para projetar classificadores automáticos de patologias da coluna vertebral;
- Avaliar o desempenho de algoritmos estatísticos clássicos e neurais na classificação de padrões normais e patológicos da coluna vertebral;
- Implementar métodos de extração de regras a partir de redes neurais treinadas, a fim de explicar o processo de diagnóstico ao médico usuário da plataforma SINPATCO.

## 1.4 Hipóteses de Trabalho

No início deste trabalho de pesquisa algumas hipóteses são levantadas a fim de nortear as ações e estudos comparativos realizados no decorrer do desenvolvimento desta dissertação e que levam à conclusão da mesma. As principais hipóteses, listadas a seguir na forma de questionamentos, são respondidas oportunamente ao longo desta dissertação:

- Os atributos biomecânicos utilizados são úteis no projeto de classificadores de padrões para diagnóstico de patologias da coluna vertebral?
- Classificadores neurais apresentam melhor desempenho em relação aos classificadores convencionais?
- A classificação de padrões é mais eficiente quando os dados estão livre de padrões incomuns (*outliers*)?
- As regras extraídas explicam realmente o processo de diagnóstico realizado pelos classificadores neurais? Ou seja, a inferência é satisfatória para o médico usuário?

## 1.5 Organização da Dissertação

Este trabalho é formado por cinco capítulos, além deste, organizados da seguinte forma: reconhecimento de padrões; extração de regras de redes neurais treinadas; SINPATCO e resultados; e conclusões e trabalhos futuros.

O Capítulo 2 descreve a estrutura e os componentes da coluna vertebral, além das patologias hérnia de disco e espondilolistese que são objetos de estudo.

O Capítulo 3 trata dos principais tópicos desse assunto que podem auxiliar no entendimento do restante desta exposição. Discorre sobre os principais objetivos do reconhecimento de padrões, os classificadores, tipos de classificadores, e descreve de forma sucinta a implementação dos algoritmos: Discriminante Linear, Discriminante Quadrático, *Naive Bayes*, *k - Vizinhos mais Próximos*, rede Perceptron Multicamada, rede WTA, rede SOM (*Self-Organizing Map*) e *General Regression Neural Network*. Também aborda sobre algumas técnicas de pré-processamento de dados adotadas, tais como remoção de amostras discrepantes *outliers*.

O Capítulo 4 apresenta um abordagem introdutória e geral sobre as técnicas de extração de regras de redes neurais, descrevendo a sua taxonomia, além de descrever os algoritmos que realizam a extração e representação de regras para as redes Perceptron Multicamadas e a rede SOM.

O Capítulo 5 aborda aspectos sobre a implementação realizada para os algoritmos de classificação e extração de regras, destacando a plataforma utilizada. Explica todo o procedimento utilizado para construção e ajuste dos algoritmos, uma forma automatizada de obtenção das regras simbólicas e uma comparação entre as técnicas aplicadas.

O Capítulo 6 aborda algumas considerações finais sobre esta exposição, comentando e analisando os resultados obtidos. Ressalta as contribuições que auxiliaram na elaboração desse trabalho. E para finalizar, sugere alguns trabalhos futuros relacionados com esta dissertação.

## 1.6 Produção Científica

Durante o desenvolver deste trabalho de mestrado foram desenvolvidos os seguintes trabalhos científicos:

- **Ajalmar R. R. Neto**, Paulo C. Cortez, Henrique da Mota & Guilherme A. Barreto (2006), “SINPATCO: Sistema Inteligente para Diagnóstico de Patologias da Coluna Vertebral”, submetido e aceito no *XVI Congresso Brasileiro de Automática (CBA'2006)*, Salvador-BA.
- **Ajalmar R. R. Neto**, Paulo C. Cortez, Henrique da Mota & Guilherme A. Barreto (2006), “Classificação de Patologias da Coluna Vertebral Usando Redes Neurais



Artificiais”, submetido e aceito no *X Congresso Brasileiro de Informática em Saúde* (CBIS’2006), Florianópolis-SC.

- **Ajalmar R. R. Neto**, Paulo C. Cortez, Henrique da Mota & Guilherme A. Barreto (2006), “SINPATCO: An Intelligent System for Diagnosis of Pathologies of the Vertebral Column”, *Artificial Intelligence in Medicine* (em preparação).

## *2 Coluna Vertebral e Patologias: uma Descrição Fisiológica*

O objetivo deste capítulo é fornecer o fundamento teórico básico para características (atributos) a serem usados pelos classificadores. Este capítulo descreve a estrutura e os componentes da coluna vertebral, além das características fundamentais de duas patologias muito comuns da coluna vertebral, a saber: hérnia de disco e espondilolistese.

### **2.1 A Coluna Vertebral**

A coluna vertebral, segundo HALL (2000), é um segmento complexo e funcionalmente significativo do corpo humano. As principais funções da coluna vertebral são as seguintes:


1. eixo de suporte do corpo humano;
2. protetor ósseo da medula espinhal e das raízes nervosas;
3. eixo de movimentação do corpo, possibilitando o movimento nos três planos: frontal, sagital e transversal.

As funções enumeradas nos itens 1 e 2 por serem de caráter mais estáveis são obtidas, de uma forma mais satisfatória, por uma estrutura sólida ou rígida. Já, para uma função como enumerada em 3, uma estrutura com múltiplas articulações pode fornecer melhores resultados para os movimentos do corpo em detrimento a uma estrutura sólida, pois em uma estrutura bem articulada existem vários graus de liberdade e eixos de movimentação (KNOPLICH, 2003).

Na coluna vertebral, os elementos anteriores formados por disco, corpo vertebral, ligamentos longitudinais anteriores e posteriores são os responsáveis pela função de sustentação, enquanto os elementos posteriores dos arcos neurais e articulações da coluna são responsáveis pela movimentação do corpo. Enquanto a função de proteção da medula

e raízes nervosas é desempenhada pelos elementos anteriores e posteriores da coluna vertebral.

A coluna vertebral, do ponto de vista anatômico, é composta por 33 ou 34 vértebras sobrepostas e se encontra dividida em quatro partes: coluna cervical, coluna torácica, coluna lombar e coluna sacral/coccix. A Figura 2.1 mostra a coluna cervical na região A, a coluna torácica na região B, a coluna lombar na região C e a coluna sacral/coccix na região D. A coluna cervical está localizada na região do pescoço e apresenta 7 vértebras, a coluna torácica possui 12 vértebras e se localiza na região do tórax, a coluna lombar apresenta 5 vértebras e se localiza na região da cintura, enquanto a coluna sacral/coccix localiza-se na região pélvica e possui 9 ou 10 vértebras que se encontram fundidas em um único bloco (TRIBASTONE, 2001). A Figura 2.1 é derivada de outra que pode ser obtida no site [http://www.doresnascostas.com.br/images/i7a\\_b.gif](http://www.doresnascostas.com.br/images/i7a_b.gif).



**Figura 2.1:** segmentos da coluna vertebral.

Segundo KNOPLICH (2003), as curvas fisiológicas têm um papel funcional, permitindo que a coluna vertebral aumente a sua flexibilidade e a capacidade de absorver os choques, enquanto mantém a tensão e a estabilidade das articulações intervertebrais. A curvatura da cervical e da lombar são devidas a espessura do disco intervertebral, que é mais alto na frente do que atrás, entretanto a cifose torácica é devida ao aumento em cunha das vértebras.

### 2.1.1 Vértébras

Uma vértebra é constituída por um sólido cilindro ósseo chamado de corpo vertebral e de um anel ósseo de formato redondo-ovalado, composta pelas lâminas que se juntam e formam o processo espinhoso.

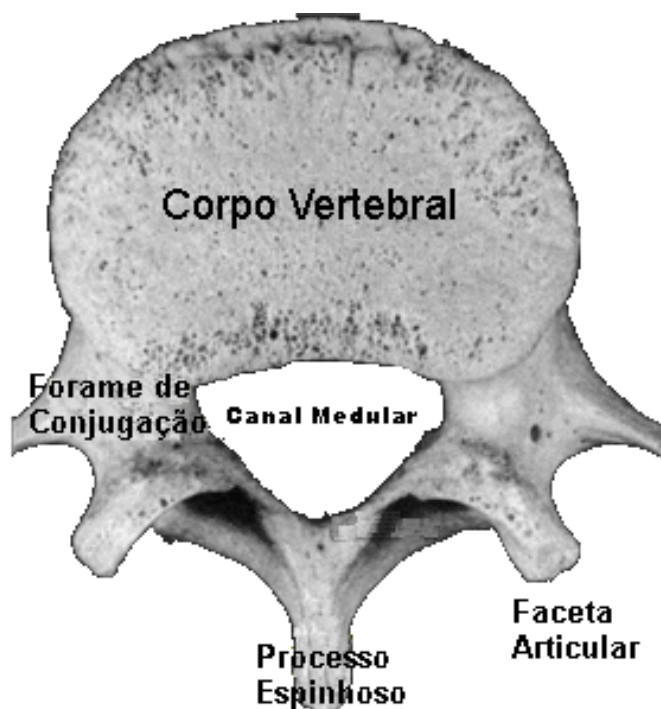


Figura 2.2: estrutura de uma vértebra típica.

Uma vértebra típica, segundo CAMPOS (2002), consiste de duas partes principais: uma parte anterior, denominada corpo da vértebra e uma parte posterior, denominada arco da vértebra. Os corpos vertebraes funcionam como os componentes primários da coluna responsáveis pela sustentação do peso. Os arcos neurais e os lados posteriores dos corpos e dos discos intervertebrais compõem uma passagem protetora para a medula espinhal e os vasos sanguíneos associados, conhecida como canal vertebral ou medular. A partir da superfície de cada arco neural, fazem protusão vários processos ósseos. Os processos espinhosos e transversos funcionam como forquilhas destinadas a aprimorar a vantagem mecânica dos músculos inseridos. O corpo vertebral, o canal medular e outros elementos que compõem a vértebra podem ser observados na Figura 2.2. Esta figura apresenta-se modificada de outra obtida no site <http://www.doresnascostas.com.br>.

O corpo da vértebra é composto de osso esponjoso, recoberto com uma camada de osso cortical e é a porção da vértebra que recebe maior sobrecarga.

O arco da vértebra é constituído por processos articulares, que formam as facetas articulares ou articulações facetárias, e por processos não-articulares, os quais são formados por dois processos transversos e um processo espinhoso (CAMPOS, 2002).

Na coluna vertebral observa-se um aumento gradativo no tamanho das vértebras da região cervical até a região lombar. Em particular, as vértebras lombares são mais espessas e maiores que as vértebras nas regiões superiores da coluna. A finalidade funcional que justifica essa característica é a necessidade de que cada vertebra tem de sustentar o peso não apenas dos braços e da cabeça, mas também de todo o tronco posicionado acima dela. Logo, uma maior área superficial das vértebras na região lombar reduz a quantidade de estresse mecânico, ao qual poderiam ser submetidas estas vértebras.


Ao longo das diferentes regiões vertebrais existe uma modificação na orientação das articulações facetárias, devido a variação do tamanho e da angulação dos processos vertebrais, o que limita a amplitude de movimento. Além de canalizar o movimento do segmento móvel, as articulações facetárias auxiliam na sustentação das cargas. As articulações facetárias e os discos proporcionam cerca de 80% da capacidade da coluna de resistir à torção rotacional e ao cisalhamento, com metade dessa contribuição sendo feita por parte das articulações facetárias. Estas sustentam cerca de 30% das cargas compressivas que agem sobre a coluna, principalmente quando se encontram em hiperextensão.

### 2.1.2 Discos Intervertebrais

Os discos intervertebrais são sínfises com discos fibrocartilagosos interpostos que atuam como coxins. Os discos intervertebrais em um adulto saudável são responsáveis por uma quarta parte da altura da coluna. As diferenças na espessura anterior e posterior dos discos, quando o tronco está ereto, produzem as curvaturas: lombar, torácica e cervical da coluna.

Um disco intervertebral é constituído por um material gelatinoso central conhecido como núcleo pulposo (ou apenas núcleo) e por um anel externo formado por cartilagem fibrosa denominado anel fibroso ou ânulo, que circunda o núcleo. O ânulo é formado por cerca de 90 faixas concêntricas de tecido cartilaginoso, mantidas em íntimo contato umas com as outras. As fibras colágenas do ânulo se entrecruzam verticalmente, formando ângulos de aproximadamente 30° umas com as outras, o que torna esta estrutura mais sensível à pressão rotacional do que à compressão, à tensão e ao cisalhamento. O núcleo de um disco jovem e saudável é constituído por cerca de 90% de água, com o restante sendo formado por colágeno e proteoglicanos, materiais especializados que atraem a água

quimicamente. O conteúdo hídrico extremamente alto do núcleo o torna resistente à compressão. O núcleo, o anel fibroso e estruturas relacionadas podem ser observadas através da Figura 2.3 que mostra um segmento lombar da coluna vertebral.



**Figura 2.3:** visão superior de um segmento lombar.


Mecanicamente, o ânulo atua como uma mola espiralada cuja tensão mantém juntos os corpos vertebrais contra a resistência do núcleo pulposos, com este agindo como um rolamento contendo um gel incompressível. Durante a flexão e a extensão os corpos vertebrais giram sobre o núcleo, enquanto as articulações facetárias orientam os movimentos. A extensão e a flexão lateral da coluna vertebral produzem um esforço compressivo em um lado dos discos e um estresse de tração no outro lado, enquanto a rotação vertebral cria um esforço de cisalhamento nos discos. Durante a realização das atividades diárias, a compressão é a forma mais comum de sobrecarga imposta a coluna vertebral.

Quando um disco é sobrecarregado com compressão, ele tende simultaneamente a perder água e absorver sódio e potássio até que sua concentração eletrolítica interna seja suficiente para prevenir qualquer perda adicional de água. Quando é alcançado esse equilíbrio químico, a pressão interna do disco torna-se igual à pressão externa. Uma sobrecarga contínua, por um período de várias horas, resulta em uma ligeira redução adicional na hidratação do disco. Por esta razão, a coluna sofre uma diminuição na altura de até 2cm no transcorrer do dia, com cerca de 54% desta perda ocorrendo durante 30 minutos após levantar-se pela manhã.

Uma vez eliminada a pressão exercida sobre os discos, estes reabsorvem água rapidamente e seus volumes e alturas aumentam. Os astronautas experimentam um aumento temporário na altura da coluna de aproximadamente 5cm quando estão livres da influência da gravidade. Na terra, a altura e o volume dos discos são tipicamente maiores quando

uma pessoa se levanta pela manhã. Como o aumento de volume do disco que equivale também a uma maior rigidez vertebral, deve haver uma intensificação de risco de lesão discal na parte inicial da manhã.

Os discos intervertebrais possuem um suprimento sanguíneo até aproximadamente os 8 anos de idade, porém a seguir os discos terão que confiar em meios mecânicos para manter o estado nutricional saudável. As mudanças intermitentes na postura e na posição corporal alteram a pressão discal interna, dando origem a uma ação de bombeamento no disco. O influxo e o fluxo de água transportam nutrientes para dentro e removem produtos de desgaste metabólico, logo desempenhando basicamente a mesma função que o sistema circulatório proporciona às estruturas vascularizadas dentro do corpo. A manutenção de uma posição corporal fixa, até mesmo extremamente confortável, durante um certo período de tempo reduz esta ação de bombeamento e pode afetar negativamente a saúde discal.



**Figura 2.4:** coluna vertebral, com rotulação das vértebras.

As lesões e o envelhecimento reduzem irreversivelmente a capacidade dos discos absorverem água, havendo uma diminuição concomitante na capacidade de absorção dos choques. Os estudos de ressonância magnética mostram que as alterações degenerativas são mais comuns em L5-S1 (observar Figura 2.4), com o disco estando sujeito ao máximo de esforço mecânico em virtude de sua posição. Entretanto, o conteúdo líquido de todos os discos começa a diminuir por volta da segunda década da vida.

### 2.1.2.1 Compressão dos Discos Intervertebrais

Os discos intervertebrais possuem uma grande capacidade de absorção de sobrecargas de compressão axial. Quando ocorre uma sobrecarga, o disco perde altura e tenta expandir-se para fora em direção ao anel fibroso e placas terminais.

Os fluidos, tanto do núcleo pulposo, como do anel fibroso diminuem, devido ao aumento da pressão. Cerca de 10% da água de dentro do disco pode ser expelida. A quantidade exata de perda de fluido depende da magnitude de duração da força aplicada (CAMPOS, 2002).

No jovem o conteúdo de proteoglicanos (substância que atrai água) é de 65%, diminuindo para cerca de 30% na idade avançada. Acima dos 30 anos, quando o conteúdo de proteoglicanos está alto, o núcleo pulposo é gelatinoso e sua pressão é uniforme. Com o avanço da idade, diminui a quantidade de água do disco diminuindo assim sua capacidade de reação à compressão (CAMPOS, 2002).

As alterações relacionadas com a idade, a redução de condicionamento físico, alterações de padrões dos movimentos na realização de atividades da vida diária, acarretam maior suscetibilidade às lesões. As lesões e o envelhecimento reduzem irreversivelmente a capacidade dos discos absorverem água, havendo uma diminuição concomitante na capacidade de absorção de choques (HALL, 2000).

As forças de compressão aumentam a dimensão horizontal do disco, fator importante para a explicação da hérnia discal. Esta força de flexão é uma das mais agressivas ao disco. O ato de fletir o corpo faz com que as forças compressivas se apliquem na parte côncava, com deslocamento do núcleo, conforme o peso levantado, este ato pode produzir a herniação do núcleo pulposo. As forças que causam mais danos para o anel fibroso são as de torção ou rotação do corpo com peso. As forças de cisalhamento (forças de compressão que encontram a estrutura discal na posição inclinada), atuam no disco nas diversas idades, encontrando assim a estrutura anatômica, histoquímica e biológica do disco com diversas alterações. Esta força quando aplicada por muito tempo, pode alterar a estrutura do disco, aumentando a degeneração discal (KNOPLICH, 2003).

O disco é uma estrutura visco-elástica que absorve energia após receber repetidas forças, denominado de histerese. Inicialmente admitiu-se que isto fosse um fator de proteção, mas hoje sabe-se que as forças axiais vibratórias, de pequena intensidade mas atuando por longo tempo, podem causar hérnia de disco ou discopatia (KNOPLICH, 2003).

O conteúdo líquido de todos os discos começa a diminuir por volta dos 20 anos, e



um disco geriátrico típico possui um conteúdo líquido reduzido em cerca de 35%. À medida que ocorre esta alteração degenerativa natural, ocorrem movimentos anormais entre corpos vertebrais adjacentes, e uma maior proporção de cargas compressivas, de tração e de cisalhamento que agem sobre a coluna que deve ser suportada por outras estruturas, particularmente as facetas e as cápsulas articulares (HALL, 2000).

A pressão nos discos intervertebrais é afetada pela posição do corpo. Para uma pessoa de 70Kg em pé, a pressão no disco L3 é de 100%. Na posição em decúbito dorsal, a pressão diminui para 25%. Conforme a coluna lombar é flexionada, a pressão aumenta. Na postura sentada a pressão intradiscal é de 140%, em relação ao indivíduo na posição ereta.

### 2.1.2.2 Hidratação dos Discos Intervertebrais

A hidratação dos discos ocorre quando a pressão exercida sobre os discos é eliminada, eles reabsorvem água rapidamente e seus volumes e alturas aumentam (HALL, 2000).

O disco é provido de vascularização própria até os 20 anos , depois torna-se avascular e se nutre pela difusão da linfa. Isto é possível a partir da alternância de compressões e relaxamentos, ou seja, o anel fibroso se comporta como uma esponja (TRIBASTONE, 2001).

A pressão discal interna é alterada por mudanças na postura e na posição corporal, originando uma ação de bombeamento no disco, transportando nutrientes para dentro do disco e removendo produtos de desgaste metabólico, desempenhando assim a função que o sistema circulatório proporciona às estruturas vascularizadas. Portanto, a manutenção de uma mesma posição corporal por um certo período de tempo reduz essa ação de bombeamento, podendo afetar a saúde discal (HALL, 2000).

Alguns fatores, como tabagismo e a exposição às vibrações, podem afetar negativamente a nutrição discal, em contra-partida o exercício regular pode aprimorar a nutrição (HALL, 2000).

### 2.1.3 Articulações

As articulações, nos seres vertebrados, são conexões habituais existentes entre dois ou mais ossos. As vértebras são conectadas entre si pelas articulações posteriores entre os corpos vertebrais e os arcos neurais.

As vértebras da coluna se articulam de modo a conferir estabilidade e flexibilidade

à coluna. A estabilidade e flexibilidade são atributos necessários para a mobilidade do tronco, postura, equilíbrio e suporte de peso. Na coluna vertebral as articulações são de dois tipos: diartroses e anfiartroses.

As diartroses são juntas verdadeiras, com superfície cartilaginosa, líquido sinovial (líquido transparente e viscoso das cavidades articulares e bainhas dos tendões) e cápsula.

As articulações do tipo anfiartroses são semimóveis, não contendo líquido sinovial, como os discos intervertebrais e as conexões ligamentares. As diartroses são formadas pelas facetas articulares das vértebras e também incluem a articulação atlantoaxoidea com o crânio; as articulações costovertebrais das costelas e as sacroiliacas da coluna com a bacia. Nas anfiartroses, os movimentos são pequenos, porém também há alterações de desgaste, pelo fato do disco desempenhar uma função de suporte do peso corporal.

Além das diartroses e anfiartroses, existem outras articulações especiais com características bem peculiares, que são: occipitoatloidea, atlantoaxoidea, pelvivertebral, sacroilíaca, coccigianas e a sínfise púbica.

As occipitoatloideas são articulações em que existem numerosos ligamentos bem desenvolvidos, que permitem uma conexão importante, de manutenção e proteção dessa articulação, que não tem disco. As atlantoaxoideas são articulações cuja estabilidade depende do ligamento cruciforme. A ruptura do ligamento cruciforme nas atlantoaxoideas pode causar a fratura da apófise odontóide. O ligamento nugal é uma faixa larga e fibrosa, firmemente aderida ao crânio e aos processos espinhosos das primeiras vértebras cervicais, tendo a função de proteção contra uma excessiva flexão da cabeça.

A articulação pelvivertebral apresenta-se na altura da quinta vértebra lombar, saem de cada lado os ligamentos iliolumbares. Outro tipo de articulação a sacroilíaca é uma articulação pouco móvel (anfiartrose), porém tem as superfícies articulares, tanto do sacro como do íliaco, cobertas por cartilagens. Estas articulações têm ligamentos, os sacroilíacos, que aumentam sua estabilidade. Enquanto as articulações coccigianas são semelhantes às das vértebras, com rudimento de disco e articulações, e possuem com inúmeros ligamentos a sínfise púbica é uma articulação tipo anfiartrose, e apresenta também inúmeros ligamentos.

Identifica-se na coluna, como unidade funcional, o chamado segmento motor de Jungmans, que é formado por dois segmentos: porção anterior e posterior.

A porção anterior consta dos dois corpos vertebrais e do disco intervertebral e tem a função de suportar 80% do peso e absorver os choques. Na porção anterior da coluna

cervical existem, além do corpo vertebral e do disco, as duas articulações que se formam nas margens laterais do anel cartilaginoso. Estas projeções articulares anteriores são chamadas de uncovertebrais, intervertebrais laterais ou articulações de Van Luschka. Embora sejam chamadas de articulações, são pseudo-articulações, pois não há superfícies articuladas. Estas apófises unciformes formam parte importante da patologia da coluna cervical, porque sofrem um processo de hipertrofia no ato degenerativo de uso e de desgaste da região. Este processo unciforme não permite que o disco cervical, quando herniado, comprima a raiz nervosa, como ocorre na região lombar, em que não existem as apófises unciformes. A função de proteção da compressão da raiz, na região dorsal, é feita pela presença da costela.

A porção posterior é também chamada de arco neural e consta dos dois processos transversos, uma apófise espinhosa e dois pares de articulações, uma inferior e outra superior, conhecidas como facetas articulares. Estas articulações são diartroses e, em conjunto com os músculos, realizam os movimentos da coluna. Constatou-se que as articulações suportam de 16 a 20% do peso corporal. A direção das facetas articulares, que varia nas três regiões da coluna, determina a direção do movimento que o respectivo segmento pode realizar.

#### 2.1.4 As Facetas

As facetas são articulações situadas frente a frente com outras, que deslizam umas sobre as outras e se inclinam para frente e para trás. Em virtude de suas superfícies achatadas, que deslizam umas sobre as outras no plano frontal, elas impedem que a coluna vertebral fique rodando ou balançando, para esquerda ou para direita em algum grau significativo. Por seu alinhamento, também impedem que a coluna vertebral incline-se para os lados. Tais facetas, encontradas apenas na coluna lombar, permitem que esta se incline para frente e para trás, mas impedem ou limitam a inclinação ou balanceio lateral. A coluna lombar só pode, essencialmente, fletir-se ou se estender, isto é, inclinar-se para frente ou para trás, mas só pode se inclinar ou balançar muito pouco para esquerda ou para direita.

#### 2.1.5 Ligamentos

Inúmeros ligamentos sustentam a coluna, contribuindo para a estabilidade dos segmentos móveis. O poderoso ligamento longitudinal anterior e o ligamento longitudinal

posterior, mais fraco, conectam os corpos vertebrais nas regiões cervical, torácica e lombar. O ligamento supra - espinhoso se insere nos processos espinhosos em toda a extensão da coluna. Este ligamento exhibe um aumento proeminente na região cervical, onde recebe a designação de ligamento nugal ou ligamento do pescoço. As vértebras são adjacentes e possuem conexões adicionais entre os processos espinhosos, os processos transversos e as lâminas, reforçadas respectivamente pelos ligamentos inter-espinhosos, ligamentos intertransversais e ligamentos amarelos.

Os três grupos de ligamentos intersegmentares são os ligamentos: amarelo, interespinhosos e intertransversos. O ligamento amarelo une as lâminas das vértebras adjacentes. Cada ligamento amarelo consiste de uma folha de tecido elástico regular. Os ligamentos amarelos, como ligamento nugal, são estirados durante a flexão da coluna vertebral e, assim, auxiliam a restaurar a orientação normal da coluna após a flexão. Desta forma, o ligamento amarelo alivia a pressão sobre os músculos extensores do dorso.

O ligamento amarelo torna-se importante, pois, conecta-se às lâminas de vértebras adjacentes. Apesar da maioria dos ligamentos vertebrais ser constituída, principalmente por fibras colágenas, que se distendem muito pouco, o ligamento amarelo contém uma alta proporção de fibras elásticas, que se alongam quando distendidas durante a flexão vertebral e se encurtam durante a extensão vertebral. O ligamento amarelo permanece sobre tensão até mesmo quando a coluna está em sua posição anatômica, o que aprimora a estabilidade vertebral. Esta tensão cria uma ligeira compressão constante nos discos intervertebrais, que a designação de pré-estresse.


Os ligamentos interespinhosos são sindesmoses membranosas que unem as espinhas das vértebras adjacentes. São contínuos com os ligamentos supra - espinhosos e fornecem áreas de inserção para os músculos em ambas as áreas laterais. Os ligamentos intertransversos unem os processos transversos das vértebras adjacentes e tendem a se tornar progressivamente mais largos de cima para baixo na coluna.

## 2.2 Hérnia de Disco

A hérnia de disco é um prolapso do núcleo pulposo para fora do anel fibroso do disco intervertebral. A hérnia de disco pode ser descrita ainda como a projeção da parte central do disco intervertebral, o núcleo pulposo, para além de seus limites normais (a parte externa do disco). Geralmente, a hérnia de disco, ocorre póstero-lateralmente, em virtude da falta de ligamentos que sustentem o disco nessa região. Além disso, a hérnia

de disco pode apenas fazer uma saliência na parede do disco ou pode sair, dando vazão a grande parte do conteúdo nuclear (MERCÚRIO, 1998).

Uma radiografia de um indivíduo com hérnia de disco é mostrado na Figura 2.5. Vale ressaltar que, visualmente, não é possível o diagnóstico de hérnia de disco por uma radiografia simples. No entanto, a radiografia permite medir parâmetros que possibilitam o diagnóstico.



**Figura 2.5:** indivíduo com hérnia de disco.

A sintomatologia da hérnia discal está relacionada com a situação do disco, com sua localização no disco e com a pressão que o material herniado exerce em estruturas sensíveis como por exemplo, as raízes nervosas (MERCÚRIO, 1998).

O disco propriamente dito não é inervado, e portanto incapaz de gerar uma sensação de dor, existem porém, nervos sensoriais que inervam os ligamentos longitudinais anterior e posterior, os corpos vertebrais e a cartilagem articular das articulações facetárias. Se a hérnia exerce pressão sobre uma dessas estruturas, sobre a medula espinhal ou sobre um nervo raquidiano, pode resultar em dor ou dormência (HALL, 2000).

Um fator bastante relacionado a degeneração do disco intervertebral é a diminuição no conteúdo de proteoglicanos no disco, sendo estes os principais responsáveis pela hidratação do núcleo pulposo, dando-lhe a propriedade de gel, que faz com que as pressões no anel sejam distribuídas uniformemente. Com a diminuição da pressão de embebição do disco, maior pressão é transmitida às fibras do anel, o núcleo perde suas propriedades hidráulicas, de amortecedor das pressões e as fibras do anel tornam-se mais predispostas à ruptura (HERBERT, 1998).

Entre os 30 e 50 anos de idade - fase de degeneração discal, é mais comum ocorrer a hérnia, com a distribuição das pressões de forma desigual e após esta fase, devido à maior perda de água no disco, o núcleo deixa de transmitir estas pressões, diminuindo assim as chances da ocorrência de hérnia. Um outro fator causal pode ser a postura ereta adotada pelo homem durante a evolução. Em um trabalho experimental, ratos tiveram suas patas dianteiras amputadas, adquirindo assim a postura ereta e passaram a apresentar alterações discas semelhantes às do homem. Em um outro trabalho em voluntários na Suécia, em que medida a pressão intradiscal em diferentes posições, observou-se uma maior pressão na posição sentada, menor em decúbito dorsal e quanto mais se inclina o tronco à frente, maior é a pressão (HERBERT, 1998).

### **2.2.1 Causas da hérnia de Disco**

A hérnia de disco é uma combinação de fatores biomecânicos, alterações degenerativas do disco e situações que levam a um aumento de pressão sobre o disco, cujas causas estão relacionadas à traumatismos, deformidades da coluna, rigidez corporal em indivíduos sedentários, obesidade, hipotonia e flacidez muscular. Fatores psicológicos como depressão e estresse também contribuem para desencadear um quadro de hérnia de disco (HERBERT, 1998).

Os discos intervertebrais estão sujeitos à cargas crônicas (pressão intensa ou contínua por grandes períodos de tempo), especialmente nas inclinações e torções, durante trabalho braçal pesado como: levantamento e carregamento de peso, uso de pás, puxões e empurrões. Essa pressão crônica acelera a degeneração do disco, contribuindo significativamente para o surgimento de hérnias discas (VERDERI, 2004).


### **2.2.2 Diagnóstico da Hérnia de disco**

A realização de uma história clínica (em que se avaliam as características da dor e a existência de outros sintomas associados) e de um exame objetivo completo são procedimentos essenciais para o diagnóstico desta doença. Em algumas situações é necessário a realização de uma radiografia, de uma tomografia axial computadorizada (TAC) ou de uma ressonância magnética da área da coluna afetada, para assim se avaliarem melhor as estruturas ósseas, musculares, cartilaginosas e nervosas. A ressonância magnética é o melhor exame para visualizar os discos intervertebrais. Por vezes, pode-se efetuar uma discografia, que consiste na injeção de contraste no disco para a sua visualização.

## 2.3 Espondilolistese

A palavra espondilolistese deriva de duas partes, espondilo que significa vértebra e listese que significa deslizamento. Desta forma espondilolistese é um deslizamento para frente de uma vértebra, de forma que uma das 33 vértebras desliza adiante em relação a outra na coluna vertebral. Este deslizamento quando verificado ocorre, geralmente, em direção a base da espinha na região lombar.

Na Figura 2.6, que mostra a radiografia de um indivíduo com espondilolistese, percebe-se em sua parte mais inferior um deslizamento da quinta vértebra sobre o sacro. Este deslizamento caracteriza a espondilolistese. Uma análise comparativa pode ser feita através das Figuras 2.6 e 2.7 que representam um indivíduo com espondilolistese e um indivíduo saudável, pois, é fácil observar a sobreposição correta entre as vértebras na última figura.



**Figura 2.6:** indivíduo com espondilolistese.

A métrica usada para medida da espondilolistese é o quanto do corpo da vértebra tem deslizado adiante sobre o corpo da vértebra debaixo dela, ou seja, mede-se o grau de severidade do deslizamento. Em vista disso, uma classificação comumente usada para espondilolistese, descreve os graus de severidade em níveis, que aumentam de uma situação menos avançada com grau 1 até o grau 5 na situação mais avançada.

Aproximadamente entre 5-6% de homens, e 2-3% de mulheres têm espondilolistese. Esta patologia aparece geralmente em pessoas que estão envolvidas com muita atividade física (esportivas ou não). Outra evidência, relativa ao aumento de atividades físicas, é



Figura 2.7: indivíduo saudável.

a menor predisposição de indivíduos à espondilolistese em pessoas na infância do que em pessoas na fase adolescente e adulta.

### 2.3.1 Causas da espondilolistese

Os diferentes tipos de espondilolistese são ocasionados de diferentes formas. Alguns exemplos são a espondilolistese desenvolvida e a adquirida.

A espondilolistese desenvolvida pode existir desde o nascimento, ou pode ser desenvolvida durante a infância, mas geralmente não é percebida na infância notando-se apenas depois na fase adulta.

A espondilolistese adquirida pode ter sua causada pelo estresse do dia-a-dia ou pela repetição da aplicação de uma força a coluna. O esforço do dia-a-dia que incide sobre a coluna, assim como o carregamento de itens pesados e esportes físicos, pode causar um desgaste da coluna, que se degenera, e ocasiona o enfraquecimento das conexões entre as vértebras levando a espondilolistese. Uma simples força ou a repetição de forças aplicadas a coluna vertebral podem causar a espondilolistese, por exemplo, o impacto de subir em uma escada, ou o impacto regular sofrido por jogadores de futebol.

### 2.3.2 Diagnóstico da espondilolistese

Um procedimento que tira radiografia lateral enquanto se está de pé confirma o diagnóstico da espondilolistese. De forma que, o raio-x mostra o deslizamento de uma vértebra sobre



uma outra vértebra adjacente, geralmente inferior.

Usando o raio-x lateral, o deslize pode ser medido de acordo com o grau de severidade. O sistema de classificação Myerding mede a percentagem do deslize de vértebra adiante em relação à vértebra inferior. As medidas podem ser: de grau 1 com 25% de deslize, grau 2 entre 25% até 49%, grau 3 de 50% até 74%, grau 4 com 75% até 99% e por fim grau 5 com 100% de deslize. Para medidas com grau 5 nota-se logicamente que a vértebra deslizou completamente e para este caso a espondilolistese é denominada e espondiloptose.

## 2.4 Seleção de Características

Um grupo formado pelos especialistas Joannés Dimnet, Eric Berthonnaud, Pierre Roussouly e Henrique da Mota com estudos sobre Biomecânica Clínica intensificam seus trabalhos no anos de 2000/2001 no Laboratório de Biomecânica do Centre Des Massues localizado em Lyon/França. Durante este período, o Grupo de Pesquisa Avançada em Ortopedia (*Group of Applied Research in Orthopaedics*, GARO) organiza um base de dados com informações de pacientes saudáveis, escolióticos e com espondilolistese, e realiza importantes estudos que são apresentados na França, Suécia, EUA e Canadá.

Em paralelo, o Dr. Henrique da Mota juntamente com Vincent Fiére realiza um trabalho que, pela primeira vez, permite notar a relação entre a hérnia de disco e os parâmetros espinopélvicos. Ao regressar ao Brasil o Dr. Henrique da Mota percebe pela primeira vez que outras patologias discais degenerativas e que também as lombalgias estão em correlação com os ângulos espinopélvicos. E assim, vem apresentando diversos trabalhos neste sentido em vários eventos da especialidade. Exemplos de trabalhos desenvolvidos são vistos nos artigos de FIÉRE e DA MOTA (2001) e BERTHONNAUD et al. (2001).

Das pesquisas realizadas resulta a descrição de um conjunto de características referentes a coluna vertebral que são selecionadas com a intenção de identificar se um indivíduo se apresenta normal, termo usado para a pessoa saudável, ou doente com as patologias hérnia de disco ou espondilolistese. Vale ressaltar que em pesquisa realizada na literatura praticamente verifica-se uma ausência de trabalhos nesta área, que se justifica em parte, por não existir até então uma conjunto de dados com características biomecânicas para estudo. Assim, a obtenção de uma base de dados com tais atributos é uma importante inovação nesta área.

A base de dados agrupada possui 310 amostras, das quais: 60 pertencem a indivíduos

com hérnia de disco, 150 a indivíduos com espondilolistese e 100 a indivíduos saudáveis. Cada uma das amostras desta base possui seis características, as quais estão relacionados a dores e deformidades iniciais, de grande interesse do ponto de vista clínico. As características são os parâmetros angulares sagitais do sistema espinopélvico, que são: ângulo de incidência pélvica, ângulo de versão pélvica, ângulo de lordose, declive sacral, raio pélvico e grau de deslizamento.





Figura 2.8: ângulo de incidência pélvica.

O ângulo de incidência pélvica (do inglês *pelvic incidence* - *PI*) é definido como sendo o ângulo subtendido pela reta  $\overline{ab}$ , que é extraído do centro da cabeça femoral para o ponto médio da placa sacral terminal, e uma reta perpendicular ao centro da placa sacral  $a$ . A placa terminal sacral é definida pela segmento de reta  $\overline{bc}$  entre o canto superior posterior do sacrum e a ponta anterior da placa terminal S1 no promontório sacral. Para o caso quando as cabeças femoral não são sobrepostas, o centro de cada cabeça femoral é marcado, e um segmento de reta deve ligar os centros das cabeças femorais. Verifique os pontos e as retas que definem o ângulo de incidência pélvica na Figura 2.8.



**Figura 2.9:** ângulo de versão pélvica.


O ângulo de versão pélvica (do inglês Pelvic tilt - PT), ver Figura 2.9, é descrito como sendo o ângulo subtendido por uma reta de referência vertical originada do centro  $o$  da cabeça do fêmur e do raio pélvico  $\overline{oa}$ . Esta afirmação está correta quando o verdadeiro eixo hipotético está em frente ao ponto médio da placa sacral terminal.

O declive sacral (do inglês Sacral slope - SS) que é definida como o ângulo subtendido por uma linha de referência horizontal (HRL) e pela linha sacral da placa terminal  $\overline{bc}$ . Esta característica pode ser observada na Figura 2.10.

O ângulo de lordose é o maior ângulo sagital entre o platô superior do sacro e o platô superior da vértebra lombar ou torácica limite.

A distância ou raio pélvico é a distância do centro do eixo bicoxofemural ao centro do plateau sacral. Este segmento de reta  $\overline{ao}$  pode ser verificado na Figura 2.8 (além desta, as figuras 2.9 e 2.10 são obtidas no artigo de LABELLE, ROUSSOULY e BERTHONNAUD (2005)).

Por último, o grau de deslizamento é o grau percentual de deslizamento entre o platô



**Figura 2.10:** declive sacral.

inferior da quinta vértebra lombar e o sacro.

O ângulo de incidência pélvica é uma constante anatômica individual que determina o comportamento de todo o sistema espinopélvico, através das variáveis posicionais de declive sacral e de versão pélvica. As variáveis posicionais têm, entre si, várias correlações. O surgimento de patologias na coluna vertebral está condicionada aos tipos morfológicos do sistema coluna e pelve. A incidência pélvica, sendo de grau elevado, condiciona a um maior declive sacral, que gera aumento de cisalhamento pelo aumento da inclinação do plano de apoio para lordose lombar, além de facilitar o conflito de estruturas posteriores, levando ao surgimento de uma fratura de fadiga no arco que sustenta a vértebra e gerando um deslizamento chamado de espondilistese. As baixas incidências pélvicas levam ao efeito contrário, com surgimento de aumento de pressão no disco intervertebral e facilitação de surgimento de degenerações e hérnias de disco. O ângulo de incidência determina um padrão de normalidade.

## 2.5 Extração de Características

A base de dados aplicada neste trabalho, contendo 310 amostras de pacientes, é obtida através de scanner de radiografias panorâmicas sagitais em formato de  $30 \times 90$  cm. Destes, 100 indivíduos são voluntários do Hospital de Massues que não possuem patologias na coluna. Os dados restantes são obtidos a partir de radiografias de pacientes operados de hérnias de disco (60 indivíduos) ou espondilolistese (150 indivíduos). Um scanner Vidar VXR 8 é utilizado, e as radiografias são tratadas por um sistema semi-automatizado de tratamento de imagem, desenvolvido pelo Dr. Eric Berthionnaud, chamado de Sagittal-Spine. Este sistema calcula os ângulos de bacia e o traçado linear da coluna a partir dos centros de cabeça de fêmur, da determinação da linha do plateau sacral e da determinação dos ápices das curvaturas lordóticas e cifóticas. Estas medidas facilitam os cálculos necessários para obtenção dos valores para cada um dos atributos descritos anteriormente.

## 2.6 Conclusão

Este capítulo descreve de um ponto de vista anatômico a coluna vertebral e os principais elementos que a compõem: disco vertebral, disco intervertebral, ligamentos, facetas entre outros. Os processos de compressão e hidratação dos discos intervertebrais também são apresentados. E ainda, também são descritas algumas patologias que ocorrem na coluna, tais como: hérnia de disco e espondilolistese.

A partir do conhecimento de patologias e atributos da coluna vertebral como: ângulo de incidência pélvica, ângulo de versão pélvica, ângulo de lordose, declive sacral, raio pélvico e grau de deslizamento, pode-se empregar técnicas de reconhecimento de padrões para a classificação das patologias hérnia de disco e espondilolistese. Um sistema formado por classificadores deste tipo pode auxiliar na tomada de decisão médica. Assim faz-se necessário a apresentação de técnicas de reconhecimento de padrões e algoritmos de classificação os quais são mostrados no capítulo a seguir.

## *3 Reconhecimento de Padrões*

O reconhecimento de caracteres, dígitos ou letras, escritos das mais diversas formas, grandes ou pequenos, rotacionados ou não são tarefas muito simples e facilmente realizadas por seres humanos desde crianças. Contudo, essas tarefas são ainda difíceis de ser traduzidas para uma linguagem ou formato que o computador possa processar e reconhecer. Esse tipo de tarefa, como o reconhecimento, a descrição, a classificação, e o agrupamento automático (de máquina) de entidades, dizem respeito a um ramo da ciência denominado Reconhecimento de Padrões (RP). Logo, desde que surgiu a necessidade de automatizar estas tarefas, muitas técnicas vem sendo testadas.

Neste capítulo são abordados aspectos relacionados ao Reconhecimento de Padrões; são descritos classificadores de padrões estatísticos convencionais; e, em seguida, classificadores neurais. Quanto às citações, além das apresentadas neste capítulo quando devidas, tomou-se como base para escrita os livros de KOHONEN (2001), HAYKIN (1999), KOSKO (1992) e o artigo de JAIN, DUIN e MAO (2000).

### **3.1 Conceitos Gerais**

As técnicas de Reconhecimento de Padrões têm um vasto leque de aplicações em um grande número de áreas científicas e tecnológicas, principalmente no projeto e desenvolvimento de sistemas inteligentes, que constituem o cerne do investimento tecnológico atual. Um padrão de teste ou simplesmente padrão é definido como uma entidade numérica, a qual poderia ser dada um rótulo, tal como, uma imagem de impressão digital, um sinal de um eletrocardiograma, uma face ou uma patologia humana, ou qualquer tipo de medida que necessite ser classificada.

O poder computacional disponível no momento permite processar dados mais rapidamente, facilitando também o uso de métodos sofisticados e bastante diversos para a análise e a classificação de dados. Ao mesmo tempo, as demandas em sistemas de reconhecimento de padrões automáticos estão aumentando bastante devido à disponibilidade

de bases de dados grandes e de exigências de desempenho restritas (velocidade, exatidão e custo). Nenhuma técnica para classificação pode ainda ser considerada completa ou ótima, sendo necessário muitas vezes combinar os vários métodos, o que atualmente tem sido uma prática bastante usada, constituindo assim os chamados sistemas inteligentes híbridos. O projeto de um sistema de reconhecimento de padrões envolve essencialmente os seguintes aspectos:

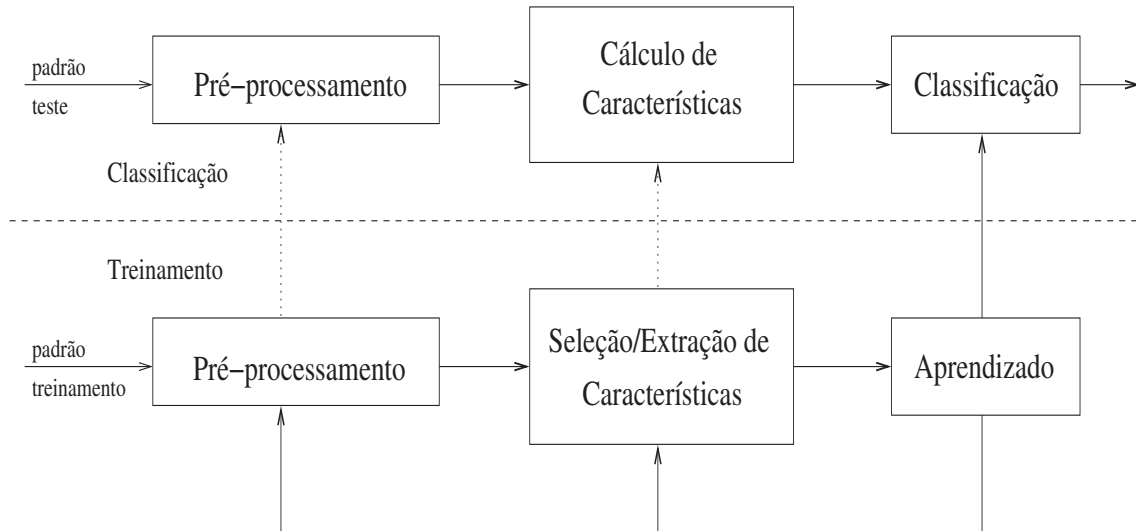
1. aquisição e pré-processamento de dados;
2. representação de dados;
3. tomada de decisão (a qual classe um padrão em teste pertence).

O domínio do problema dita a escolha da técnica de pré-processamento, do esquema de representação e do modelo da tomada de decisão. Concorda-se, em geral, que um problema bem definido e suficientemente restrito nas tarefas de reconhecimento são descritos como aquele em que as amostras apresentam variações pequenas para padrões da mesma classe (variação intra-classe) e variações grandes entre padrões de classes distintas (variação inter-classes), logo conduzindo a uma representação compacta das amostras e a uma estratégia simples para a tomada de decisão.

A representação de um padrão ou vetor  $\mathbf{x} = (x_1, x_2, x_3, \dots, x_d)^T$  é dado por um conjunto de  $d$  características ou atributos, e pode ser visto como um ponto (ou vetor) no espaço  $d$ -dimensional. O objetivo da área de reconhecimento de padrões é a escolha das características, que pertencem aos vetores, que possam diferenciar os padrões em regiões compactas e separadas por classe em um espaço característico  $d$ -dimensional, daí então considerar o vetor  $\mathbf{x}$  pertencente a uma classe  $W$  (em  $W_1, W_2, \dots, W_c$ ) baseado nos valores de suas  $d$  características. A eficácia do espaço de representação (conjunto de características) é determinado por quão bem os padrões de diferentes classes possam ser separados. A extração do conhecimento de um conjunto de exemplos é um atributo importante e desejado para os sistemas de reconhecimentos de padrões, que a partir desse processo, podem realizar a tomada de decisão.

Um processo típico de reconhecimento de padrões pode ser descrito diagramaticamente pela Figura 3.1.

O papel do módulo de pré-processamento tem por objetivo remover ruídos, normalizar padrões, ou qualquer outra operação que contribuir na definição das amostras de uma forma compacta. No modo de treinamento, o módulo de extração/seleção de caracterís-



**Figura 3.1:** modelo para o reconhecimento (semi-)automático de padrões.

ticas busca as características apropriadas para representar os padrões de entrada, já o classificador treinado é usado para dividir o espaço de características, para que no modo de classificação este seja capaz de determinar a qual classe um dado vetor ou padrão de entrada pertence.

Classificadores de padrões podem ser classificados quanto a forma de aprendizado, em supervisionados, em que os padrões no treinamento apresentam-se com seus rótulos (*labels*) que indicam a qual classe os padrões pertencem, ou não-supervisionados em que no treinamento não se usa ou não se dispõe dos rótulos para o aprendizado e o número número de classes muitas vezes deve ser também determinado (WATANABE, 1985).

Uma outra forma de classificá-los pode ser baseada na forma como se determina a fronteira de decisão, diretamente através de aproximação geométrica ou indiretamente baseada na densidade de probabilidade. Na aproximação probabilística é necessário que se estime primeiro as funções de densidade, e, em seguida, construa as funções discriminantes que especificam os limites de decisão. No caso da aproximação geométrica, os limites de decisão são determinados diretamente pela otimização de uma função custo.

Um número de regras de decisão bem conhecidas, incluindo a regra de decisão de Bayes, a regra de probabilidade máxima (que pode ser considerada um caso particular da regra de Bayes), como exemplo, permitem definir a fronteira ou limite de decisão. Outros algoritmos definem diretamente essa fronteira, como as redes Perceptron Multicamadas, outras baseiam em medidas de similaridade como a rede SOM. Em seguida, são descritas as características gerais no processo de classificação e alguns algoritmos que são aplicados ao problema proposto.



## 3.2 Classificadores de Padrões

Um classificador é um elemento de software capaz de atribuir uma amostra, cuja classe é a princípio desconhecida, a uma classe dentro de um conjunto de finitas possibilidades. Na prática, a escolha de um classificador é uma tarefa difícil e a tomada de decisão sobre qual classificador utilizar é, muitas vezes, baseada na disponibilidade do algoritmo, ou se este classificador já é de conhecimento do usuário, porém, a escolha correta deve-se basear em experimentações com vários classificadores, para que se possa utilizar o que se apresenta mais apropriado para certo tipo de problema ou aplicação.

Em nenhuma das técnicas de classificação ou tomada de decisão usada, deve-se utilizar todas as amostras disponíveis. É sabido que o desempenho de um classificador depende do número de amostras no treinamento e dos valores específicos das amostras. Ao mesmo tempo, deve-se analisar a generalização do conhecimento adquirido, pois, o objetivo de projetar um sistema de reconhecimento é classificar as amostras futuras que são provavelmente diferentes das amostras usadas no treinamento. Conseqüentemente, a otimização de um classificador para maximizar seu desempenho no conjunto de treinamento, pode não resultar no desempenho desejado para os dados de teste. A capacidade de generalização de um classificador refere-se a seu desempenho em classificar os padrões de teste que não são usados durante o estágio de treinamento.

Uma baixa capacidade de generalização de um classificador pode ser atribuída a qualquer dos seguintes fatores:

1. número de características grande em relação ao número das amostras de treinamento (JAIN; CHANDRASEKARAN, 1982);
2. número grande de parâmetros desconhecidos associados com o classificador (por exemplo, classificador polinomial ou uma rede neural grande);
3. classificador com grande capacidade de classificar para o conjunto de treinamento e baixa capacidade para o conjunto de teste, denominado sobreajuste (*overfitting*).

De uma forma geral, podem ser descritos três técnicas para o projeto de classificadores tomando-se como base medidas de similaridade, estimativa das funções de densidade probabilidade ou a minimização de um critério (como por exemplo o de erro).

### 3.2.1 Projeto de classificadores

A técnica mais simples e intuitiva no projeto do classificador é baseada no conceito de similaridade, ou seja, as amostras do grupo de teste que são similares devem ser classificadas como pertencentes a uma mesma classe. A utilização dessa técnica depende de uma métrica que deve ser estabelecida para definir similaridade, padrões podem ser classificados por comparação entre modelos/exemplos ou minimização de distâncias. A escolha da métrica e dos protótipos é crucial para o sucesso desta técnica. No classificador que mede proximidade, usando por exemplo a distância euclidiana como métrica, cada classe do grupo de teste é representada por um único protótipo que é o valor médio de todos os padrões de treinamento para essa classe.

Técnicas mais avançadas para definição de protótipos baseiam-se na quantização de vetores (OEHLER; GRAY, 1995)(XIE; LASZLO; WARD, 1993), no aprendizado por quantização vetorial (*Learning Vector Quantization - LVQ*) e nos métodos de redução de dados. Uma técnica mais simples, a regra do um vizinho mais próximo (*One-Nearest Neighbor, 1-NN*), pode ser convenientemente usada como ferramenta de comparação para todos os outros classificadores, já que o desempenho de classificação apresenta-se satisfatório para muitas aplicações, e não necessitar que qualquer parâmetro seja especificado.

O segundo conceito usado para projetar classificadores é baseado em uma abordagem probabilística. Nesta técnica, a probabilidade à posteriori  $P(W_i|x)$ , que pode ser entendida como a probabilidade de uma nova amostra  $x$  pertencer a uma respectiva classe  $W_i$ , pode ser utilizada para o cálculo da regra de Bayes ótima, desde que as probabilidades à priori  $p(W_i)$  sejam conhecidas ( senão, podem ser calculadas por  $p(W_1) = N_1/N$ ,  $p(W_2) = N_2/N, \dots, p(W_c) = N_c/N$ , em que  $N$  denota o número total de amostras e  $N_i$  o número de amostras da  $i$ -ésima classe). Uma outra medida, que se supõe ser conhecida, é a função densidade de probabilidade condicional (probability density function, pdf) da classe  $p(x|W_i)$ , que descreve a distribuição dos vetores característicos em cada uma das classes. Uma forma muito comum de denominar a pdf  $p(x|W_i)$  é função de verossimilhança. Definido os conceitos e com base na regra de Bayes, para calculo da probabilidade à posteriori, dada por

$$P(W_i|x) = \frac{p(x|W_i)P(W_i)}{p(x)} \quad (3.1)$$

pode-se obter a maior probabilidade à posterior (maximum a posteriori probability, regra MAP) através da Equação (3.2).

$$W_c = arg \max_{\forall i} \{P(W_i|x)\}, \quad (3.2)$$

Com a maior probabilidade à posteriori pode-se determinar a classe a qual determinado padrão pertence. Das suposições feitas, vale ressaltar que, normalmente a densidade condicional das classes ou alguns dos seus parâmetros são desconhecidos e devem ser aprendidas dos padrões de treinamento disponíveis. Neste caso, tem-se um problema de decisão paramétrico e uma estratégia comum para este tipo de problema consiste em substituir os parâmetros desconhecidos por seus valores estimados, resultando então no chamado classificador *plug-in*.

A terceira categoria de classificadores se refere aos que conseguem construir as fronteiras ou limites de decisão diretamente pela otimização de certos critérios, tal como a medida do erro de classificação. A força que direciona o processo de treinamento é normalmente baseado na minimização de um critério como o erro de classificação aparente ou o erro quadrático médio (*mean squared error - MSE*) entre a saída do classificador e a saída desejada, cujo exemplo clássico desse classificador é o Discriminate Linear de Fisher.

A seguir descrevem-se, formalmente, alguns classificadores que são aplicados na tarefa de classificação de patologias da coluna vertebral, tais como: Discriminante Linear, Discriminante Quadrático, *Naive-Bayes*, K-Vizinhos mais Próximos, Perceptron Multicamadas (MLP), *Self Organizing Map*(SOM) e GRNN (*General Regression Neural Network*). Estes classificadores são diferentes em estrutura, configuração de parâmetros iniciais, forma de aprendizado, critério de parada, dentre outras coisas. Assim, a forma de avaliação e os valores que os configuram são apresentados junto com os resultados no capítulo 5.

### 3.3 Classificadores Baseados em Estatística

Algoritmos estatísticos clássicos são apresentados e aplicados ao problema proposto, pois, tais técnicas que se baseiam em distribuição de probabilidade e função de verossimilhança têm forte embasamento matemático e aplicação prática. Destes classificadores pertencem: Discriminante Linear, Discriminante Quadrático, *Naive-Bayes* e K-Vizinhos mais Próximos.

#### 3.3.1 Discriminantes

Discriminante é um algoritmo estatístico que se baseia em considerações de distribuições de probabilidade. Supõe-se que os vetores de atributos para exemplos da classe

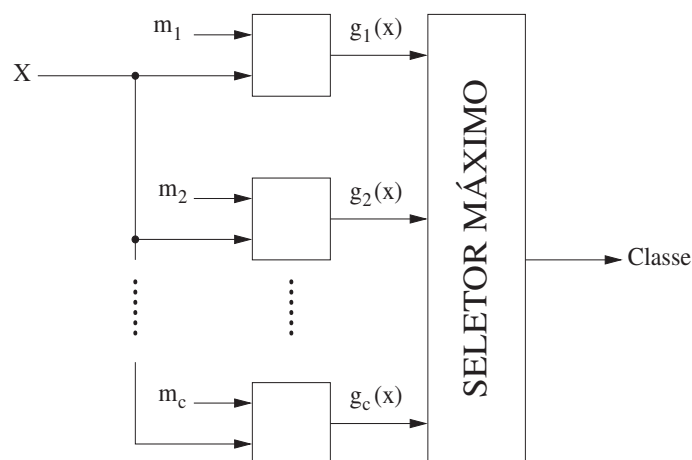
$W_i$  são independentes e seguem uma certa distribuição de probabilidade como a função de densidade de probabilidade (probability density function - pdf). Um vetor de atributos  $\mathbf{x}$  é atribuído então à classe para qual a função de densidade de probabilidade é maior.

Uma suposição freqüentemente feita é que as distribuições são normais (ou gaussianas), com diferentes médias e com mesma matriz de covariância para as classes (pode-se optar também por uma matriz de covariância por classe). A definição de uma única matriz de covariância resulta em um discriminante linear, enquanto a definição de uma matriz de covariância por classe define um discriminante quadrático. Deve-se ressaltar que os discriminantes, aqui apresentados, são classificadores estatísticos importantes pois são os classificadores mais utilizados, uma descrição deles é vista a seguir.

### 3.3.1.1 Discriminante Linear

Um discriminante linear é baseado na maximização da função densidade de probabilidade para um vetor-característica<sup>1</sup>  $x$ , o que significa minimizar a distância entre este e os protótipos  $\mu_1, \mu_2, \dots, \mu_c$  de cada classe.

Uma maneira útil de interpretar funções discriminantes lineares se dá através do conceito de produto-interno, pois, pode-se afirmar que as funções discriminantes lineares medem a correlação entre  $\mathbf{x}$  e  $\mathbf{m}_i$ , adicionada de um termo de correção (regularização) que penaliza valores elevados da norma  $\|\mathbf{m}_i\|^2$  do vetor-protótipo correspondente. Com esta correção incluída, um classificador de distância-mínima é equivalente a um classificador de correlação-máxima (Figura 3.2).



**Figura 3.2:** classificador de correlação-máxima.

<sup>1</sup>Os atributos ou características da amostra.

O critério de minimização permite atribuir um vetor  $\mathbf{x}$  à classe do protótipo mais próximo. Para um dado padrão  $\mathbf{x}$ , a distância Mahalanobis entre  $\mathbf{x}$  e um dado protótipo  $\mathbf{m}_i$  é dado por

$$d_i = \sqrt{(\mathbf{x} - \mu_i)^T \tilde{\mathbf{C}}_i^{-1} (\mathbf{x} - \mu_i)}. \quad (3.3)$$

em que  $\tilde{\mathbf{C}}_i$  é a matriz de covariância e  $\mu_i$  e a média das amostras da  $i$ -ésima classe. A matriz de covariância é melhor descrita como um conjunto de coeficientes da função de densidade e probabilidade ou um conjunto de parâmetros para a distribuição. Isto significa que os padrões para as classes são distribuídos em um agrupamento (*cluster*) centrado em  $\mu_i$  da forma elipsoidal descrita por  $\tilde{\mathbf{C}}_i$ . Cada agrupamento tem a mesma orientação e dispersão apesar das médias serem obviamente diferentes. Em classificação a distribuição correta é normalmente desconhecida, logo, é necessário estimar os parâmetros para as distribuições com base nas amostras disponíveis, sendo a matriz de covariância estimada  $\tilde{\Sigma}_i$  e a média estimada  $\mathbf{m}_i$ .

Analisando a Equação 3.3 e diante da suposição de que todos os grupos de padrões (*clusters*) em todas as  $c$  classes têm a mesma matriz de covariância, ou seja,

$$\tilde{\mathbf{C}}_1 = \tilde{\mathbf{C}}_2 = \dots = \tilde{\mathbf{C}}_c = \tilde{\mathbf{C}}, \quad (3.4)$$

de forma que, pode-se expandir o quadrado da distância de Mahalanobis de um padrão  $\mathbf{x}$  para o protótipo  $\mathbf{m}_i$ , de onde é possível obter a seguinte expressão

$$\begin{aligned} g_i(\mathbf{x}) &= (\mathbf{x} - \mathbf{m}_i)^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{m}_i) \\ &= (\mathbf{x} - \mathbf{m}_i)^T [\mathbf{C}^{-1} \mathbf{x} - \mathbf{C}^{-1} \mathbf{m}_i] \\ &= \mathbf{x}^T \mathbf{C}^{-1} \mathbf{x} - \mathbf{x}^T \mathbf{C}^{-1} \mathbf{m}_i - \mathbf{m}_i^T \mathbf{C}^{-1} \mathbf{x} + \mathbf{m}_i^T \mathbf{C}^{-1} \mathbf{m}_i \\ &= -2[\mathbf{m}_i^T \mathbf{C}^{-1} \mathbf{x} - \frac{1}{2} \mathbf{m}_i^T \mathbf{C}^{-1} \mathbf{m}_i] + \mathbf{x}^T \mathbf{C}^{-1} \mathbf{x}, \end{aligned} \quad (3.5)$$

em que se nota que o termo  $\mathbf{x}^T \mathbf{C}^{-1} \mathbf{x}$  é o mesmo para todas as classes, não influenciando no valor final do discriminante. Este resultado tem forma similar à expressão obtida para um classificador de distância euclidiana mínima expressa na seguinte equação

$$\begin{aligned} g_i(\mathbf{x}) &= \mathbf{w}_i^T \mathbf{x} + b_i \\ &= \mathbf{m}_i^T \mathbf{x} - \frac{1}{2} \mathbf{m}_i^T \mathbf{m}_i. \end{aligned} \quad (3.6)$$

Assim, pode-se novamente obter uma função discriminante linear maximizando-se a expressão entre colchetes na Equação (3.5), resultando em

$$g_i(\mathbf{x}) = \mathbf{m}_i^T \mathbf{C}^{-1} \mathbf{x} - \frac{1}{2} \mathbf{m}_i^T \mathbf{C}^{-1} \mathbf{m}_i = \mathbf{w}_i^T \mathbf{x} + b_i, \quad (3.7)$$

em que pode-se verificar a matriz de covariância  $\mathbf{C}$  no termo do vetor de pesos  $\mathbf{w}_i = (\mathbf{m}_i^T \mathbf{C}^{-1})^T$  e no *bias*  $b_i = -\frac{1}{2} \mathbf{m}_i^T \mathbf{C}^{-1} \mathbf{m}_i$ .

O discriminante linear é muito útil, pois, embora ele não possua a vantagem de ter uma superfície de decisão não-linear, ele tem a seu favor o fato de ser invariante à transformações lineares. Além disso, este tal discriminante reduz os requisitos de memória, necessários para armazenar uma matriz de covariância  $d \times d$ , para os requisitos necessários para armazenar  $C$  vetores  $\mathbf{w}_i$ ,  $i = 1, \dots, C$  de dimensão  $d \times 1$ , aumentando a velocidade do cálculo das funções discriminantes.

Na prática, a matriz  $\mathbf{C}$  é estimada pela matriz agregada  $\mathbf{S}_{pool}$  mostrada na equação

$$\mathbf{S}_{pool} = \sum_{i=1}^c \frac{N_i}{N} \hat{\Sigma}_i \quad (3.8)$$

em que  $N$  representa o número total de amostras e  $N_i$  o número total de amostras da  $i$ -ésima classe, o que confere uma maior confiabilidade à estimativa da matriz de covariância, conforme discutido na Seção 3.3.1.3.

### 3.3.1.2 Discriminate Quadrático

O discriminante quadrático é similar ao discriminante linear, mas o limite entre duas regiões é agora uma superfície quadrática. Quando a suposição de igualdade para as matrizes de covariância é eliminada, no argumento da probabilidade máxima com distribuições normais, uma superfície quadrática (por exemplo, elipsoidal, hiperboloidal, etc..) é obtida. Este tipo de discriminante pode tratar das classificações em que o conjunto de padrões de uma determinada classe está cercado de alguma forma padrões de outra classe.

Entretanto, o número de parâmetros a ser estimados torna-se maior e as diferenças entre as variâncias precisam ser consideradas para justificar o uso deste método, especialmente para conjunto de dados de tamanho pequeno ou moderado (Marca & Dunn, 1974). Ocasionalmente, as diferenças nas covariâncias são apenas de escala e algumas simplificações podem ocorrer (Kendall et al., 1983).

Analisando a Equação 3.3 e diante da suposição de que todos os grupos de padrões em todas as classes  $c$  têm a matrizes de covariância diferentes, ou seja,

$$\tilde{\mathbf{C}}_1 \neq \tilde{\mathbf{C}}_2 \neq \dots \neq \tilde{\mathbf{C}}_c, \quad (3.9)$$

de forma que, pode-se expandir o quadrado da distância de Mahalanobis de um padrão  $\mathbf{x}$  para o protótipo  $\mathbf{m}_i$ , similarmente a Equação (3.5), de onde é possível obter a seguinte expressão

$$g_i(\mathbf{x}) = \mathbf{m}_i^T \mathbf{C}_i^{-1} \mathbf{x} - \frac{1}{2} \mathbf{m}_i^T \mathbf{C}_i^{-1} \mathbf{m}_i - \frac{1}{2} \mathbf{x}^T \mathbf{C}_i^{-1} \mathbf{x} = \mathbf{x}^T \mathbf{w}_i \mathbf{x} + a_i^T \mathbf{x} + b_i, \quad (3.10)$$

em que se nota que o termo  $\mathbf{x}^T \mathbf{C}_i^{-1} \mathbf{x}$  agora não é o mesmo para todas as classes, diferente do que acontece com o discriminante linear, assim, influenciando no valor final para o discriminante. Assim, pode-se novamente obter uma função discriminante, em que se pode verificar a matriz de covariância  $\mathbf{C}_i$  no termo do vetor de pesos  $\mathbf{w}_i = -\frac{1}{2} \mathbf{C}_i^{-1}$ , no  $\mathbf{a}_i = \mathbf{m}_i^T \mathbf{C}_i^{-1}$  e no *bias*  $b_i = -\frac{1}{2} \mathbf{m}_i^T \mathbf{C}_i^{-1} \mathbf{m}_i$ .

O discriminante quadrático apresenta a vantagem de apresentar uma fronteira de decisão não-linear. Porém nota-se que existe um custo significativo para o cálculo da matriz de covariância. Além disso, o problema mais comum para ele é a ocorrência de algum atributo com variância igual a zero em uma das classes, no que resulta a impossibilidade de inverter a matriz de covariância. Uma forma de evitar este problema é adicionar aos elementos da diagonal da matriz valores constantes (pequenos e positivos). Isto corresponde a adição de ruído aleatório para os atributos. Uma outra forma é adotar uma combinação entre as matrizes de covariâncias das classes e a matriz *pooled*.

### 3.3.1.3 Regularização

Basicamente, existem poucas opções para se obter uma boa estimativa da matriz de covariância, que são: assumir que as características são estatisticamente independentes; que a matriz de covariância usada pelo discriminante é a mesma para todas as classes e usar o método de regularização proposto por FRIEDMAN (1989).

A primeira forma de estimativa, devido a suposição de independência estatística das características, resulta em uma matriz de covariância diagonal, na qual os elementos da diagonal principal são as variâncias de cada um dos  $d$  atributos, ou seja:

$$\mathbf{C} = \begin{pmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_d^2 \end{pmatrix} \quad (3.11)$$

em que as variâncias individuais  $\sigma_j^2$  são facilmente estimadas por meio da Equação (3.12).

$$\sigma_j^2 \approx \frac{1}{N-1} \sum_{k=1}^N (x_j - m_j)^2, \quad j = 1, \dots, d \quad (3.12)$$

$$m_j = E[x] \approx \frac{\sum_{k=1}^N x_j}{K} \quad (3.13)$$

Esta abordagem é utilizada pelo *Classificador Naive-Bayes* (WEBB, 2002). Infelizmente, a suposição de independência é muito forte e difícil de se encontrar na prática. De qualquer modo, se os atributos envolvidos no projeto do classificador forem gaussianos, técnicas de decorrelação podem ser aplicadas aos dados, resultando em atributos independentes.

A segunda forma é assumir que o discriminante é a mesmo para todas as classes. Em geral, define-se uma matriz de covariância agregada, que leva em consideração a matriz de covariância estimada de cada classe  $\hat{\Sigma}_i$  que pode ser visualizada na Equação 3.8. Esta abordagem é particularmente interessante se o número de classes é elevado.

E por último, usar o método de regularização proposto por Friedman (FRIEDMAN, 1989) como um meio de evitar a degradação do desempenho do discriminante gaussiano quadrático para conjunto de dados com poucos vetores e com dimensão elevada. De modo mais específico, a matriz de covariância estimada da  $i$ -ésima classe  $\hat{\Sigma}_i$  é substituída por uma matriz  $\hat{\Sigma}_i^\lambda$ , construída a partir da combinação linear de  $\hat{\Sigma}_i$  com a matriz agregada  $\mathbf{S}_{pool}$  dada por

$$\hat{\Sigma}_i^\lambda = \frac{(1-\lambda)\mathbf{S}_i + \lambda\mathbf{S}}{(1-\lambda)n_i + \lambda n}, \quad (3.14)$$

em que  $0 \leq \lambda \leq 1$ ,  $\mathbf{S}_i = n_i \hat{\Sigma}_i$  e  $\mathbf{S} = n \mathbf{S}_{pool}$ . Perceba que para os valores extremos de  $\lambda = 0$  e  $\lambda = 1$  chega-se às estimativas da matriz de covariância que levam ao discriminante gaussiano quadrático e discriminante gaussiano linear, respectivamente

$$\hat{\Sigma}_i^\lambda = \begin{cases} \hat{\Sigma}_i, & \lambda = 0 \\ \mathbf{S}_{pool}, & \lambda = 1. \end{cases} \quad (3.15)$$

O melhor valor do parâmetro  $\lambda$  para um determinado conjunto de dados a classificar é encontrado experimentalmente, ou seja, pelo método de tentativa e erro.

### 3.3.2 Classificador *Naive Bayes*

O classificador Bayes Ingênuo, do inglês *Naive Bayes*, largamente utilizado, baseia-se na suposição da independência condicional entre os dados de entrada e o rótulo da



classe (WEBB, 2002). Entendendo por dados de entrada  $\mathbf{x}$  e o rótulo  $W_i$ , sendo simplificado no seguinte modelo probabilístico

$$p(\bar{\mathbf{x}}|W_i) = \prod_{e=1}^d p(x_e|W_i). \quad (3.16)$$

Considerando  $\mathbf{x}$  uma variável contínua, pode-se concluir com base na Equação 3.16, que uma aproximação conveniente assume que,  $\mathbf{p}(\mathbf{x}|\mathbf{W}_i) = N(\mathbf{x}; \mu_{e,i}, \sigma_{e,i}^2)$  é a função de probabilidade para uma distribuição normal de  $\mathbf{x}$ . Neste caso, o treinamento significa aprender ou calcular os valores estimados para os parâmetros  $\mu_{e,i}$  e  $\sigma_{e,i}$  do conjunto de treinamento (JOHN; LANGLEY, 1995). Assim sendo, as amostras do conjunto de treinamento são separadas por grupos ou classes, e para cada conjunto de amostras de um determinada classe, os valores para  $\mu_{e,i}$  e  $\sigma_{e,i}$  são obtidos por atributo ou componente de cada vetor, aplicando-se a Equação 3.17. Ao final, são obtidos  $n$  valores para  $p(x_e|W_i)$ ,  $e = 1..d$ . Assim, a densidade condicional da classe  $p(x|W_i)$  para a  $i$ -ésima classe é obtida pelo produto desses valores, conforme descrito. A classe que resultar em maior valor para a densidade condicional é atribuída a amostra.

O cálculo de  $p(x_e|W_i)$  é dado pela equação

$$p(x_e|W_i) = \frac{1}{\sqrt{2\pi}\sigma_{e,i}} \cdot \exp \left\{ -\frac{(x_e - \mu_{e,i})^2}{2\sigma_{e,i}^2} \right\}, \quad e = 1, 2, \dots, d; \quad (3.17)$$

em que  $\sigma_{e,i}^2$  e  $\mu_{e,i}$  representam o desvio padrão e a média da  $e$ -ésima característica para a  $i$ -ésima classe, tal que  $e$  indica a componente do vetor para a classe  $W_i$ .

Para uma entrada de dados discreta, a densidade condicional da classe no lado direito da equação é especificado através da tabela de probabilidade condicional baseada na frequência de ocorrência para o conjunto de treinamento. Visto que a probabilidade estimada é baseada na frequência dos dados do treinamento, isto pode não ser confiável em regiões onde os dados de entrada se distribuem de forma esparsa.

### 3.3.3 Classificador $k$ - Vizinhos mais Próximos

Considerando-se um conjunto de dados rotulados, consistindo de  $N$  amostras, dados por  $D = x^1, x^2, \dots, x^N$ . Seja  $\mathbf{x}$  um padrão a ser classificado, que não pertence ao conjunto  $D$ , a idéia do algoritmo dos  $k$ -vizinhos mais próximos consiste em atribuir a mesma classificação para o padrão  $\mathbf{x}$  ao da classe mais representada nos  $k$  vizinhos mais próximos ou  $k$  ponto mais próximos. Em outras palavras, para classificar  $\mathbf{x}$  procuram-se as  $k$  amostras mais próximas pertencentes ao conjunto  $D$ . A classe mais frequente observada

é atribuída a  $\mathbf{x}$ . Este algoritmo baseia-se numa métrica ou função de distância entre dois padrões, quando  $k = 1$ , dada por

$$\min_e \{d(\mathbf{x} - x_{(e)}^{(i)})\} \leq \min_e \{d(\mathbf{x} - x_o^{(i)})\}, \quad \forall_{e \neq o}, \quad (3.18)$$

em que  $x_e^{(i)} \equiv e$ -ésimo padrão que pertence a classe  $W_i$ ; e  $d(.,.) \equiv$  medida de distância.

O cálculo da distância  $d(.,.)$ , contida na equação 3.18, pode ser feito de várias formas, porém a mais comumente utilizada é a norma  $L_2$ , também conhecida como distância euclidiana, dada por

$$L_2 = d_{euclidiana}(a, b) = \sqrt{\sum_{t=1}^d (a_t - b_t)^2}, \quad (3.19)$$

em que  $a_t$  e  $b_t$  representam as componentes dos padrões  $a$  e  $b$ .

Este classificador constrói diretamente a regra de decisão sem estimar as densidades condicionadas às classes, e a principal motivação para utilização deste algoritmo está em que, padrões próximos no espaço de características possivelmente pertencem a mesma classe.

## 3.4 Classificadores Baseados em Redes Neurais

A partir desta seção são descritos alguns algoritmos para classificação de padrões baseados em redes neurais artificiais.

### 3.4.1 Rede Perceptron Multicamadas


Tipicamente, uma rede neural Perceptron Multicamada (*Multilayer Perceptron*, MLP) é constituída de uma camada de entrada que recebe os vetores de atributos, e uma ou mais camadas intermediárias, compostas por neurônios somadores com função de ativação não-linear e uma camada de saída, também composta por neurônios somadores (que podem ser lineares ou não).

A rede contém uma ou mais camadas escondidas, aquelas que não fazem parte nem da entrada nem da saída, são essas camadas que tornam a rede capaz de extrair progressivamente as características mais significativas do espaço de entrada. Outra característica é que estas redes mostram um alto grau de conectividade, determinado pelas sinapses da rede, interligações entre os neurônios das diferentes camadas, em que cada uma delas está

associada a um valor numérico chamado peso sináptico.

Nas definições e cálculos mostrados a seguir, considera-se uma arquitetura de rede neural MLP com apenas uma camada escondida de neurônios, treinada com o algoritmo de retropropagação do erro (*Error Backpropagation*).

A arquitetura geral das redes supervisionadas, portanto também para o MLP, compostas de uma camada escondida e neurônios lineares na saída, pode ser vista na Figura 3.3. O vetor de pesos associado ao  $i$ -ésimo neurônio da camada escondida, também chamada



**Figura 3.3:** arquitetura geral de uma rede neural supervisionada.

de camada oculta ou camada intermediária, é representado como

$$\mathbf{w}_i = \begin{pmatrix} w_{i0} \\ \vdots \\ w_{in} \end{pmatrix} = \begin{pmatrix} \theta_i \\ \vdots \\ w_{in} \end{pmatrix}, \quad (3.20)$$

em que  $\theta_i$  é o limiar associado ao neurônio  $i$ . Os neurônios desta camada são chamados de neurônios escondidos por não terem acesso direto à saída da rede MLP, em que são calculados os erros de aproximação.

De modo semelhante, o vetor de pesos associado ao  $k$ -ésimo neurônio da camada de saída é representado como

$$\mathbf{m}_k = \begin{pmatrix} m_{k0} \\ \vdots \\ m_{kq} \end{pmatrix} = \begin{pmatrix} \theta_k \\ \vdots \\ m_{kq} \end{pmatrix}, \quad (3.21)$$

na qual  $\theta_k$  é o limiar associado ao neurônio de saída  $k$ .

#### 3.4.1.1 Treinamento da rede MLP

O treinamento da rede MLP se dá em dois sentidos: um direto e outro reverso.

No sentido direto, o funcionamento da rede MLP envolve o cálculo das ativações e saídas de todos os neurônios da camada escondida e de todos os neurônios da camada de saída. Assim, o fluxo de sinais (informação) se dá dos neurônios de entrada para os neurônios de saída, passando obviamente pelos neurônios da camada escondida. Por isso, diz-se que a informação está se propagando no sentido **direto**, ou seja,

Entrada  $\rightarrow$  Camada Intermediária  $\rightarrow$  Camada de Saída.

Assim, após a apresentação de um vetor de entrada  $\mathbf{x}$ , na iteração  $t$ , o primeiro passo a ser executado no treinamento é calcular as ativações dos neurônios da camada escondida

$$u_i(t) = \sum_{j=0}^n w_{ij}(t)x_j(t) = \mathbf{w}_i^T(t)\mathbf{x}(t), \quad i = 1, \dots, q \quad (3.22)$$

em que  $T$  denota a operação de transposição dos vetores e  $q$  indica o número de neurônios da camada escondida. Em seguida, as saídas correspondentes são calculadas por

$$v_i(t) = \varphi_i[u_i(t)] = \varphi_i \left[ \sum_{j=0}^p w_{ij}(t)x_j(t) \right] = \varphi_i [\mathbf{w}_i^T(t)\mathbf{x}(t)], \quad (3.23)$$

tal que a função de ativação  $\varphi$  assume geralmente uma das seguintes formas

$$\varphi_i[u_i(t)] = \frac{1}{1 + \exp[-u_i(t)]}, \quad (\text{Logística}) \quad (3.24)$$

$$\varphi_i[u_i(t)] = \frac{1 - \exp[-u_i(t)]}{1 + \exp[-u_i(t)]}, \quad (\text{Tangente Hiperbólica}). \quad (3.25)$$

O segundo passo consiste em repetir as operações das equações (3.22) e (3.23) para os neurônios da camada de saída

$$u_k(t) = \sum_{i=0}^q m_{ki}(t)v_i(t), \quad k = 1, \dots, m \quad (3.26)$$

na qual  $m \geq 1$  é o número de neurônios de saída.

Em seguida, as saídas dos neurônios da última camada são calculadas pela Equação

$$y_k(t) = \varphi_k[u_k(t)] = \varphi_k \left[ \sum_{i=0}^q m_{ki}(t)v_i(t) \right], \quad (3.27)$$

tal que a função de ativação  $\varphi_k$  assume geralmente uma das formas definidas nas equações (3.24) e (3.25).

No Sentido Reverso o funcionamento da rede MLP envolve o cálculo de gradientes

locais e o ajuste dos pesos de todos os neurônios da camada escondida e da camada de saída. Assim, o fluxo de informação se dá dos neurônios de saída para os neurônios da camada escondida. Por isso, diz-se que a informação está se propagando no sentido reverso, ou seja,

Camada de Saída  $\rightarrow$  Camada Escondida.

Assim, após os cálculos das ativações e saídas no sentido direto, o primeiro passo do sentido reverso consiste em calcular os gradientes locais  $\delta_k(t)$  dos neurônios da camada de saída

$$\delta_k(t) = e_k(t)\varphi'[u_k(t)], \quad k = 1, \dots, m \quad (3.28)$$

em que  $e_k(t)$  é o erro entre a saída desejada  $d_k(t)$  para o neurônio  $k$  e saída gerada por ele  $y_k(t)$

$$e_k(t) = d_k(t) - y_k(t). \quad (3.29)$$

A derivada  $\varphi'[u_k(t)]$  na equação 3.28 assume diferentes expressões, dependendo da escolha da função de ativação. Assim, tem-se as seguintes possibilidades

$$\varphi'_k[u_k(t)] = y_k(t)[1 - y_k(t)], \quad \text{se } \varphi_k[u_k(t)] \text{ é a função logística;} \quad (3.30)$$

$$\varphi'_k[u_k(t)] = \frac{1}{2}[1 - y_k^2(t)], \quad \text{se } \varphi_k[u_k(t)] \text{ é a tangente hiperbólica.} \quad (3.31)$$

O segundo passo do sentido reverso consiste em calcular os gradientes locais  $\delta_i(t)$  dos neurônios da camada escondida

$$\delta_i(t) = \varphi'_i[u_i(t)] \sum_{k=1}^m m_{ki}(t)\delta_k(t), \quad i = 1, \dots, q \quad (3.32)$$

tal que a derivada  $\varphi'[u_i(t)]$  é calculada da mesma forma que nas Equações (3.30) e (3.31).

O terceiro passo corresponde ao processo de atualização ou ajuste dos parâmetros (pesos sinápticos e limiares) da rede MLP com uma camada escondida. Assim, para a camada escondida tem-se que a regra de atualização dos pesos,  $w_{ij}$ , é dada por

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij}(t) \\ &= w_{ij}(t) + \eta \delta_i(t) x_j(t), \end{aligned} \quad (3.33)$$

em que  $\eta$  é a taxa de aprendizagem. E para camada de saída tem-se que a regra de atualização dos pesos  $m_{ki}$  é dada por

$$m_{ki}(t+1) = m_{ki}(t) + \Delta m_{ki}(t)$$

$$= m_{ki}(t) + \eta \delta_k(t) y_i(t). \quad (3.34)$$

### 3.4.1.2 Utilização da rede MLP em classificação de padrões

Nos problemas de classificação, a escolha do número de neurônios e da faixa de valores para as suas saídas na camada de saída tem fundamental importância, podendo melhorar substancialmente o desempenho da rede, pois, a partir desse ponto a rede rotula os padrões. Como exemplo podem-se citar a representação para uma classificação em que estejam envolvidas 3 classes distintas  $w_1, w_2$  e  $w_3$ , exemplificada pelas estratégias: um único neurônio na camada de saída com função de ativação hiperbólica, número de neurônios igual ao número de classes com função de ativação hiperbólica ou logística.

Usar 1(um) neurônio na camada de saída (com função de ativação Hiperbólica), o qual pode assumir valores para sua saída no intervalo  $[-1, +1]$ , assim sendo, no treinamento da rede os rótulos dos padrões receberão os valores -1 , 0 ou 1 para as classes  $w_1, w_2$  e  $w_3$ , respectivamente. Na classificação, aplica-se um arredondamento para o valor de saída  $y_1(t)$ , obtendo-se então três possíveis valores -1 , 0 ou 1 e se fazendo em seguida a associação a classe  $w_1, w_2$  ou  $w_3$  de acordo com o respectivo valor de saída.

Usar tantos neurônios (com função de ativação Hiperbólica) quantos são os números de classes na camada de saída, nesse caso três. Sendo que cada saída  $y_k(t)$  desses neurônios podem assumir valores para sua saída no intervalo  $[-1, +1]$ . No treinamento assume-se os rótulos

$$w_1 = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = \begin{pmatrix} +1 \\ -1 \\ -1 \end{pmatrix}, \quad (3.35)$$

$$w_2 = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = \begin{pmatrix} -1 \\ +1 \\ -1 \end{pmatrix}, \quad (3.36)$$

$$w_3 = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = \begin{pmatrix} -1 \\ -1 \\ +1 \end{pmatrix}, \quad (3.37)$$

em que verifica-se que a classe do padrão é  $w_j$ ,  $j$  é o índice em que o valor na representação assume o maior valor. O rótulo do padrão na classificação terá valor +1 para a saída  $y_k(t)$

que possuir maior valor e  $-1$  para as outras. Na classificação de forma similar, atribuindo-se a classe  $w_j$  para o padrão de teste, em que  $j$  é o índice de maior valor entre as saídas.

Usar tantos neurônios (com função de ativação Logística) quantos são os números de classes na camada de saída, nesse caso três. Sendo que cada saída  $y_k(t)$  desses neurônios podem assumir valores para sua saída no intervalo  $[0, 1]$ . No treinamento assume-se os rótulos

$$w_1 = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, \quad (3.38)$$

$$w_2 = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, \quad (3.39)$$

$$w_3 = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}, \quad (3.40)$$

em que verifica-se que a classe do padrão é  $w_j$ ,  $j$  é o índice em que o valor na representação assume o maior valor. O rótulo do padrão na classificação terá valor 1 para a saída  $y_k(t)$  que possuir maior valor e 0 para as outras saídas. Na classificação de forma similar, atribuindo-se a classe  $w_j$  para o padrão de teste, em que  $j$  é o índice de maior valor entre as saídas. Nesse caso particular, pode-se fazer uma análise estatística já que as saídas para cada neurônio  $k$  representam a probabilidade à posteriori do padrão de pertencer a classe  $w_k$ , logo quando se determina um padrão pertencente a classe de maior valor, utiliza-se da regra de Bayes para a tomada de decisão.

### 3.4.2 Classificador Baseado na Rede Auto-Organizável de Kohonen

Na rede neural Auto-Organizável de Kohonen (*Self-Organizing Map*, SOM), proposto por Kohonen (KOHONEN, 2001), durante a fase de treinamento o neurônio vencedor e os neurônios em sua vizinhança (conjunto de neurônios que estão em torno do neurônio vencedor  $i^*(t)$ ) têm seus vetores de pesos  $\mathbf{w}_{i^*}(t)$  atualizados em resposta a um dado vetor de entrada  $\mathbf{x}(t)$ . Os neurônios para esta rede estão dispostos em uma grade fixa, bi-dimensional, de modo que se possa definir uma relação de vizinhança espacial entre neurônios desta grade. O treinamento da rede SOM é resumido a seguir

1. seleção aleatória de um exemplo de treinamento  $\mathbf{x}(t)$  como vetor de entrada atual.
2. busca pelo neurônio vencedor  $i^*(t)$  para o vetor de entrada  $\mathbf{x}(t)$ , dado por

$$i^*(t) = \arg \min_{\forall i} \{\|\mathbf{x}(t) - \mathbf{w}_i(t)\|\}. \quad (3.41)$$

3. atualização do vetor de pesos do neurônio vencedor  $\mathbf{w}_i^*(t)$  pela equação

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t) + \eta(t)h(i^*, i; t)[\mathbf{x}(t) - \mathbf{w}_i(t)], \quad (3.42)$$

em que  $0 < \eta < 1$  denota o passo de aprendizagem,  $h(i^*, i; t)$  a função de vizinhança, geralmente do tipo gaussiana, ou seja,

$$h(i^*, i; t) = \exp\left(-\frac{\|\mathbf{r}_i(t) - \mathbf{r}_{i^*}(t)\|^2}{\vartheta^2(t)}\right), \quad (3.43)$$

tal que  $\vartheta(t)$  define o raio de influência da função de vizinhança, enquanto  $\mathbf{r}_i(t)$  e  $\mathbf{r}_{i^*}(t)$  são, respectivamente, as posições dos neurônios  $i$  e  $i^*$  no arranjo geométrico da rede.

A função de vizinhança funciona como uma espécie de janela de ponderação, fazendo com que os neurônios mais próximos do neurônio vencedor atual, tenham seus vetores de pesos atualizados mais intensamente do que aqueles neurônios que estão mais distantes do neurônio vencedor. O neurônio vencedor tem seus pesos reajustados com maior intensidade, visto que para ele tem-se  $h(i^*, i; t) = 1$ . Para todos os outros neurônios, tem-se  $h(i^*, i; t) < 1$ .

Em geral, os valores iniciais dos pesos são atribuídos de forma aleatória e equiprovável dentro do intervalo  $[0, 1]$ . Alternativamente, os vetores de pesos iniciais podem ser selecionados a partir do próprio conjunto de vetores de treinamento.

A fim de aumentar a probabilidade de convergência do algoritmo para um mínimo global, é comum fazer com que o passo de aprendizagem decresça com o tempo. A rede competitiva adotada nesta dissertação, utiliza-se um decaimento exponencial dado por

$$\eta(t) = \eta_0 \left(\frac{\eta_T}{\eta_0}\right)^{(t/T)}, \quad (3.44)$$

tal que  $\eta_0$  e  $\eta_T$  ( $\eta_T \ll \eta_0$ ) são os valores inicial e final de  $\eta$ . A velocidade de decaimento é controlada pelo parâmetro  $T$ , que simboliza o número máximo de iterações de treinamento. E ainda, por questões de convergência e estabilização do aprendizado, a função de vizinhança deve decrescer no tempo, ou seja, o raio de influência  $\vartheta(t)$  decai com o






Figura 3.4: projeção implementada pela rede SOM.

decorrer do treinamento de modo semelhante à Equação (3.44)

$$\vartheta(t) = \vartheta_0 \left( \frac{\vartheta_T}{\vartheta_0} \right)^{(t/T)}, \quad (3.45)$$

tal que  $\vartheta_0$  e  $\vartheta_T$  ( $\vartheta_T \ll \vartheta_0$ ) são os valores inicial e final de  $\vartheta$ . Em suma, a equação (3.45) faz com que a vizinhança diminua com o passar das iterações de treinamento.

É importante enfatizar que se os neurônios da rede SOM estão dispostos em uma grade bidimensional, tem-se que  $\mathbf{r}_i(t) \in \mathbb{R}^2$ , ou seja, a posição de um neurônio  $i$  na grade é dada pelas coordenadas  $(x_i, y_i)$  em relação a uma origem pré-fixada. Neste caso, um neurônio pode ter vizinhos à esquerda, à direita, acima, abaixo e diagonalmente.

Em razão de sua arquitetura peculiar e de seu algoritmo de treinamento, a rede SOM implementa uma projeção não-linear  $\Phi$  do espaço de entrada contínuo  $\chi \subset \mathbb{R}^n$  (espaço dos dados), em um espaço de saída discreto  $\mathcal{A}$  conforme mostrado na Figura 3.4, representado pelo espaço das coordenadas dos neurônios na grade, tal que  $\dim(\mathcal{A}) \ll n$ . Matematicamente, esta projeção pode ser simbolizada por

$$\Phi: \chi \rightarrow \mathcal{A}. \quad (3.46)$$

A rede SOM tem tido grande utilização em aplicações de mineração de dados e reconhecimento de padrões. Grande parte do seu sucesso se deve à combinação de dois princípios essenciais de auto-organização de sistemas (VON DER MALSBERG, 2003): competição entre neurônios por recursos limitados, implementada pela Equação (3.41); e cooperação,

implementada pela função vizinhança. O resultado da atuação destes dois princípios na rede SOM é uma projeção  $\Phi$  que preserva relações de proximidade espacial entre os dados de entrada, ou seja, o mapeamento preserva a topologia do espaço de entrada no espaço de saída (HAYKIN, 1999), conforme ilustrado na Figura 3.4, na qual  $\dim(\chi) = n = 2$  e  $\dim(\mathcal{A}) = 1$ , os pontos pretos correspondem às coordenadas dos vetores de pesos do  $i$ -ésimo neurônio. Neurônios que são vizinhos estão conectados por linhas tracejadas.

Pode-se expressar a propriedade de preservação de topologia da rede SOM da seguinte forma: sejam  $\mathbf{x}_1$  e  $\mathbf{x}_2$  dois vetores no espaço de entrada  $\chi$ ,  $\mathbf{r}_{i_1^*}$  e  $\mathbf{r}_{i_2^*}$  as coordenadas dos neurônios vencedores para  $\mathbf{x}_1$  e  $\mathbf{x}_2$ , respectivamente. Diz-se que a rede SOM, corretamente treinada, preserva a topologia do espaço de entrada se a seguinte relação for observada

$$\|\mathbf{x}_1 - \mathbf{x}_2\| \rightarrow 0 \quad \Rightarrow \quad \|\mathbf{r}_{i_1^*} - \mathbf{r}_{i_2^*}\| \rightarrow 0 \quad (3.47)$$

ou seja, se quaisquer dois vetores estão fisicamente próximos no espaço de entrada, então eles terão neurônios vencedores espacialmente próximos na rede (HERTZ; KROGH; PALMER, 1991).

Devido à propriedade de preservação de topologia, a rede SOM é capaz de construir uma aproximação do espaço de entrada, ou seja, ela constrói uma aproximação discreta do espaço de entrada, na qual cada neurônio da rede representa uma determinada região do espaço de entrada que define sua região de atração ou campo receptivo. Esta região é conhecida também como célula de Voronoi. Assim, uma das principais aplicações da rede SOM é a categorização de dados não-rotulados em agrupamentos e sua posterior utilização na classificação de vetores de características que não estavam presentes durante o treinamento.

A propriedade de preservação de topologia permite à rede SOM fazer uma estimativa pontual da função densidade de probabilidade, o que significa que o mapeamento da rede SOM reflete variações na estatística do espaço de entrada, ou seja, regiões no espaço de entrada  $\chi$  nas quais as observações  $\mathbf{x}$  têm uma alta probabilidade de ocorrência, são povoadas com um maior número de neurônios, possuindo, conseqüentemente, uma melhor resolução do que regiões em  $\chi$  nas quais as observações  $\mathbf{x}$  são retiradas com baixa probabilidade de ocorrência.

### 3.4.2.1 Rede SOM em classificação de padrões

A rede neural SOM por apresentar um aprendizado não-supervisionada, geralmente não é utilizada para classificação de padrões mas essencialmente para descoberta de agru-

pamentos em dados. Neste trabalho, é implementada uma adaptação no algoritmo para possibilitar a utilização desta rede para fins de classificações de padrões.

Em tarefas de classificação, após a rede SOM treinada, uma estratégia possível a ser seguida é descrita: uma associação para cada padrão de treinamento e o seu respectivo protótipo (vencedor) é realizado, ao final deste processo estão associados  $k$  padrões a um determinado protótipo, em seguida atribui-se ao protótipo a classe com mais ocorrências dentre os  $k$  padrões associados. Quando um novo padrão é apresentado, a rede verifica qual o protótipo vencedor e atribui a esta amostra o rótulo determinado ao seu respectivo neurônio vencedor. Um problema desta estratégia é que pode ser que um novo padrão seja atribuído a um protótipo que não esteja associado a nenhuma amostra. Este contornado problema pode ser através da verificação dos rótulos dos protótipos em seus vizinhos e atribuir a nova amostra, apresentada a rede, a classe de maior ocorrência dentre esses protótipos vizinhos.

Uma outra estratégia que leva também em consideração informação global, não apenas do agrupamento, é descrita. A rotulação de agrupamentos para um *cluster* homogêneo (contendo apenas amostras de uma classe) continua da mesma forma, como descrita no parágrafo anterior, porém com agrupamentos heterogêneos, a rotulação é dada de uma forma diferente, para isso algumas definições devem ser apresentadas:

1. tendo  $X$  representando o número de amostras do tipo  $X$  no *cluster*  $i$ , e  $X_{total}$  sendo o número total de amostras de rótulo  $X$  no conjunto de treinamento, então a probabilidade de uma amostra do tipo  $X$  ser mapeada para um agrupamento  $i$  é dada por  $X_i/X_{total}$ ;
2. sendo  $N_i$  o número total de registros no agrupamento  $i$ , a probabilidade de uma amostra mapeada para um agrupamento  $i$  pertencer a um tipo  $X$  é dado por  $X_i/N_i$ ;
3. uma definição para um fator de preferência para um rótulo  $X$  como a relação entre a probabilidade de uma amostra do tipo  $X$  ser mapeada para um agrupamento  $i$  e a probabilidade de uma amostra mapeada para um *cluster*  $i$  pertencer a um tipo  $X$ , é dada por

$$F_i(x) = (X_i/X_{total}) (X_i/N_i), \quad (3.48)$$

tendo  $W = \{w_1, w_2, \dots, w_r\}$  representando o conjunto de rótulos que identificam todos as amostras mapeadas para o neurônio  $i$ , a definição para o rótulo de  $i$  é  $L(i) = w$ , em que  $F_i(w) = \max F_i(x)$ , e  $L(i)$  representa o rótulo do agrupamento  $i$ .

### 3.4.3 Rede Neural Genérica para Regressão

A Rede Neural Genérica para Regressão (*General Regression Neural Network*, GRNN), constitui-se de uma variação da rede de funções base radial (RBF), sendo utilizada principalmente para aproximar funções ou mapeamentos entrada-saída, e por esta característica também pode ser utilizada como um classificador.

A regressão de uma variável dependente  $y$  sobre uma variável independente  $x$  estima o valor mais provável de  $y$ , dado  $x$  e um conjunto de treinamento (que pode conter ou não ruído). As variáveis  $x$  e  $y$  são geralmente vetores, sendo que a variável independente  $x$  é o vetor de entrada e a variável dependente  $y$  é o vetor de saída. Podem-se então pensar em  $y$  para o problema de classificação como sendo a classe a qual se deseja determinar, para um dado padrão de teste, e em  $x$  como o vetor de características deste padrão.

#### 3.4.3.1 Sobre o Problema de Regressão Estatística

Seja a função  $f(x,y)$  que representa a densidade de probabilidade contínua de uma variável aleatória  $\mathbf{x}$  (vetor) relacionada a uma variável aleatória escalar  $y$ . Sendo  $\mathbf{X}$  um caso particular da variável aleatória  $x$ , a medida da probabilidade condicional de  $y$  baseado em  $X$ , também conhecida como regressão de  $y$  em  $X$ , é dada por

$$E[y|X] = \frac{\int_{-\infty}^{+\infty} y f(X, y) dy}{\int_{-\infty}^{+\infty} f(X, y) dy}. \quad (3.49)$$

Quando a densidade  $f(x, y)$  é desconhecida, ela deve ser estimada a partir das amostras observadas de  $x$  e  $y$ . Para uma estimativa não-paramétrica de  $f(x, y)$ , utilizam-se uma classe de estimadores não-paramétricos propostos por THOMPSON e TAPIA (1990) e que mostra ser aplicável ao caso multidimensional (CACOULLOS, 1966). Estes tipos de estimadores são uma boa escolha para se estimar a função densidade de probabilidade  $f$  já que se pode assumir que as densidades são contínuas e que a primeira derivada parcial da função avaliada para qualquer  $x$  é pequena (SPECHT, 1967).

O estimador de probabilidade  $\hat{f}(X, Y)$  é baseado em valores das amostras  $X^i$  e  $Y^i$  das variáveis aleatórias  $x$  e  $y$ , em que  $N$  é o número de amostras observadas e  $d$  é a dimensão do vetor  $\mathbf{x}$  e é dado pela expressão:

$$\hat{f}(X, Y) = \frac{1}{(2\pi)^{(d+1)/2} \sigma^{(d+1)}} \cdot \frac{1}{N} \sum_{i=1}^N \exp \left[ -\frac{(X - X^i)^T (X - X^i)}{2\sigma^2} \right] \cdot e \left[ -\frac{(Y - Y^i)}{2\sigma^2} \right]. \quad (3.50)$$

Substituindo a probabilidade  $\hat{f}(X, Y)$  dada pela Equação (3.50) na medida da probabilidade condicional na expressão na Equação (3.49), obtém-se a medida de probabilidade condicional desejada de  $y$  dado um  $X$ . Em particular, combinando-se as Equações (3.50) e (3.49), a medida condicional desejada, designada por  $\hat{Y}(X)$  resulta em

$$\hat{Y}(X) = \frac{\sum_{i=1}^N Y^i \exp\left(-\frac{D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^N \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (3.51)$$

em que a função escalar  $D_i^2$  é dada por,

$$D_i^2 = (X - X^i)^T (X - X^i). \quad (3.52)$$

A regressão resultante expressa na Equação (3.51), que envolve o somatório sobre as amostras, é diretamente aplicável a problemas envolvendo dados de classificação.

Os estimadores de densidade da forma da Equação (3.50) usados para estimar a probabilidade condicional através da Equação (3.49) pode ser substituída pela equação 3.51. Os estimadores como os descritos na Equação (3.51) são consistentes, pois estes convergem assintoticamente para a função densidade de probabilidade  $f(x, y)$  para todos os pontos  $(x, y)$  na qual a função densidade é contínua (THOPSON; TAPIA, 1990; CACOULOS, 1966).

Os estimadores  $\hat{Y}(X)$  podem ser vistos como a média ponderada de todos os valores das amostras observadas  $Y^i$ , em que cada valor observado cresce exponencialmente de acordo com a distância Euclidiana de  $X$ . Quando o parâmetro de suavização  $\sigma$  é grande, a densidade estimada suavizada torna-se uma Gaussiana multivariada com covariância  $\sigma^2 I$ . Em outras palavras, para valores pequenos de  $\sigma$  a densidade estimada pode assumir formas não-Gaussianas, mas com o perigo de que amostras discrepantes tenham grande efeito na estimativa. E ainda, quando  $\sigma$  se torna grande,  $\hat{Y}(X)$  assume o valor da média das amostras observadas  $Y^i$ , e quando  $\sigma$  tende a zero,  $\hat{Y}(X)$  assume o valor de  $Y^i$  associado com a observação mais próxima de  $X$ .

Quando a distribuição é desconhecida, não é possível calcular o valor ótimo de  $\sigma$  para um dado número de observações  $N$ , então necessita-se encontrar o valor de  $\sigma$  de uma forma empírica. Isto pode ser feito facilmente quando há um critério natural que pode ser usado para avaliar cada valor de  $\sigma$ , a saber, o erro médio quadrático entre  $Y^j$  e a estimativa  $\hat{Y}(X^j)$ , em que  $j$  representa a observação atual. Para este propósito, a equação 3.51 deve ser modificada de forma que o  $j$ -ésimo elemento no somatório seja eliminado. Assim, cada  $\hat{Y}(X^j)$  é baseado na inferência de todas as amostras, exceto do valor da

observação atual  $X^j$ . Este processo é usado para evitar um erro mínimo artificial quando  $\sigma$  tende a zero. *Overfitting* dos dados também está presente na estimação dos mínimos quadrados em regressão de superfícies lineares, mas não é tão crítico porque a equação de regressão linear tem somente  $p+1$  graus de liberdade, e se  $n \gg p$  o fenômeno do *overfitting* é normalmente ignorado.

As variáveis  $Y$  e  $\hat{Y}$  podem ser vetoriais ou escalares. Neste caso, cada componente do vetor  $Y$  deve ser da mesma forma, com exceção logicamente da mesma observação. Observando a equação 3.51 verifica-se que o denominador do estimador e de todos os termos exponenciais não mudam para estimação vetorial.

Tem-se sugerido que melhores estimativas de densidade, usando janela de Parzen e conjunto de dados finitos, podem ser obtidos a partir do uso de um conjunto diferente de  $\sigma$ 's para cada exemplar. Variando-se o valor de  $\sigma$ , e em seguida para cada valor de  $\sigma$  particular, calcula-se a estimativa de probabilidade  $\hat{Y}$  baseado em todas as amostras (com exceção da apresentada) e se calcula o erro quadrático médio em relação a  $Y^j$ , repetindo este processo para cada exemplar, e armazenando cada estimativa, o erro quadrático médio pode ser medido entre a amostra atual  $Y^j$  e as estimadas. O valor de  $\sigma$  que resultar no menor erro deve ser usado como seu valor ótimo. Este método é conhecido como *holdout method* (BREIMAN; MEISEL; PURCELL, 1977).

Finalmente, deve ser mostrado que o *kernel* Gaussiano usado na Equação (3.49) pode ser substituído por alguma janela de Parzen, e expresso em termos de neurônios de redes neurais tendo funções de ativações específicas, particularmente atrativas do ponto de vista da simplicidade computacional, resultando no estimador

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp\left(-\frac{C_i}{\sigma}\right)}{\sum_{i=1}^n \exp\left(-\frac{C_i}{\sigma}\right)}, \quad (3.53)$$

em que

$$C_i = \sum_{j=1}^p |X_j - X_j^i|. \quad (3.54)$$

Esta medida é normalmente conhecida como distância de quarteirão (do inglês *city block distance*). Pode ser observado em classificação com PNN que a métrica das quadras da cidade funciona tão bem quanto a distância Euclidiana (SPECHT, 1990).

### 3.4.3.2 Arquitetura da rede GRNN

A rede GRNN, como toda rede neural, apresenta um grande número de elementos processadores simples, interconectados, que operam em paralelo e aprendem por experiência. A arquitetura pode ser visualizada na Figura 3.5, que pode ser descrita como contendo três camadas de neurônios, a primeira camada que representa a apresentação da amostra  $X = \{x, y\} = \{x_1, x_2, \dots, x_d, y_1, \dots, y_m\}$ , em que o vetor de características contém  $q$  atributos e o rótulo  $m$  componentes, e serve para distribuição do vetor  $X$  a todos os neurônios (unidades padrões) da camada intermediária.

Na camada intermediária de uma rede GRNN, o número de neurônios apresenta-se igual ao número de amostras do conjunto de treinamento com tamanho  $n$ , sendo a unidade padrão dedicada para um centro de agrupamento e seu vetor de pesos representado pelo vetor de características para uma dada amostra. Sendo o conjunto de treinamento representado por  $D = \{X^1, X^2, \dots, X^k\}$ , contendo  $k$  amostras. Quando um padrão de teste  $X$  é apresentado à rede, ele é subtraído de cada unidade padrão, então o quadrado ou o valor absoluto da diferença são somados e em seguida calculado o valor da função de ativação não-linear. A função de ativação normalmente utilizada é a exponencial  $\varphi_i(\cdot)$  como mostrado na equação 3.55.




Figura 3.5: arquitetura geral da GRNN.

$$\varphi_i(\cdot) = \exp\left(-\frac{(X - X^i)^T(X - X^i)}{2\sigma^2}\right) \quad (3.55)$$

Os valores obtidos da ativação de todas as unidades padrões chegam como entrada para um neurônio especial, que tem como saída o somatório  $\rho(\cdot)$  desses valores,

$$\rho(\cdot) = \sum_{i=1}^n \varphi_i(\cdot). \quad (3.56)$$

A saída das unidades padrões, que são calculadas pela multiplicação da componente  $j$  do rótulo  $y_i^j$  que representa a amostra de treinamento pela sua função de ativação  $\varphi_i^j(\cdot)$ , na equação 3.57,

$$\theta_j^i(\cdot) = \varphi_i(\cdot) \times y_j^i, \quad j = 1..m \quad (3.57)$$

são então distribuídas para as unidades somadoras como entrada.

A camada de saída contém  $m$  neurônios ou unidades somadoras, que como dito, recebem como entrada as componentes referentes a seu índice na camada, além de  $\rho(\cdot)$ , retornando como saída o somatório das componentes dividido pelo somatório das ativações das unidades padrões, que pode ser visto em 3.58,

$$\hat{y}_j = \frac{1}{\rho(\cdot)} \times \sum_{i=1}^n \theta_j^i(\cdot), j = 1..m \quad (3.58)$$

e daí se obter o vetor  $\hat{Y} = (y_1, \dots, y_m)^T$ .

## 3.5 Conclusão

Este capítulo apresenta algoritmos para os classificadores que são implementados e avaliados nesta dissertação, a saber Discriminante Linear, Discriminante Quadrático, *Naive Bayes*, *k - Vizinhos mais Próximos*, Rede MLP, Rede SOM, e Rede GRNN.

Estes algoritmos cobrem grande parte das técnicas utilizadas em problemas de classificação e, por isso, conhecimentos básicos sobre o funcionamento destes algoritmos é de grande importância na compreensão dos métodos de classificação que são propostos neste trabalho.

O capítulo seguinte é dedicado à apresentação de técnicas de extração de conhecimento de redes neurais, que podem assim permitir extrair conhecimento desses classificadores para que possam ser apresentados de uma forma compreensível para o ser humano e ajudar a desvendar o conhecimento por trás das redes neurais.



## *4 Extração e Representação do Conhecimento Embutido em Redes Neurais Artificiais Treinadas*

O objetivo deste capítulo é demonstrar que o mecanismo complexo de decisão codificado dentro das redes neurais pode se tornar explícito através da utilização de técnicas de extração de conhecimento de redes neurais. O estudo que pode ser considerado a origem na investigação de técnicas de extração de conhecimento é o trabalho proposto em GALLANT (1988), em que se planeja um sistema especialista conexionista que considera a rede neural como uma base de conhecimento. Neste trabalho, a fim de explicar o processo de inferência do sistema, apresenta-se metodologias para extrair regras proposicionais de uma rede simples.

Desde seu renascimento em meados de 80, as técnicas de redes neurais artificiais (RNA) são aplicadas com sucesso em uma grande faixa de domínios de problema, tais como reconhecimento de padrões e aproximações de funções (THRUN; BALA; BLOEDORN, 1991). Entretanto, as RNAs tem um inconveniente principal, o fato que o conhecimento embutido está codificado geralmente em um grande número de pesos e valores obtidos das ativações dos neurônios, sendo consideradas um enigma numérico. Como consequência, a falta de ferramentas de validação da rede neural é freqüentemente uma das razões que limitam seu uso na prática. Por exemplo, os médicos não podem confiar em um sistema de diagnóstico sem explanação de suas respostas, pois, as redes não detalham para o usuário final nenhuma introspecção de como se chega a um determinado resultado.

Recentemente, para contornar esta situação apresentada tem-se notado um esforço considerável na direção de suplementar RNAs com a potencialidade de explanação. Uma parte substancial deste esforço focaliza em uma linha da investigação que envolve o desenvolvimento de técnicas para extração e representação do conhecimento embutido em

redes neurais treinadas para um conjunto de regras que se apresentam de uma forma mais amigável e bem mais compreensível. Uma linha no desenvolvimento de algoritmos de extração da regras é dirigida para apresentar a saída como um conjunto de regras usando a lógica proposicional (THRUN, 1995; CRAVEN; SHAVLIK, 1996; SETIONO, 1997; ZHOU; CHEN; CHEN, 2000). Um esforço paralelo substancial é dirigido para expressar o conhecimento embutido nas redes neural usando os conceitos extraídos de lógica fuzzy (MASUOKA et al., 1990; CASTRO; MANTAS; BENITEZ, 2002). Alguns algoritmos são desenvolvidos também para extrair os autômatos de estado-finito também conhecidos como DFA (*Deterministic Finite Automaton*) das redes neural recorrentes (GILES et al., 1992; OMLIN; GILES; MILLER, 1992; GILES; OMLIN, 1993).

Em ANDREWS, DIEDERICH e TICKLE (1995) podem ser vistas diversas razões que tornam a extração de conhecimento de RNAs uma tarefa importante. As razões mostradas são: explanação, validação, exploração de dados e indução de teorias, melhorar a generalização de soluções envolvendo RNAs, integração entre sistemas simbólicos e conexionistas, e por último, redefinição da RNA.

A explanação é importante para que se saiba como um sistema de aprendizado toma uma decisão. O objetivo da explanação é permitir que o usuário explore o conhecimento do sistema. Idealmente é preciso que a explanação responda a questões sobre aspectos relevantes a respeito do sistema. A explanação é importante para aceitação das RNAs pelos usuários, pois, permite melhorar o entendimento por parte dos usuários.

Já, a validação é importante quando se quer um grau maior de confiança no conhecimento armazenado pela RNA. Em aplicações de alto risco, em que uma falha traria conseqüências graves, é fundamental que se valide o conhecimento adquirido antes de sua utilização.

A exploração de dados é outra razão importante além da explanação e validação. As RNAs com o passar do tempo têm provado ser uma ferramenta poderosa para este tipo de tarefa, apresentando a capacidade de descobrir dependências e relações desconhecidas dentro de um conjunto de dados. Sem a capacidade de explicação dos conhecimentos armazenados em uma RNA, estas descobertas ficam codificadas e a serem apreciadas.

Melhorar a generalização de soluções envolvendo RNAs quando um conjunto de dados limitado ou não representativo é utilizado no processo de treinamento de uma RNA, é difícil prever quando a generalização pode falhar. Nestes casos, a extração de conhecimento de RNAs é capaz de fornecer um conjunto de regras simbólicas, que podem ser analisadas por um especialista na tentativa de encontrar pontos em que a generalização

pode falhar;

A integração entre sistemas simbólicos e conexionistas é importante, pois, o conhecimento extraído na forma de regras SE...ENTÃO... facilita a integração com sistemas simbólicos baseados em conhecimento. As regras criam uma linguagem comum entre as duas técnicas, facilitando a sua integração.

Por último, a redefinição de uma RNA pode ser conseguida através das regras extraídas, que sendo utilizadas para verificar a adequação da arquitetura escolhida para a aplicação na qual a rede está sendo utilizada.

O modelo neural treinado é utilizado para a descoberta do conhecimento embutido em conjunto com os dados de treinamento, e conseqüentemente gerar uma base de conhecimento para um dado problema com regras simbólicas de fácil entendimento para um ser humano, e assim permitir que o mecanismo de decisão revelado possa explicar aos peritos a base da solução da rede neural. Vale ressaltar ainda que este capítulo focaliza principalmente em algoritmos para extrair regras do tipo proposicional (do tipo SE-ENTÃO).

## 4.1 Taxonomia das Técnicas de Extração de Conhecimento de Redes Neurais Artificiais

As técnicas de extração/refinamento de conhecimento embutido em redes neurais podem ser classificadas com base em cinco critérios: o poder de expressão (ou, alternativamente, o formato da regra) das regras extraídas; a qualidade das regras obtidas; a granularidade/translucência quanto às redes para as técnicas de extração das regras; a complexidade algorítmica ; a portabilidade para outras arquiteturas, como mostra a pesquisa de ANDREWS, DIEDERICH e TICKLE (1995):

### 4.1.1 O poder de expressão

Para o primeiro critério, o poder de expressão (ou o formato das regras) das regras extraídas, verificam-se três agrupamentos para o formato destas:

1. regras simbólicas tradicionais (booleano e proposicional), ou seja, regras do tipo SE-ENTÃO que apresentam no antecedente teste booleano e no conseqüente uma conclusão;

2. regras que envolvem conjuntos e lógica fuzzy ( regras do tipo SE-ENTÃO em que o antecedente pode ser parcialmente verdadeiro, ou seja, o quanto a expressão no antecedente pode ser considerada verdadeira);
3. regras que são expressas em lógica de primeira-ordem, que permitem descrever e raciocinar sobre objetos e predicados que especificam propriedades de objetos ou relacionamentos entre objetos.

### 4.1.2 A qualidade das regras

A qualidade refere-se a métricas de exatidão, fidelidade, consistência e compreensibilidade de regras quanto à rede neural da qual se teve o conhecimento extraído.

A exatidão da regra é a capacidade que o conjunto de regras para classificar corretamente um conjunto de exemplos previamente desconhecidos no domínio do problema. Enquanto, a fidelidade da regra é a capacidade que o conjunto de regras para imitar o comportamento da rede neural da qual é extraída.

A consistência da regra, como parâmetro de qualidade, é definida como medida de como as regras geradas da rede neural produzem as mesmas classificações sob sessões diferentes de treinamento dos exemplos desconhecidos. De outra forma, a compreensibilidade da regra é a medida do tamanho da regra baseado nos termos de número das regras e do número dos antecedentes para esta regra.

### 4.1.3 A granularidade/translucência das regras

A granularidade/translucência faz referência em que nível de detalhe a rede apresentada é considerada, observando-se com uma visão global, parcial ou unitária das unidades subjacentes da RNA, subdividindo-se em: pedagógica, decomposicional e eclética.

A granularidade é considerada pedagógica quando a rede é considerada uma caixa preta e as regras são extraídas fazendo um mapeamento entrada-saída, desconsiderando então a rede como composta por unidades menores, os neurônios, a rede é vista em um nível de granularidade máxima;

A granularidade decomposicional quando a rede é considerada em seu nível de detalhe mínima, ou seja, as regras são extraídas com base nos neurônios, além de considerar as várias camadas: entrada, saída e escondida.

A denominação de eclética para a granularidade é dada quando se considera em a rede

em um nível de detalhe médio, apresentando-se como um meio termo entre a granularidade pedagógica e decomposicional, já que para a extração de regras é feita análise da rede neural tanto em nível individual (neurônios) como análise em nível global.

#### **4.1.4 A complexidade algorítmica**

A complexidade algorítmica de técnicas de extração de regras, mede a grandeza de complexidade do algoritmo de extração de regras. Alguns algoritmos não definem bem em que complexidade está inserido, de forma que um bom algoritmo apresenta complexidade polinomial em detrimento a complexidade exponencial, que pode ser verificada em alguns algoritmos.

#### **4.1.5 A portabilidade**

Uma técnica de extração é considerada tão mais portátil quanto for a capacidade de mudança entre arquiteturas de RNAs, e ainda assim o algoritmo continua extraindo regras. A extensão a que a RNA subjacente incorporada especializa os regimes de treinamento, mede a portabilidade de técnicas de extração de regras através das várias arquiteturas.

Outros critérios além dos descritos acima, que podem ser vistos em TAHA e GHOSH (1999), são: capacidade de modificação, potencial de refinamento e estabilidade ou robustez.

A capacidade de modificação, refere-se a capacidade das regras extraídas de serem atualizadas quando a arquitetura neural treinada sofrer atualização ou re-treinamento com diferentes bases de dados. Enquanto o potencial de refinamento refere-se a capacidade de reduzir os efeitos referentes a aquisição de conhecimento devido ao incompletude, à inconsistência, e/ou ao inexatidão do conhecimento inicialmente adquirido do domínio.

E por último a estabilidade ou robustez refere-se a medida de quão insensível é o método a dados de treinamento corrompidos, além deste e dos fatores citados acima pode ser considerados por sua relevância a capacidade de aplicação do algoritmo a valores em domínios discretos e/ou contínuos.

## 4.2 Algoritmos para Extração de Regras

Alguns algoritmos são descritos, tanto algoritmos que extraem conhecimento de redes com aprendizado supervisionado quanto algoritmos que extraem conhecimento de redes com aprendizado não-supervisionado.

No primeiro caso, para algoritmos de aprendizado supervisionado como o Perceptron Multicamadas a extração é vista de duas formas diferentes: como uma caixa-preta, ou seja, tendo-se uma visão pedagógica da rede ou em um nível de granularidade menor, de forma decomposicional, em que tem-se a visão da rede em seu nível de granularidade mínima, sendo as regras são extraídas com base nos neurônios, como visto em TSUKIMOTO (2000).

No segundo caso, o algoritmo para extração de conhecimento embutido em redes do tipo SOM que apresenta treinamento não-supervisionado também é descrito. Neste caso, as regras são extraídas também em nível de neurônios, baseado no trabalho desenvolvido por DARRAH, TAYLOR e SKIAS (2004).

### 4.2.1 Extração de Regras do Perceptron Multicamadas - Pedagógica

Um algoritmo simples baseia-se no conjunto de dados de treinamento e em uma rede neural do tipo Perceptron Multicamadas treinada com o algoritmo *backpropagation*. A rede neural é visualizada em seu nível máximo de granularidade, os neurônios não são investigados individualmente, de forma que a rede toda é mapeada para uma função do tipo  $F(x)$  ( que representa a própria rede).

Considerando o problema consistindo de  $q$  classes dadas por  $\{w_1, w_2, \dots, w_q\}$ , em que  $i = 1..q$  indica a classe e os padrões de treinamento dados na forma  $x = (x_1, x_2, \dots, x_n)^T$ . Com a rede neural treinada e os dados do treinamento, as amostras que são utilizadas no aprendizado são rerepresentadas a rede e os padrões são reagrupados por classe, de acordo com o resultado fornecido pela rede neural. Assim, os padrões para os quais a rede sinaliza como pertencente a uma determinada classe  $i$  são reunidos e agrupados em  $M_i$ . Como existem  $q$  classes, verifica-se a formação de  $q$  agrupamentos de amostras, que podem ser vistas também como  $q$  matrizes  $\{M_1, M_2, \dots, M_n\}$ , e cada matriz  $M_i$  contém os padrões aos quais a rede classifica como pertencente a classe  $i$ .

Para os  $q$  agrupamentos ou matrizes de padrões, os valores máximos e mínimos são

calculados e armazenados na seguinte forma

$$\begin{aligned} \min_i &= \min M_i, & \forall i \in e \\ \max_i &= \max M_i, & \forall i. \end{aligned} \quad (4.1)$$

Os vetores  $\min_i = (x_{1-\min}, x_{2-\min}, \dots, x_{n-\min})^T$  e  $\max_i = (x_{1-\max}, x_{2-\max}, \dots, x_{n-\max})^T$ , de forma a gerar o seguinte grupo de regras para cada classe

PARA  $i = 1$  ATÉ  $q$  FAÇA

INÍCIO

$\min = \min_i$ ;

SE  $(x_{1-\min} < x_1 < x_{1-\max})$  E ... E  $(x_{n-\min} < x_n < x_{n-\max})$

ENTÃO  $w_i$

FIM.

Quando uma amostra de teste é apresentada às regras, cada antecedente é verificado e caso todos os antecedentes apresentem-se verdadeiros, o padrão é considerado pertencente a classe indicada pelo conseqüente. O número de regras está diretamente relacionado e apresenta-se igual ao número de classes, cada antecedente contém um número  $n$  de testes devido ao tamanho  $n$  do vetor de característica da amostra.

## 4.2.2 Extração de Regras do Perceptron Multicamadas - Decomposicional

### 4.2.2.1 O algoritmo básico

O algoritmo básico aproxima as unidades da rede neural por funções Booleanas. Tendo  $f(x_1, \dots, x_n)$  representando a unidade da rede neural e  $(f_i)(i = 1, \dots, 2^n)$  o valor das unidades de saída dos neurônios da rede neural. As funções de ativação dos neurônios são funções sigmóides, então os valores das unidades de saída estão no intervalo  $[0, 1]$ . Tendo  $g(x_1, \dots, x_n)$  representando a função Booleana, e  $(g_i)(i = 1, \dots, 2^n)$  os valores de saída da função Booleana.

A representação da função Booleana é dada da seguinte forma

$$g(x_1, \dots, x_n) = \sum_{i=1}^{2^n} g_i \cdot a_i, \quad (4.2)$$

em que o somatório representa a disjunção,  $a_i$  é um atom, e  $g_i$  é o valor do domínio correspondente ao atom. Um atom é dado por

$$a_i = \prod_{j=1}^n e(x_j) (i = 1, \dots, 2^n), \quad (4.3)$$

em que o produtório representa a conjunção, e  $e(x) = x_j \text{ ou } \bar{x}_j$ , sendo  $\bar{x}$  a negação de  $x$ . O domínio  $(x_1, \dots, x_n)$  correspondente para um atom é descrito a seguir. Quando  $e(x_j) = x_j$ ,  $x_j = 1$ , e quando  $e(x_j) = \bar{x}_j$ ,  $x_j = 0$ . Esta fórmula pode ser facilmente verificada, pois, o valor de  $g_i$  é dado

$$g_i = \begin{cases} 1, & f_i \geq 0.5 \\ 0, & f_i < 0.5 \end{cases} \quad (4.4)$$

Fazendo-se uma análise da função  $g_i$  verifica-se que esta minimiza a distância Euclidiana, de forma que atribui a imagem de  $x$  ao ponto mais próximo com relação a  $f_i$ . Sendo então a função Booleana representada pela Equação 4.2, em que  $g_i$  é calculado pela Equação 4.4.

O funcionamento da técnica descrita pode ser analisado para o MLP com uma arquitetura de rede contendo uma única camada e esta camada com um único neurônio com duas entradas.

O domínio para todo o espaço de entrada  $(x, y)$ , pertencendo ao conjunto  $(0, 0)$ ,  $(0, 1)$ ,  $(1, 0)$ ,  $(1, 1)$  e uma saída  $z \in [0, 1]$ . Logo, os atoms correspondentes ao domínio são os seguintes  $(0, 0) \Leftrightarrow \bar{x}\bar{y}$ ,  $(0, 1) \Leftrightarrow \bar{x}y$ ,  $(1, 0) \Leftrightarrow x\bar{y}$  e  $(1, 1) \Leftrightarrow xy$ . Suponha que a rede tenha aproximado o OU Booleano, logo os valores para a função Booleana são:  $g(0, 0) = 0$ ,  $g(0, 1) = 1$ ,  $g(1, 0) = 1$  e  $g(1, 1) = 1$ . Sendo assim, a função Booleana é representada por

$$g(x, y) = g(0, 0)\bar{x}\bar{y} + g(0, 1)\bar{x}y + g(1, 0)x\bar{y} + g(1, 1)xy,$$

reduzindo a fórmula a

$$g(x, y) = g(0, 0)\bar{x}\bar{y} + g(0, 1)\bar{x}y + g(1, 0)x\bar{y} + g(1, 1)xy$$


$$g(x, y) = 0.\bar{x}\bar{y} + 1.\bar{x}y + 1.x\bar{y} + 1.xy$$

$$g(x, y) = \bar{x}y + x\bar{y} + xy$$

$$g(x, y) = \bar{x}y + x.$$

O gráfico referente a aproximação da rede para a função OU lógico é mostrado na Figura 4.1, de onde facilmente se vê que o atom  $a_i$  existe quando o valor de saída do neurônio  $f_i$  correspondente é maior do que 0,5. Como por exemplo para os valores de  $(x, y)$  iguais a

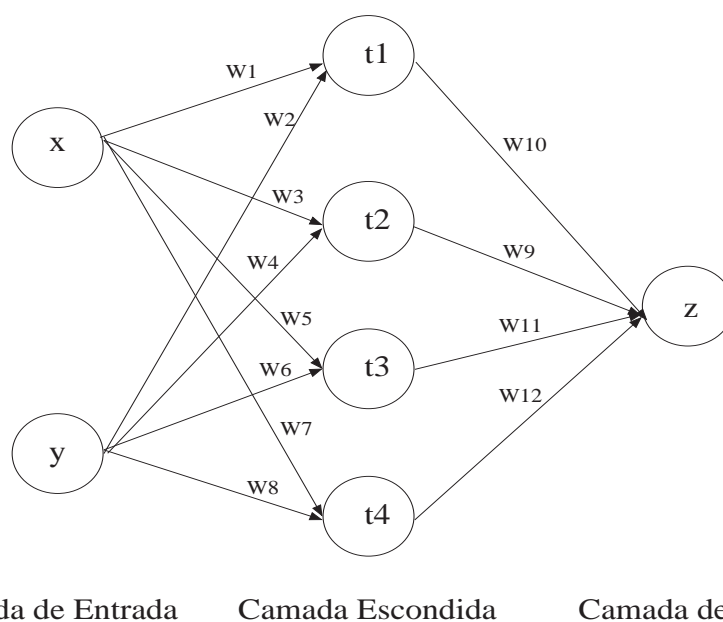




**Figura 4.1:** aproximação da disjunção (OU) pela rede neural.

(0, 1) , (1, 0) e (1, 1).

A aplicabilidade do algoritmo apresentado para uma arquitetura de rede neural mais complexa, que consegue resolver problemas não-lineares, como por exemplo a aproximação da função OU exclusivo, pode ser descrita abaixo. Sua arquitetura apresentando uma camada escondida com quatro neurônios e uma camada de saída com um neurônio. Os passos que se seguem demonstram que a regra do OU exclusivo, que é,  $\bar{x}y \wedge x\bar{y}$ , pode ser obtida de uma estrutura de rede neural treinada, em que  $\wedge$  é a operação E booleano.



**Figura 4.2:** rede neural modelada para resolver o problema OU EXCLUSIVO.

Na Figura 4.2,  $x$  e  $y$  são entradas,  $z$  é uma saída,  $t_1, t_2, t_3$  e  $t_4$  são as saídas para as

quatro unidades escondidas. Cada entrada é representada

$$\begin{aligned} t_1 &= S(w_1x + w_2y + h_1) \\ t_2 &= S(w_3x + w_4y + h_2) \\ t_3 &= S(w_5x + w_6y + h_3) \\ t_4 &= S(w_7x + w_8y + h_4) \\ z &= S(w_9t_1 + w_{10}t_2 + w_{11}t_3 + w_{12}t_4 + h_5), \end{aligned}$$

em que  $w_1, \dots, w_9$  representam os pesos,  $S(x)$  a função sigmóide e  $h_1, \dots, h_5$  os bias (limiar de excitação).

Os resultados do treinamento da rede para 1000 iterações são os seguintes:

$$\begin{aligned} w_1 &= 2,51 & w_2 &= -4,80 & w_3 &= -4,90 \\ w_4 &= 2,83 & w_5 &= -4,43 & w_6 &= -4,32 \\ w_7 &= -0,70 & w_8 &= -0,62 & w_9 &= 5,22 \\ w_{10} &= 5,24 & w_{11} &= -4,88 & w_{12} &= 0,31 \\ h_1 &= -0,83 & h_2 &= -1,12 & h_3 &= 0,93 \\ h_4 &= -0,85 & h_5 &= -2,19 \end{aligned}$$

Como exemplo, seja  $t_1 = S(2,51x - 4,80y - 0,83)$  em que os valores para  $t_1(1,1), t_1(1,0), t_1(0,1)$  e  $t_1(0,0)$  são os seguintes

$$\begin{aligned} t_1(1,1) &= S(2,51 \cdot 1 - 4,80 \cdot 1 - 0,83) = S(-3,12), \\ t_1(1,0) &= S(2,51 \cdot 1 - 4,80 \cdot 0 - 0,83) = S(+1,68), \\ t_1(0,1) &= S(2,51 \cdot 0 - 4,80 \cdot 1 - 0,83) = S(-5,63), \\ t_1(0,0) &= S(2,51 \cdot 0 - 4,80 \cdot 0 - 0,83) = S(-0,83), \end{aligned}$$

produzem aproximações  $S(-3,12) \simeq 0$ ,  $S(1,68) \simeq 1$ ,  $S(-5,63) \simeq 0$  e  $S(-0,83) \simeq 0$ , então

$$t_1 \simeq x\bar{y}. \quad (4.5)$$

De maneira similar, as outras saídas são obtidas para as seguintes funções Booleanas:

$$t_2 = \bar{x}y, \quad t_3 = \bar{x}\bar{y} \quad \text{e} \quad t_4 = 0.$$

O resultado da extração da regra resultante para a saída  $z$  é  $z = \bar{t}_1t_2 \vee \bar{t}_1t_2\bar{t}_3 \vee t_1\bar{t}_2\bar{t}_3$ . Pela substituição de  $t_1 = x\bar{y}$ ,  $t_2 = \bar{x}y$  e  $t_3 = \bar{x}\bar{y}$  produz

$$z = \bar{x}y \wedge x\bar{y}.$$

Desta forma é obtido a regra que representa o OU exclusivo. Assim, confirma-se a obtenção da regra lógica do OU exclusivo pela aproximação da rede neural que aprende o OU exclusivo. Podendo-se considerar os seguintes aspectos:

1. o resultado do treinamento é obtido de quatro unidades escondidas e uma unidade de saída;
2. a saída da unidade escondida 4,  $t_4$ , não é incluída na função Booleana da unidade de saída,  $z$ , então a unidade escondida 4 não trabalha e pode ser excluída;
3. as outras três unidades escondidas trabalham e são necessárias, portanto não podem ser excluídas.

Este algoritmo funciona muito bem para domínios em que o espaço de entrada são valores booleanos  $0, 1^n$ . Entretanto apresentam uma deficiência já que a complexidade do algoritmo é exponencial  $2^n$ , em que  $n$  é representa o número de entradas. Um aprimoramento deste algoritmo no sentido de atenuar esta desvantagem surge como alternativa, de forma a expandi-lo para o domínio contínuo.

#### 4.2.2.2 Extensão do Algoritmo para Domínios Contínuos

Um ponto importante que deve ser considerado para o algoritmo apresentado é a sua expansão para domínios contínuos. Domínios contínuos podem ser normalizados para o espaço  $[0, 1]$  por algum método de normalização.

O primeiro na direção de expansão do algoritmo para o domínio contínuo é apresentar um sistema de expressão qualitativa correspondente para as funções Booleanas no intervalo  $[0, 1]$ . Nas Figuras abaixo podem ser observados os sistemas de expressões gerados pela proporção direta e reversa, conjunção e disjunção. A Figura 4.3 mostra a proporção direta e a reversa ( $y = 1 - x$ ). Esta última apresenta-se levemente diferente da convencional  $y = -x$ , porque  $y = 1 - x$  é a extensão natural da negação de funções Booleanas. As funções gerada pela proporção direta, proporção reversa, conjunção e disjunção são chamadas funções Booleanas contínuas, pois estas satisfazem os axiomas da Álgebra Booleana.

Com base nas considerações anteriores é desejado que uma expressão qualitativa seja obtida, podendo valores quantitativos serem ignorados. Por exemplo, a função A na Figura 4.4 não é uma proporção direta de  $x$ , mas a função de um ponto de vista qualitativo




Figura 4.3: proporção direta e reversa.




Figura 4.4: norma qualitativa.

é considerada como uma proporção para domínios booleanos. Então, as duas funções devem ser consideradas como uma mesma em uma expressão qualitativa, isto é, no intervalo  $[0, 1]$ ,  $x^k$  ( $k \geq 2$ ) deve ser identificado como  $x$  na expressão qualitativa.

Em uma outra análise, uma unidade da rede neural é uma função multilinear e o espaço de uma função multilinear é Euclidiano, então uma unidade pode ser aproximada por uma função Booleana usando uma norma Euclidiana. Novamente no espaço  $[0, 1]$ , fato similar acontece, isto é, a unidade da rede neural é uma função multilinear na expressão qualitativa, ou seja, o espaço de funções multilineares qualitativo é um espaço Euclidiano então a norma qualitativa pode ser usada similarmente. Assim, a unidade da rede neural pode ser aproximada por funções Booleanas contínuas usando a norma Euclidiana.

De acordo com o que é descrito, a transformação  $\tau_x$  para a variável  $x$  entre funções

polinomiais reais do tipo

$$f(x) = p(x)(x - x^2) + q(x) \quad (4.6)$$

em que  $q(x) = ax + b$  representa o resto, e  $a$  e  $b$  são números reais, é dada por

$$\tau_x : f(x) \rightarrow q(x). \quad (4.7)$$

Da transformação descrita anteriormente implica a propriedade

$$\tau_x(x^k) = x \quad (4.8)$$

onde  $k \geq 2$ . E para o caso de

No caso de  $n$  variáveis,  $\tau$  é definido como segue

$$\tau = \prod_{i=1}^n \tau_{x_i}. \quad (4.9)$$

Por exemplo,  $(x^2y^3 + y + 1) = xy + y + 1$ .

A função obtida da função Booleana pela extensão do domínio  $\{0, 1\}$  para  $[0, 1]$  pode satisfazer todos os axiomas da algebra Booleana com os operadores definidos na tabela 4.1, cuja prova pode ser encontrada em TSUKIMOTO (1994) Conseqüentemente, as funções

CONJUNÇÃO (E):	$\tau(fg)$
DISJUNÇÃO (OU):	$\tau(f + g - fg)$
NEGAÇÃO (NÃO):	$\tau(1 - f)$

**Tabela 4.1:** operadores da algebra booleana.

obtidas de funções Booleanas, estendendo-se o domínio de  $\{0, 1\}$  para  $[0, 1]$  são chamadas funções Booleanas contínuas. Por exemplo,  $xy$  e  $1 - y (= \hat{y})$  são funções Booleanas, em que  $x, y \in [0, 1]$ . Pode-se observar um exemplo simples para uma operação lógica

$$(X \vee Y) \wedge (X \vee Y) = X \vee Y \quad (4.10)$$

sua transformação para um domínio contínuo é dada por

$$\begin{aligned} \tau((x + y - xy)(x + y - xy)) &= \tau(x^2 + y^2 + x^2y^2 + 2xy - 2x^2y - 2xy^2) \quad (4.11) \\ &= x + y + xy + 2xy - 2xy - 2xy \\ &= x + y - xy \end{aligned}$$

Como se nota, a expressão em lógica booleana  $(X \vee Y) \wedge (X \vee Y) = X \vee Y$  pode ser

substituída pela expressão  $x + y - xy$ , basta que se simule entradas para valores de  $x$  e  $y$  com valores 0, 1.

### 4.2.3 Extração de Regras da Rede SOM - Decomposicional

A técnica de extração apresentada tem como base o algoritmo de DARRAH, TAYLOR e SKIAS (2004) que é utilizado para extrair conhecimento da rede SOM. A partir de uma rede SOM treinada utiliza-se as amostras de treinamento como entrada para o algoritmo de extração de conhecimento.

Uma associação com o protótipo vencedor é feito baseado na similaridade com a amostra apresentada, a memória da associação entre as amostras e os protótipos são armazenadas de forma que ao final cada protótipo saiba as amostras associadas a ele. Assim sendo, os dados do treinamento são divididos em regiões baseado em nos protótipos vencedores ou BMU (*Best-Matching Units*).

Da forma apresentada, então para um dado vetor da forma  $x = (x_1, \dots, x_n)^T$ ,  $i = 1..n$ , para cada região  $x_{i-lower}$  é o menor valor da variável independente  $i$  que tem um particular BMU e  $x_{i-upper}$  é o maior valor da variável independente  $i$  que tem o mesmo BMU. Estes dois valores formam o limite para o intervalo no antecedente da regra para a componente do vetor de índice  $i$ . O antecedente de uma regra é formado por  $n$  testes lógicos, da seguinte forma  $(x_i \geq x_{i-lower}) \text{ AND } x_i \leq x_{i-upper}$ , que é o mesmo que  $(x_{i-lower} \leq x_i \leq x_{i-upper})$ , fazendo-se variar o valor de  $i$  tem-se o antecedente completo, como descrito

$$SE \quad \forall 1 \leq i \leq n : x_i \in [x_{i-lower}, x_{i-upper}] \quad ENTAO \quad w_j, \quad (4.12)$$

em que  $[x_{i-lower}, x_{i-upper}]$  representa a faixa de efetividade para o protótipo na  $i$ -ésima componente.

No caso de extração de regras em problemas de classificação, a conclusão do SE-ENTÃO refere-se a uma classe. Neste caso, uma estratégia para se determinar a classe no conseqüente deve ser utilizada, é importante salientar que podem ocorrer as seguintes casos: protótipo não atrai amostras, protótipo atrai amostras da mesma classe e protótipo atrai amostras de classes diferentes.

No caso de um protótipo não atrair amostras, este não venceu nenhuma vez para nenhuma amostra, não há como associar amostras ao protótipo também não é possível extrair diretamente os limites dessa célula de Voronoi, muito menos indicar o conseqüente

da regra ( a classe) para as amostras do conjunto de teste que são atraídas por esse protótipo.

Quando um protótipo atrai amostras da mesma classe, o protótipo ou centro da região de Voronoi atraiu uma ou mais amostras da mesma classe. Logo, tanto os limites das variáveis independentes quanto o conseqüente podem ser determinados facilmente, e é atribuído ao conseqüente desta regra a classe a qual todas as amostras pertencem.

Por fim, quando um protótipo atrai amostras de classes diferentes, o protótipo ou centro da região de Voronoi atraiu uma ou mais amostras de classes diferentes. Como existe mais de uma classe envolvida, uma medida para se determinar a classe do conseqüente deve ser definida, então, basta que se verifica qual a classe que apresenta mais amostras dentro daquele subconjunto de amostras atraídas para aquela célula de Voronoi, e atribui-se esta ao conseqüente da regra.

Quando o mapeamento da rede SOM é feito para um espaço uni-dimensional, pode ser possível resolver o problema no caso 1, através da generalização ou verificação dos vizinhos (à direita e à esquerda) e verificar se estes pertencem a mesma classe, em caso positivo, uma regra geral pode ser criada, em que o antecedente é formado pelos mínimos dos mínimos das duas regras e o conseqüente a mesma classe de seus vizinhos. De forma similar, pode-se resolver o mesmo caso 1 mas para o mapeamento bi-dimensional, sendo que uma verificação maior de vizinhos deve ser usada.

### 4.3 Simplificação de Regras

Um dos principais propósitos de técnicas de extração de conhecimento de redes neurais é o de fornecer a facilidade de explanação para as decisões feitas pela rede. Assim sendo, é obvio a importância de que as regras sejam compreensíveis tanto quanto possíveis. O conjunto de regras diretamente extraídas podem conter: redundância; individualidade, com condição de antecedente redundante e ainda pares de regras onde onde as condições dos antecedentes podem ser combinadas.

Uma regra  $b$  pode ser removida de um conjunto de regras se existe uma outra regra  $a$ , geral, tal que

$$\forall 1 \leq i \leq n : [x_{i-lower}(b), x_{i-upper}(b)] \subseteq [x_{i-lower}(a), x_{i-upper}(a)]. \quad (4.13)$$

Uma regra é também redundante e deve ser removida do conjunto de regras se

$$\exists 1 \leq i \leq n : [i_{lower}, i_{upper}] \cap [x_{i-lower}, x_{i-upper}] = \phi, \quad (4.14)$$

em que  $[i_{lower}, i_{upper}]$  representa a faixa de entrada dos valores da  $i$ -ésima dimensão de entrada, ou seja, o teste de  $x_i$  para o intervalo  $[x_{i-lower}, x_{i-upper}]$  nunca é verdadeiro.

Uma condição do antecedente é redundante e deve ser removida da regra se

$$\exists 1 \leq i \leq n : [i_{lower}, i_{upper}] \subseteq [x_{i-lower}, x_{i-upper}], \quad (4.15)$$

ou seja, o teste de  $x_i$  para o intervalo  $[x_{i-lower}, x_{i-upper}]$  sempre é verdadeiro.

As regras **a** e **b** devem ser mescladas no antecedente para a  $j$ -ésima dimensão de entrada se

$$\forall 1 \leq i \leq n : (i \neq j) \wedge ([x_{i-lower}(a), x_{i-upper}(a)] = [x_{i-lower}(b), x_{i-upper}(b)]). \quad (4.16)$$

## 4.4 Fidelidade versus Exatidão das Regras

Como mencionado em seções anteriores, fidelidade descreve quão bem as regras imitam o comportamento das redes neurais, que é usualmente definida como a percentagem de exemplos de teste, nos quais a classificação é feita pelas regras concordam com as da rede neural, exatidão descreve quão bem as regras podem generalizar, que é normalmente definida como a percentagem dos exemplos de teste que são corretamente classificados pelas regras. Em um recente artigo ZHOU, JIANG e CHEN (2003) apresenta um algoritmo pedagógico para extrair regras proposicionais de um complicado sistema de redes neurais. Com diferentes configurações, o algoritmo apresentado pode extrair regras com alta fidelidade mas moderada exatidão ou alta exatidão mas moderada fidelidade, como descrito na Tabela 4.2. Uma questão é levantada: que configuração devemos preferir?

	Fidelidade	Exatidão
config-1	alta	moderada
config-2	moderate	alta

**Tabela 4.2:** tabela de compromisso da precisão versus exatidão.

A questão apresentada resulta numa situação embaraçosa: sacrificar a fidelidade ou sacrificar a exatidão. De fato, conseguir alta fidelidade e alta exatidão pode não ser possível em certas situações, esta situação dá-se o nome de dilema fidelidade versus exatidão.



Formalmente, sendo  $X$  o conjunto de teste,  $h(x)$  representando a função desejada,  $f_N(x)$  a função implementada pela rede neural, e  $f - R(x)$  a função implementada pelas regras extraídas da rede neural, a fidelidade e a exatidão das regras podem ser definidas por

$$fidelidade_R = 1 - Prob\{x \in X | f_R(x) \neq f_N(x)\}, \quad (4.17)$$

$$exatidao_R = 1 - Prob\{x \in X | f_R(x) \neq h(x)\}. \quad (4.18)$$

Supondo que um novo exemplo de teste  $t$  é adicionado a  $X$ , dado que  $f_N(t) \neq h(t)$ , e as regras podem ser modificados para  $t$ . E se o  $f_R(t) = f_N(t)$ , então a exatidão é deteriorada; mas se  $f_R(t) = h(t)$  então a fidelidade é deteriorado. Isto ilustra que melhorar a exatidão não conduz necessariamente à melhoria da fidelidade, e vice-versa.

De fato, um algoritmo para extração de regras pode implicitamente detectar um erro cometido pela rede durante o processo de extração de regras, se o algoritmo tentar imitar o erro então perde em exatidão, caso contrário perde em fidelidade.

É interessante notar que pesquisadores observam que as regras extraídas podem generalizar melhor do que a rede, das quais as regras são extraídas (ZHOU; JIANG; CHEN, 2003; TOWELL; SHAVLIK, 1993; FU, 1994; TAHA; GHOSH, 1999; SETIONO, 2000). Os pesquisadores constatam, que no caso de, se tentar aprimorar mais ainda a fidelidade das regras, são grandes as possibilidades de encontrar uma exatidão deteriorada. Isto se deve porque ao se tentar perseguir uma fidelidade 100%, a exatidão das regras deve ser diminuída ao nível de exatidão da rede neural.

Como Andrews et o al. (ANDREWS; DIEDERICH; TICKLE, 1995) indicam, a motivação para a extração de regras das redes neurais é de incrementar as redes neurais com a capacidade de explanação. Em outras palavras, no caso em que as redes neurais são mais exatas do que outras técnicas de aprendizado, como as árvores de decisão para alguns problemas específicos, a potencialidade destas pode ser melhor aproveitada se sua compreensibilidade for realçada. Mas, se a rede neural não for assim exata como algumas outras técnicas de aprendizagem, em um problema específico, as técnicas de aprendizagem alternativas é que devem ser usadas em substituição a rede neural. Conseqüentemente, é evidente que o objetivo principal da extração de regras das redes neural é gerar sistemas de aprendizagem exatos e compreensíveis, em que a rede neural é somente uma ferramenta para conseguir este objetivo. Este cenário é denominado de extração de regras usando redes neurais.

Em outro caso, a motivação pode ser encontrar regras que exibam fielmente o comportamento das redes, ou seja, com uma fidelidade alta, o que não tem relação alguma com o objetivo da extração de regras usando redes neurais. Porém, a maioria dos trabalhos nesta área tentam extrair réguas com fidelidade elevada e exatidão elevada, embora como indicado em discussão anterior, isto seja impossível em determinadas situações. Muitos trabalhos focalizam somente na fidelidade, reivindicando um valor muitas vezes próximos a 100%, e muitas vezes a fidelidade elevada é conseguida arbitrariamente (CRAVEN; SHAVLIK, 1994; CHALUP; HAYWARD; DIEDERICH, 1998; MAIRE, 1999; BOLOGNA, 2000).

Baseado na análise acima, é evidente que a fidelidade deve ser excluída da estrutura de avaliação da qualidade da regra para a extração de regras usando redes neural. Além disso, a pergunta levantada anteriormente pode ser facilmente respondida: a configuração com exatidão alta é preferível porque o objetivo é obter sistemas de aprendizagem exatos e detalhados.

Então uma outra pergunta surge: é a fidelidade inútil em tudo?

Deve-se utilizar de cautela para responder a essa pergunta. Embora a fidelidade pareça ser inútil no objetivo de conseguir desenvolver sistemas de aprendizagem exatos e compreensíveis, pode ser útil para outras finalidades. De fato, a extração das regras das redes neurais pode ter um objetivo secundário, isto é, para compreender o mecanismo de trabalho das redes neurais treinadas. A fim de conseguir este objetivo, as regras devem replicar o comportamento da rede neural da qual é extraída tão fielmente quanto possível. Este outro cenário é denominado extração de regras para redes neurais.

É óbvio que neste cenário a fidelidade é um critério chave quando se deseja avaliar a qualidade da regra. Além disso, a exatidão é inútil agora porque as regras extraídas reproduzem fielmente a rede neural treinada, não importando se estas generalizam bem ou não. O mais interessante neste caso é que uma exatidão mais elevada para o conjunto de regras não é desejável agora, porque estas regras não poderão nos dizer como a rede treinada trabalha realmente.

## 4.5 Conclusão

Neste capítulo são apresentados algoritmos para extração de regras de redes neurais e por conseqüência demonstrado que o mecanismo complexo de decisão codificado dentro das redes neurais pode se tornar explícito. O modelo neural treinado é utilizado para a descoberta do conhecimento embutido em conjunto com os dados de treinamento, e então

---

uma base de conhecimento para um dado problema com regras proposicionais é criada. As regras proposicionais criadas são de fácil entendimento para um ser humano, e assim permitem que o mecanismo de decisão revelado possa explicar aos especialistas a base da solução da rede neural.

Além da criação da base de conhecimento, uma discussão sobre o dilema fidelidade-exatidão também é exposto, onde mostra-se a distinção entre extrair regras usando redes neurais e extrair regras para redes neurais de acordo com seus objetivos. Por fim, vale ressaltar, que este capítulo focaliza principalmente em algoritmos que extraem regras do tipo proposicional.

## 5 *SINPATCO e Resultados*

Um sistema inteligente, como o proposto nesse trabalho, deve ser capaz de apresentar diagnóstico de patologias relacionadas a coluna vertebral. Para tanto, tal sistema deve conter alguns módulos (subsistemas) que apresentam funcionalidades bem definidas. Estes subsistemas são: interface gráfica, módulo de classificação de patologias (módulo inteligente), módulo de explanação e resultado.

O módulo gráfico pode ser definido como a interface que permite a interação do especialista com o sistema. A comunicação do especialista com o sistema deve ser feita por meio de entrada de dados (atributos referentes a dores e deformidades da coluna, como descrito no Capítulo 2). A Figura 5.1 apresenta a interface gráfica do SINPATCO, mostrando os campos para entrada de dados, a possibilidade de escolha de um classificador para ser utilizado pelo módulo de classificação de patologias, apresenta um espaço reservado para a apresentação de regras que permitam elucidar a inferência realizada e ainda um campo de resultado com o diagnóstico inferido pelo SINPATCO.

O módulo de classificação de patologias apresenta-se como sendo a parte mais importante do sistema, pois, contém os algoritmos que fazem o diagnóstico das patologias, sendo responsável pelo processamento dos dados fornecidos através da interface gráfica. Este subsistema, é formado por um classificador dentre MLP,  $k$ -NN, naive Bayes, SOM e GRNN.

Por último, o módulo de explanação e resultado contém um extrator de regras para traduzir o conhecimento embutido nos pesos dos protótipos da rede SOM em regras simbólicas, fáceis de serem compreendidas pelos homens. Este módulo têm também a responsabilidade de repassar a tradução feita aos especialistas através da chamada da *interface* gráfica.

O SINPATCO é construído em um ambiente para desenvolvimento de software integrado denominado Eclipse. Um ambiente de desenvolvimento como o Eclipse pertence ao grupo de ferramentas que fornecem suporte as mais diversas fases da construção de

**SINPATCO**  
*Sistema Inteligente para Diagnóstico de Patologias da Coluna Vertebral*

Ângulo de Incidência Pélvica

Ângulo de Versão Pélvica

Ângulo de Lordose

Declive Sacral

Raio Pélvico

Grau de Deslizamento

rede MLP  
 K-NN  
 Naive Bayes  
 Rede SOM  
 Rede GRNN

X

Resultado  
**DIAGNOSTICAR**

Regras:  
Observação: as variáveis x1, x2, x3, x4, x5 e x6 representam incidência pélvica, versão pélvica, lordose, declive sacral, raio pélvico e grau de deslizamento

Figura 5.1: interface gráfica do SINPATCO.

software, tais como: projeto, implementação e teste. O Eclipse apresenta Java, especificada pela Sun Microsystems, como linguagem padrão para desenvolvimento. Por este motivo o Eclipse é utilizado no desenvolvimento dos algoritmos e construção dos módulos do sistema.

A interface gráfica é desenvolvida com base em uma especificação Java conhecida como Java Server Pages (JSP), que possibilita o desenvolvimento de páginas HTML (*hypertext markup language*) dinâmicas com processamento no lado do servidor. O servidor Apache Tomcat 5.5, que permite processar este tipo de linguagem, é utilizado como servidor *web*, sendo escolhido principalmente por ser a implementação oficial de referência para a tecnologia JSP.

## 5.1 Metodologia

De uma forma geral, antes do treinamento para todos os algoritmos, a partir do conjunto  $T$  (conjunto com todas as 310 amostras) cria-se três conjuntos: um conjunto  $W$  sem amostras discrepantes, um conjunto  $N$  com as amostras que estão em  $T$  e não estão em  $W$ , e um terceiro conjunto  $S$  que relaciona o primeiro conjunto com o segundo da seguinte forma  $S = W \cup P(N, p)$ , em que  $P(N, p)$  representa um subconjunto de  $N$  dado por uma percentagem  $p$  de amostras selecionadas aleatoriamente.

A forma de separação para se criar os conjuntos  $W$  e  $N$  segue os procedimentos que são: remoção de padrões discrepantes e *data clean*. O primeiro procedimento divide-se em duas tarefas. A primeira tarefa está relacionada com a seleção de amostras, nas quais os valores para as componentes estejam fora da faixa  $\mu_i - 2\sigma_i > x_i > \mu_i + 2\sigma_i$ , em que  $\mu_i$  e  $\sigma_i$  são a média e o desvio padrão da  $i$ -ésima componente da amostra  $\mathbf{x}$ . A segunda tarefa refere-se a exclusão dentre as amostras selecionadas daquelas que apresentam uma ou mais componentes fora da faixa descrita.

Um processo de limpeza nos dados (do inglês *data clean*) é o segundo procedimento. Para este processo, calcula-se os centros de massa para cada um dos grupos, baseado nos rótulos fornecidos pelo especialista. Em seguida, para cada uma das amostras obtém-se a distância euclidiana entre esta e cada um dos centros de massa obtidos anteriormente, que são então armazenadas. Com base nos resultados armazenados, cada uma das amostras são associadas ao centro de massa, cuja distância euclidiana apresenta-se menor entre os protótipos e a amostra  $\mathbf{x}$ . Após esta associação, verifica-se o rótulo para amostras que se apresentam diferentes do rótulo considerado para um centro de massa de seu grupo. Então, caso isto se confirme, tais amostras são consideradas incomuns e devem ser removidas. Ao fim dos procedimentos descritos, com as amostras eliminadas forma-se o conjunto  $N$  enquanto com as amostras não-eliminadas forma-se o conjunto  $W$ , conjuntos utilizados no processo de aprendizagem.

No processo de aprendizagem, em que os algoritmos são executados um número  $n$  de vezes igual a 50, o conjunto  $S$  sofre uma divisão em dois: um para treinamento com 70% das amostras e um para teste com 30% das amostras restantes. Inicialmente, trabalha-se com um valor para  $p = 0\%$ , resultando em um conjunto  $S$  igual ao conjunto  $W$ . Este é usado como entrada no algoritmo de treinamento, e que gera como saída um classificador.

Obtido o classificador, é necessário uma verificação do quanto este consegue generalizar e resolver o problema proposto para dados não-apresentados (ou seja, pertencentes ao

conjunto de teste) e, por isso, não participam do treinamento. A fim de se obter dados para uma análise estatística, informações referentes a fase de treinamento e a fase de teste são armazenados: média no acerto para o conjunto de treinamento, média no acerto para o conjunto de teste, menor acerto para o conjunto de treinamento, maior acerto para o conjunto de teste e variância. Um outro resultado particular, conforme cada classificador, pode ser apresentado de acordo com o problema. O processo é repetido até que o conjunto  $S$  contenha todas as amostras disponíveis, para isto após cada conjunto de 50 execuções do algoritmo há um acréscimo em 20% de amostras do conjunto  $N$ . Assim, a cada conjunto de 50 execuções se forma um novo conjunto  $S$ .

A Tabela 5.1 apresenta o número de amostras contidas em  $S$  para cada percentagem de amostras discrepantes adicionada. Pode-se observar nesta tabela que para ausência de amostras discrepantes (0%) o número de amostras é igual a 195, para 100% igual a 310 amostras, enquanto para os conjuntos intermediários acréscimos de 23, 46, 69 e 92 amostras respectivamente para 20%, 40%, 60% e 80%. O número de amostras por classe para um dado conjunto  $S$  não é fixo, visto que apesar do número acrescentado ser fixo (por exemplo 23 amostras para 20% de *outliers*) as amostras são adicionadas aleatoriamente do conjunto de  $N$ .

<i>Outliers</i>	<i>Total de amostras</i>
0%	195
20%	218
40%	241
60%	264
80%	287
100%	310

**Tabela 5.1:** número de amostras do conjunto  $S$  por percentagem.

Após a explanação da forma de obtenção dos conjuntos de amostras utilizados nesse trabalho, é necessário definir os parâmetros de comparação entre os algoritmos avaliados. Tais parâmetros são: média de acerto para o conjunto de teste e a variância deste acerto para um número definido de execuções de treinamento para um algoritmo. Além destes dois, é importante também que se forneça uma análise da sensibilidade quanto à amostras discrepantes e uma análise comparativa de falsos negativos e falsos positivos. Um diagnóstico é denominado falso negativo quando um indivíduo patológico é diagnosticado saudável, e no outro caso, um diagnóstico é denominado falso positivo quando um indivíduo sadio é diagnosticado como patológico. Para o caso em estudo, um falso negativo representa o diagnóstico de espondilolistese ou hérnia de disco quando o indivíduo

está saudável; e um falso positivo representa o diagnóstico para saudável de um indivíduo com hérnia de disco ou espondilolistese.

O estudo de falso negativo e falso positivo é dado normalmente por matrizes que relacionam a classificação dada ou predita com a situação do indivíduo (saudável ou patológico). Uma matriz que permite este tipo de observação é denominada matriz de confusão. Como o objetivo é diagnosticar indivíduos que apresentam-se sadios ou com as patologias: espondilolistese e hérnia de disco, uma matriz de confusão para este fim deve conter logicamente 3 linhas e 3 colunas. Assim, pode-se assumir que, as linhas da matriz relacionam-se a situação do indivíduo e as colunas relacionam-se a predição realizada por um classificador. Os valores na primeira linha representam indivíduos com hérnia de disco, na segunda indivíduos com espondilolistese e na última indivíduos saudáveis. As colunas seguem a mesma ordem de distribuição contudo relacionam-se a predição realizada pelos classificadores.

	<i>diagnóstico 1</i>	<i>diagnóstico 2</i>	<i>diagnóstico 3</i>
diagnóstico 1	$a_{1,1}$	$a_{1,2}$	$a_{1,3}$
diagnóstico 2	$a_{2,1}$	$a_{2,2}$	$a_{2,3}$
diagnóstico 3	$a_{3,1}$	$a_{3,2}$	$a_{3,3}$

**Tabela 5.2:** explanação da matriz de confusão.

Baseado na descrição feita anteriormente em conjunto com a Tabela 5.2, pode-se afirmar que os elementos da diagonal principal da matriz de confusão,  $a_{1,1}$ ,  $a_{2,2}$  e  $a_{3,3}$ , representam os diagnósticos corretos, ou seja, a classificação inferida é igual a situação do indivíduo. Já os falso-negativos são representados pelos elementos  $a_{1,3}$  e  $a_{2,3}$ , pois, os indivíduos herniados e/ou com espondilolistese são dados como saudáveis; enquanto, os falsos positivos são representados pelos elementos  $a_{3,1}$  e  $a_{3,2}$ , quando, indivíduos saudáveis são diagnosticados como patológicos.

## 5.2 Resultados de Classificação

Nesta seção, os resultados relacionados com os classificadores são apresentados com base na ordem de desempenho obtida e não com base em nível de complexidade como no Capítulo 3, onde estes são descritos.

O projeto do MLP empregado baseia-se em uma rede com duas camadas: a camada escondida com um total de 12 neurônios (duas vezes o número de características de cada amostra) e 3 neurônios para a camada de saída. O número de neurônios de saída é fixado



em 3, devido à codificação adotada para as saídas desejadas (rótulos numérico das classes). Sendo escolhida uma codificação binária, na qual a saída desejada é igual a 1 (um) para o neurônio que representa a classe-alvo e 0 (zero) para as outras saídas desejadas. O rótulo numérico da classe de indivíduos normais é  $[1 \ 0 \ 0]$ , para classe de indivíduos com hérnia de disco é  $[0 \ 1 \ 0]$ , e para a classe com espondilolistese o rótulo é  $[0 \ 0 \ 1]$ . Esta codificação é adotada para todos os classificadores avaliados. A função de ativação utilizado em cada um dos neurônios em nas camadas é a logística.

No treinamento, o valor da taxa de aprendizagem inicia com um valor igual a 0,03, recalculando-se a cada época (apresentação de todas as amostras do conjunto de treinamento para ajuste dos pesos) com base em um decaimento exponencial deste valor, até chegar em 0,01. A fase de treinamento do algoritmo acaba em função do número de iterações, sendo fixada em 2500. Este valor é escolhido por motivos de comparação, visto que torna conveniente uma parada pré-fixada para análise de desempenho entre classificadores e também por que, em geral, a taxa de acerto para o conjunto de treinamento apresenta-se superior a 90% (quando da ausência de amostras discrepantes).

Executando-se 50 vezes o treinamento, a fim de obter 50 classificadores MLP, e se organizando os dados obtidos é possível construir a Tabela 5.3. Pode-se concluir desta tabela que o classificador consegue melhor desempenho quando o conjunto de dados está livre dos padrões incomuns, sendo o acerto médio no teste igual a 98,48%. Para esta percentagem os acertos máximos e mínimos obtidos são de 100% e 94,82%, respectivamente. Fazendo-se uma análise geral da tabela de resultados do MLP, verifica-se que o acréscimo de padrões incomuns resulta em uma diminuição do acerto médio no teste indicando uma redução no desempenho do classificador. Porém, apesar dessa diminuição, o menor valor para o acerto médio no teste apresenta-se próximo a 90% indicando uma grande capacidade de generalização.

<i>outliers</i>	acerto médio teste(%)	pioir acerto teste(%)	melhor acerto teste(%)	variância
0	98,48	94,82	100,00	2,01
20	93,82	90,71	98,48	4,26
40	91,69	90,27	95,83	2,48
60	90,74	88,55	94,96	3,29
80	89,86	88,37	94,18	2,21
100	89,67	88,11	93,54	2,48

**Tabela 5.3:** resultado geral da rede MLP.

A Tabela 5.4 apresenta a matriz de confusão do classificador MLP. Os dados obtidos

são referentes ao classificador que consegue melhor desempenho quando não são considerados padrões discrepantes. Analisando os dados contidos nesta tabela, pode-se verificar que não se encontram falsos positivos ou falsos negativos. Esse fato também demonstra o comportamento geral do MLP, com boa performance e alta taxa de acerto. Uma notação que serve para todas as matrizes apresentadas é a representação em *itálico* (nas colunas) do diagnóstico inferido pelo classificador para uma amostra  $\mathbf{x}$  apresentada, enquanto em fonte normal (nas linhas) representa a situação do indivíduo.

	<i>hérnia de disco</i>	<i>espondilolistese</i>	<i>normal</i>
hérnia de disco	5	0	0
espondilolistese	0	35	0
normal	0	0	18

**Tabela 5.4:** matriz de confusão da rede MLP.

O projeto do classificador  $k$ -NN baseia-se na distância euclidiana como métrica de proximidade e em um  $k$  igual a 7, pois para este valor de  $k$  obtêm-se os melhores resultados de generalização do classificador. A Tabela 5.5 apresenta os resultados obtidos para o classificador  $k$ -NN. Observando a primeira linha da tabela (com 0% de *outliers*), nota-se que o melhor resultado é 97,01% em média no acerto para as amostras de teste.

Fazendo-se uma análise geral da tabela de resultados do  $k$ -NN, pode-se verificar que o acréscimo de *outliers*, de forma similar ao que acontece com o MLP, resulta em uma diminuição do acerto médio no teste. Enquanto a variância, de acordo com esta tabela, apresenta seu menor valor quando da ausência de amostras discrepantes.

<i>outliers</i>	$k$	acerto médio teste(%)	pior acerto teste(%)	melhor acerto teste(%)	variância
0%	7	97,01	92,98	100,0	3,927
20%	7	90,94	81,25	98,43	13,46
40%	7	87,67	77,46	94,36	16,06
60%	7	82,77	73,07	92,30	22,00
80%	7	79,47	70,58	89,28	15,33
100%	7	75,75	68,47	82,60	13,58

**Tabela 5.5:** resultado geral do  $k$ -NN.

A matriz de confusão apresentada na Tabela 5.6 é referente ao melhor classificador  $k$ -NN obtido. Nesta tabela ocorrem: 1 falso positivo (elemento  $a_{3,1}$ , indivíduo saudável dito herniado); 1 falso negativo (elemento  $a_{1,3}$ , indivíduo herniado dito saudável); e por fim, 1 caso de indivíduo com espondilolistese dito herniado (elemento  $a_{2,1}$ ).

	<i>hérnia de disco</i>	<i>espondilolistese</i>	<i>normal</i>
<i>hérnia de disco</i>	4	0	1
<i>espondilolistese</i>	1	20	0
<i>normal</i>	1	0	11

**Tabela 5.6:** matriz de confusão do  $k$ -NN.

Para o classificador Naive Bayes é construída a Tabela 5.7 com os resultados obtidos após 50 execuções de treinamento/teste. Observando os valores do acerto médio para o conjunto de teste em função do acréscimo de outliers, nota-se uma diminuição da taxa de acerto. Obtendo-se um acerto médio de 96,62% quando não existe *outliers*, diminuindo com o acréscimo destas amostras e chegando a menor média para o grupo de teste com valor igual a 81,33%.

<i>outliers</i>	acerto médio teste(%)	pioir acerto teste(%)	melhor acerto teste(%)	variância
0%	96,62	91,37	100,0	4,96
20%	91,80	84,61	98,48	11,97
40%	89,38	83,33	95,89	10,21
60%	85,70	78,48	91,13	8,81
80%	83,57	77,90	89,53	9,48
100%	81,33	74,19	88,17	9,37

**Tabela 5.7:** resultado geral do *Naive Bayes*.

A Tabela 5.8 apresenta a matriz de confusão do classificador Naive Bayes. A tabela é construída com base nos dados obtidos referentes ao classificador que consegue melhor desempenho. Dos resultados, ocorre: 4 falsos positivos (elemento  $a_{3,1}$ , indivíduos saudáveis ditos herniados); 5 falsos negativos (elemento  $a_{2,3}$ , indivíduos com espondilolistese ditos saudáveis); e por fim, 4 casos de indivíduos com espondilolistese ditos apresentando hérnia de disco (elemento  $a_{2,1}$ ).

	<i>hérnia de disco</i>	<i>espondilolistese</i>	<i>normal</i>
<i>hérnia de disco</i>	8	0	0
<i>espondilolistese</i>	4	13	5
<i>normal</i>	4	0	5

**Tabela 5.8:** matriz de confusão do Naive Bayes.

O classificador SOM é projetado com base em uma grade bi-dimensional de  $9 \times 9$  neurônios. No treinamento, o número de iterações é calculado em 50 vezes o valor do

tamanho do conjunto de treinamento e o número de neurônios vizinhos ajustados ao decorrer das iterações, é determinado com base num decaimento exponencial, começando com uma vizinhança inicial de 9 neurônios e decaindo com o tempo até uma vizinhança igual a 1. O ajuste para vizinhança igual a 1 é alcançada com 80% do total de iterações do algoritmo, daí por diante nos 20% restante apenas o neurônio vencedor recebe atualização.

O valor da taxa de aprendizagem no treinamento da rede SOM também decai exponencialmente com o tempo, iniciando com um valor igual a 0.05 e chegando ao final com um valor em torno de 0.0001. Ao final do treinamento, usa-se o algoritmo LVQ para se conseguir um ajuste fino para os pesos dos neurônios.

A Tabela 5.9 contém os resultados após 50 execuções do classificador SOM. Dos resultados, verifica-se o melhor resultado com um acerto médio de 93,68% de classificação no teste, e como nos resultados mostrados anteriormente, nota-se uma diminuição do valor médio de acerto no teste quando *outliers* são acrescentados.

<i>outliers</i>	acerto médio teste(%)	pior acerto teste(%)	melhor acerto teste(%)	variância
0%	93,68	88,0	100,0	11,16
20%	87,84	78,0	95,0	18,99
40%	81,90	68,0	92,0	34,54
60%	77,50	66,0	90,0	25,92
80%	74,08	63,0	87,0	29,21
100%	70,24	57,0	81,0	23,49

**Tabela 5.9:** resultado geral da rede SOM.

A matriz de confusão é apresentada na Tabela 5.10 e contém informações do classificador SOM com melhor desempenho, ou seja, quando *outliers* são desconsiderados. Entre as classificações ocorre: 3 falsos positivos (elemento  $a_{3,1}$ , indivíduos saudáveis ditos herniados); 3 casos de indivíduos com espondilolistese ditos com hérnia de disco.

	<i>hérnia de disco</i>	<i>espondilolistese</i>	<i>normal</i>
<i>hérnia de disco</i>	7	0	0
<i>espondilolistese</i>	3	14	0
<i>normal</i>	3	0	12

**Tabela 5.10:** matriz de confusão da rede SOM.

A arquitetura da rede GRNN apresenta  $N$  neurônios na camada escondida, em que  $N$  representa o número de amostras utilizadas para treinamento, e três neurônios na camada

de saída. Nos neurônios da camada de saída utiliza-se função de ativação sigmóide do tipo hiperbólica.

Na Tabela 5.11 estão sintetizados os resultados para a rede GRNN. Ao verificar os dados da tabela, pode-se concluir que o melhor resultado é 95,79% também quando se considera o conjunto de treinamento sem amostras discrepantes. De uma forma geral, a classificação apresenta-se com bom desempenho, indicando uma boa generalização para o conjunto de teste. De forma similar ao que acontece com os outros classificadores o poder generalização diminui quando *outliers* são acrescentados.

<i>outliers</i>	acerto médio teste(%)	pioir acerto teste(%)	melhor acerto teste(%)	variância
0%	95,79	86,20	100,0	10,45
20%	89,38	81,53	96,92	11,13
40%	84,94	76,38	94,44	17,03
60%	81,06	72,15	88,60	13,07
80%	77,88	65,11	86,04	14,54
100%	75,78	64,51	87,09	23,04

**Tabela 5.11:** resultado geral do GRNN.

A Tabela 5.12 apresenta a matriz de confusão do GRNN, para o classificador com melhor desempenho, e são mostradas: 1 falso positivo (elemento  $a_{3,2}$ , indivíduo saudável dito com espondilolistese); 1 falso negativo (elemento  $a_{1,3}$ , indivíduo herniado dito saudável); e 1 indivíduo com hérnia de disco dito com espondilolistese.

	<i>hérnia de disco</i>	<i>espondilolistese</i>	<i>normal</i>
<i>hérnia de disco</i>	2	1	1
<i>espondilolistese</i>	0	11	0
<i>normal</i>	0	1	3

**Tabela 5.12:** matriz de confusão da rede GRNN.

Para o discriminante Linear, os resultados obtidos são vistos na Tabela 5.13. Analisando estes resultados pode-se concluir que o algoritmo tem baixa capacidade de generalização, pois, o maior acerto médio no teste é 57,63%, bem abaixo dos resultados obtidos anteriormente referente a outros classificadores. Ainda assim, mesmo que de forma menos significativa, a taxa de acerto médio para o conjunto de teste diminui quando *outliers* são acrescentados.

Para o Discriminante Quadrático os resultados obtidos são apresentados na Tabela

<i>outliers</i>	acerto médio treinamento(%)	acerto médio teste(%)	pior acerto teste(%)	melhor acerto teste(%)	variância
0%	56,55	56,37	18,75	95,31	490,75
20%	56,99	56,64	17,39	95,31	471,77
40%	57,42	57,19	17,39	95,31	421,31
60%	55,90	55,80	17,39	95,31	415,44
80%	54,03	53,94	14,77	95,31	419,49
100%	53,72	53,65	13,97	95,31	406,96

**Tabela 5.13:** resultado geral Discriminante Linear (covariância *pooled*).

5.14. Dos resultados, pode-se concluir que o classificador tem baixo desempenho de classificação, principalmente se comparado a outros classificadores apresentados anteriormente, pois apresentam valores entre 53 e 58% para o acerto médio no teste. Os acertos médios não apresentam melhora significativa quando *outliers* são extraídos, da mesma forma que acontece com o Discriminante Linear.

<i>outliers</i>	acerto médio treinamento(%)	acerto médio teste(%)	pior acerto teste(%)	melhor acerto teste(%)	variância
0%	58,19	58,00	6,25	98,43	692,82
20%	53,08	52,91	6,25	98,43	575,44
40%	55,60	55,39	6,25	98,43	511,87
60%	54,97	54,86	6,25	98,43	486,80
80%	54,59	54,51	6,25	98,43	454,18
100%	54,20	54,18	6,25	98,43	413,64

**Tabela 5.14:** resultado geral Discriminante Quadrático (covariância por classe).

Considerando os classificadores usados, uma síntese dos resultados é apresentada na Tabela 5.15, em que as linhas apresentam os acertos médios dos classificadores relativos a uma percentagem de *outliers* acrescentada e as colunas o acerto médio no teste por classificador. Dos resultados apresentados nesta tabela pode-se concluir que o Perceptron Multicamadas obteve melhores resultados quando comparado com os outros classificadores, vale observar que este apresenta o maior acerto médio. Em ordem de melhores resultados seguem MLP, *Naive Bayes*, *k*-NN, , GRNN e SOM (não se inclui os resultados dos discriminantes, pois, estes apresentam resultados bem abaixo dos discutidos). Os dados contidos na Tabela 5.15 podem ser vistos graficamente na Figura 5.2.

Após a discussão anterior, também para comparação, a Tabela 5.16 é usada para mostrar uma síntese das variâncias obtidas para o acerto médio no teste, por classificador

outliers	MLP(%)	$k$ -NN(%)	Naive Bayes(%)	GRNN(%)	SOM(%)
0%	98,48	97,01	96,62	95,79	93,68
20%	93,82	90,94	91,80	89,38	87,84
40%	91,69	87,67	89,38	84,94	81,90
60%	90,74	82,77	85,70	81,06	77,50
80%	89,86	79,47	83,57	77,88	74,08
100%	89,67	75,75	81,33	75,78	70,24

**Tabela 5.15:** resultado geral comparativo entre classificadores.

e quantidade de *outliers*. A observação dos valores contidos, revela que, o MLP tende a apresentar uma classificação com bons resultados, e não muito dispersos, mesmo que acrescente-se amostras incomuns, e ainda, apresenta menor variância quando comparado com outros classificadores.

outliers	MLP	$k$ -NN	Naive Bayes	GRNN	SOM
0 %	2,01	3,92	4,96	10,45	11,16
20 %	4,26	13,46	11,97	11,13	18,99
40 %	2,48	16,06	10,21	17,03	34,54
60 %	3,29	22,00	8,81	13,07	25,92
80 %	2,21	15,33	9,84	14,54	29,21
100 %	2,48	13,58	9,37	23,04	23,49

**Tabela 5.16:** variância de acerto médio no teste.

Analisando a Tabela 5.17 pode-se concluir através de uma comparação entre os erros para os vários algoritmos que o Perceptron Multicamadas apresenta menor quantidade de falso positivo e falso negativo, seguido por  $k$ -NN, SOM e naive Bayes. Como este tipo de erro é bastante crítico, já que, indivíduos não tratados podem ter seu caso agravado, ou indivíduos sadios podem sofrer tratamento desnecessário (o que pode gerar problemas de saúde) vê-se mais um ponto forte com relação ao MLP quando utilizado para classificação das patologias em estudo.

	MLP	$k$ -NN	Naive Bayes	GRNN	SOM
Falso Negativo	0	1	5	1	0
Falso Positivo	0	1	4	1	3

**Tabela 5.17:** relação falso positivo/negativo *versus* classificador.




Figura 5.2: acerto médio no teste para os classificadores.

### 5.3 Resultados de Extração de Regras

Nesta seção são apresentados os resultados relacionados ao módulo de explicação do sistema. As regras extraídas por este módulo permitem que o especialista possa ter uma explicação de uma forma mais amigável ao entendimento humano. No entanto, vale ressaltar que a intenção não é utilizar a base de regras para realizar classificação, embora a sua utilização seja possível, mas utilizá-la como subsídio para explicação destes resultados ao médico especialista.

Na Tabela 5.18 são mostrados os resultados obtidos (acerto médio) através da apresentação do conjunto de treinamento para a base de regras. O acerto médio é calculado com base em 50 execuções de classificação como no caso dos classificadores. Vale ressaltar que a taxa de acerto é determinada pela comparação do diagnóstico predito pelo classificador e pelo diagnóstico predito pela base, a fim de verificar o quanto as regras modelam o conhecimento embutido. Analisando os dados desta tabela, pode-se verificar que as regras



extraídas conseguem modelar bem o conhecimento, já que o acertos médios apresentam-se superiores a 92% e quando verificado o melhor caso (com 0% de *outliers*) apresenta valor próximo a 98%.

<i>outliers</i>	acerto médio regras(%)
0 %	97.46
20 %	95.96
40 %	94.78
60 %	94.42
80 %	93.48
100 %	92.72

**Tabela 5.18:** resultado regras rede SOM.

As regras extraídas da rede SOM estão na forma proposicional. Alguns exemplos de regras desta base podem ser observadas a seguir:

SE

$$43.349 \leq x_1 \leq 49.712 \text{ E } 7.5192 \leq x_2 \leq 13.320 \text{ E}$$

$$28.913 \leq x_3 \leq 37.420 \text{ E } 34.380 \leq x_4 \leq 40.060 \text{ E}$$

$$97.515 \leq x_5 \leq 112.26 \text{ E } 5.7532 \leq x_6 \leq 7.9185$$

ENTÃO

HÉRNIA DE DISCO;

SE

$$77.409 \leq x_1 \leq 88.024 \text{ E } 29.416 \leq x_2 \leq 42.689 \text{ E}$$

$$61.300 \leq x_3 \leq 82.850 \text{ E } 42.954 \leq x_4 \leq 51.952 \text{ E}$$

$$104.51 \leq x_5 \leq 125.35 \text{ E } 42.887 \leq x_6 \leq 93.563$$

ENTÃO

ESPONDILOLISTESE;

SE

$$59.167 \leq x_1 \leq 67.289 \text{ E } 14.604 \leq x_2 \leq 20.929 \text{ E}$$

$$32.529 \leq x_3 \leq 51.562 \text{ E } 44.604 \leq x_4 \leq 50.572 \text{ E}$$

$$120.53 \leq x_5 \leq 137.46 \text{ E } 1.5172 \leq x_6 \leq 4.9603$$

ENTÃO

NORMAL.

Nas regras apresentadas as variáveis  $x_1, x_2, \dots, x_6$  representam ângulo de incidência pélvica, ângulo de versão pélvica, ângulo de lordose, declive sacral, raio pélvico e grau de deslizamento.

Com base nas regras obtidas que são apresentadas na forma proposicional e com a utilização do conhecimento do especialista médico, tais regras podem ser transformadas em regras lingüísticas Fuzzy. Uma vantagem da utilização de regras do tipo Fuzzy é que estas tratam com conceitos do tipo: alto, baixo, médio dentre outros e se apresentam mais amigáveis ainda que as regras do tipo proposicional.

## 6 Conclusões e Trabalhos Futuros

Este último capítulo apresenta as conclusões, considerações finais e identifica trabalhos futuros relacionados com os assuntos abordados nesta dissertação.

### 6.1 Conclusão

O SINPATCO é um sistema que pode ser utilizado como ferramenta de auxílio ao diagnóstico do médico especializado em ortopedia. O sistema SINPATCO pode ser usado também por clínicos não-especialistas em ortopedia, a fim de minimizar a carência de ortopedistas em regiões remotas agilizando o atendimento e o encaminhamento do paciente para centros mais desenvolvidos.

O diagnóstico realizado pelo SINPATCO é feito por classificadores de padrões que compõem o módulo de classificação de patologias. Entre os classificadores de padrões que têm seus desempenhos avaliados, e podem compor o módulo de classificação, encontram-se: *Naive Bayes*, *k*-NN, rede MLP, rede SOM e rede GRNN. Dos resultados obtidos pode-se concluir e determinar que, para o problema de classificação de patologias da coluna vertebral, a rede MLP obteve melhor desempenho. Esta conclusão é resultante da combinação de três fatores importantes: a rede MLP obteve maior acerto médio para o conjunto de teste (superior a 98% com 0% de *outliers*); o classificador com melhor desempenho da rede MLP apresenta menor variância das taxas de acerto obtidas em relação aos outros classificadores com melhor desempenho (2,01 para 0% de *outliers*); e ainda a rede MLP obteve o menor erro relativo à falso positivo e falso negativo.

Por ordem decrescente de desempenho, com base na análise do acerto médio no teste, pode-se enumerar: a rede MLP, *Naive Bayes*, *k*-NN, o GRNN e a rede SOM. O Discriminante Linear e o Quadrático apresentam desempenho bem abaixo dos classificadores supracitados. Assim, o atendimento ao paciente com auxílio do SINPATCO, pode contar com classificadores de padrões que respondem bem as necessidades de classificação apresentados, pois, um erro considerado baixo é verificado.

O SINPATCO consegue elucidar para o médico como o sistema consegue chegar ao diagnóstico final através do módulo de explanação. Este módulo contém uma base de regras formada por regras proposicionais extraídas da rede SOM treinada. A base de regras gerada quando utilizada para classificação e comparada com a saída predita pelo classificador apresenta acerto igual a 97,46%, indicando que as regras extraídas conseguem extrair eficientemente as informações contidas nos neurônios. Assim, a hipótese feita inicialmente se verifica, pois a inferência realizada pela base de regras apresenta alta fidelidade e desta forma consegue explicar o processo realizado no diagnóstico.

Outra hipótese feita, relaciona-se com o desempenho dos classificadores de padrões obtidos quando no treinamento padrões incomuns são removidos. Com relação a esta hipótese e com base nos resultados para os classificadores implementados pode-se concluir que, em geral, a classificação se torna mais eficiente quando menos padrões incomuns estão presentes. Este fato é justificado, para a maioria dos classificadores, pelo aumento no desempenho de classificação à medida que padrões incomuns são removidos do conjunto de treinamento.

A hipótese na qual se espera um melhor desempenho para os classificadores neurais em relação aos classificadores convencionais não se verifica, pois o desempenho do *Naive Bayes* e o desempenho do *k*-NN apresentam-se melhores que os desempenhos obtidos com as redes SOM e GRNN. Por fim, com relação à utilidade dos atributos biomecânicos no projeto de classificadores de padrões, pode-se concluir com base nos diversos classificadores implementados e nos resultados satisfatórios obtidos que os atributos se fazem úteis e permitem a classificação de patologias da coluna vertebral.

## 6.2 **Trabalhos Futuros**

Como trabalhos futuros, pode-se sugerir a adição de um módulo ao sistema que automatize a extração de características de raios-x da coluna vertebral. Estender a classificação, fazendo o sistema capaz de auxiliar no diagnóstico de mais patologias que não apenas hérnia de disco e espondilolistese.

Com base nas regras extraídas das redes neurais e no conhecimento do especialista médico pode-se converter as regras do tipo proposicional para regras do tipo Fuzzy. Assim, um módulo poderia ser acrescentado que permitisse a configuração de conceitos e a definição de funções de pertinência relacionados aos atributos de classificação.

A utilização de um conjunto de classificadores, numa abordagem baseada em máquinas

---

de comitês, em que cada classificador funciona como juiz e há uma votação para que se determine o diagnóstico. Assim, a classificação de uma amostra é feita com base na classe mais observada dentre as preditas pelos classificadores.

## *Referências*

- ANDREWS, R.; DIEDERICH, J.; TICKLE, A. B. A survey and critique of techniques for extracting rules from trained artificial neural networks. *Knowledge-Based Systems*, v. 8, n. 6, p. 373–389, 1995.
- ANTANI, S. et al. Vertebra shape classification using MLP for content-based image retrieval. In: *Proceedings of the IEEE-INNS International Joint Conference on Neural Networks (IJCNN'03)*. [S.l.: s.n.], 2003. p. 160–165.
- BAXT, W. G. Application of artificial neural networks to clinical medicine. *Lancet*, v. 346, n. 8983, p. 1135–1138, 1995.
- BERTHONNAUD, E. et al. Sagittal spinopelvic radiological measurements of trunk balance. *European Spine Journal*, v. 1, p. 33, 2001.
- BOLOGNA, G. Rule extraction from a multi layer perceptron with staircase activation functions. In: *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks (IJCNN'00)*. [S.l.: s.n.], 2000. v. 3, p. 419–424.
- BRAUSE, R. Revolutionieren neuronale netze unsere vorhersagefähigkeiten. *Zentralblatt für Chirurgie*, p. 692–698, 1999.
- BREIMAN, L.; MEISEL, W.; PURCELL, E. Variable kernel estimates of multivariate densities. *Technometrics*, v. 19, n. 2, p. 135–144, 1977.
- CACOULLOS, T. Estimation of a multivariate density. *Annals of the Institute of Statistical Mathematics*, v. 18, p. 179–189, 1966.
- CAMPOS, M. A. *Exercícios Abdominais: uma abordagem prática e científica*. [S.l.: Sprint, Rio de Janeiro, 2002.
- CASTRO, J. L.; MANTAS, C. J.; BENITEZ, J. M. Interpretation of artificial neural networks by means of fuzzy rules. *IEEE Transactions on Neural Networks*, v. 13, n. 1, p. 101–116, 2002.
- CHALUP, S.; HAYWARD, R.; DIEDERICH, J. Rule extraction from artificial neural networks trained on elementary number classification tasks. In: *Australian Neural Network Conference (ACNN'98), The University of Queensland, Brisbane 1998*. [S.l.: s.n.], 1998. p. 265–270.
- CHERUKURI, M. et al. Anterior osteophyte discrimination in lumbar vertebrae using size-invariant features. *Computerized Medical Imaging and Graphics*, v. 28, n. 1-2, p. 99–108, 2004.

- CRAVEN, M.; SHAVLIK, J. Extracting tree-structured representations of trained networks. In: TOURETZKY, D. S.; MOZER, M. C.; HASSELMO, M. E. (Ed.). *Advances in Neural Information Processing Systems*. [S.l.]: The MIT Press, 1996. v. 8, p. 24–30.
- CRAVEN, M. W.; SHAVLIK, J. W. Using sampling and queries to extract rules from trained neural networks. In: *Proceedings of the Eleventh International Conference on Machine Learning*. [S.l.: s.n.], 1994. p. 37–45.
- DARRAH, M.; TAYLOR, B.; SKIAS, S. Rule extraction from dynamic cell structure neural network used in a safety critical application. In: *FLAIRS Conference*. [S.l.: s.n.], 2004.
- DREISEITL, S.; BINDER, M. Do physicians value decision support? a look at the effect of decision support systems on physician opinion. *Artificial Intelligence in Medicine*, v. 33, n. 1, p. 25–30, 2005.
- DYBOWSKI, R. Neural computation in medicine: Perspective and prospects. In: MALMGREN, H.; BORGA, M.; NIKLASSON, L. (Ed.). *Proceedings of the 1st Conference on Artificial Neural Networks in Medicine and Biology (ANNIMAB-1)*. [S.l.: s.n.], 2000. p. 26–36.
- FIÉRE, V.; DA MOTA, H. Discal herniation pelvic incidence and spinopelvic balance: a correlation study. *European Spine Journal*, v. 1, p. 45, 2001.
- FLOREA, F. et al. Comparison of feature-selection and classification techniques for medical images modality categorization. *Rapport Interne PSI No. 01/FIF*, 2004.
- FRIEDMAN, J. H. Regularized discriminant analysis. *Journal of the American Statistical Association*, v. 84, p. 165–175, 1989.
- FU, L. M. Rule generation from neural networks. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 24, n. 8, p. 1114–1124, 1994.
- GALLANT, S. Connectionist expert systems. *Communications of the ACM*, v. 31, n. 2, p. 152–169, 1988.
- GILES, C.; OMLIN, C. Extraction, insertion and refinement of symbolic rules in dynamically-driven recurrent neural networks. *Connection Science*, v. 5, n. 3–4, p. 307–337, 1993. Special Issue on Architectures for Integrating Symbolic and Neural Processes.
- GILES, C. L. et al. Learning and extracting finite state automata with second-order recurrent neural networks. *Neural Computation*, v. 4, p. 393–405, 1992.
- GRIGSBY, J.; KOOKEN, R.; HERSHBERGER, J. Simulated neural networks to predict outcomes, costs, and length of stay among orthopedic rehabilitation patients. *Archives of Physical Medicine and Rehabilitation*, v. 75, n. 10, p. 1077–1081, 1994.
- HALL, S. J. *Biomecânica Básica*. [S.l.]: Guanabara Koogan, Rio de Janeiro, 2000.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2nd. ed. [S.l.]: Prentice-Hall, 1999.

- HERBERT, S. *Ortopedia e Traumatologia: Princípios e prática*. [S.l.]: Artmed, Porto Alegre, 1998.
- HERTZ, J.; KROGH, A.; PALMER, R. G. *Introduction to the theory of neural computation*. Redwood City, CA: Addison-Wesley, 1991.
- JAIN, A.; CHANDRASEKARAN, B. Dimensionality and sample size considerations in pattern recognition practice. In: \_\_\_\_\_. *Handbook of Statistics*. [S.l.]: North-Holland, 1982. v. 2, cap. 39, p. 835–855.
- JAIN, A.; DUIN, P.; MAO, J. Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 1, p. 4–37, 2000.
- JOHN, G.; LANGLEY, P. Counterfactuals and policy analysis in structural models. In: . [S.l.: s.n.], 1995. p. 338–345.
- KNOPLICH, J. *Enfermidades da Coluna Vertebral*. [S.l.]: Robe Editorial, São Paulo, 2003.
- KOHONEN, T. *Self-Organizing Maps*. 3rd. ed. [S.l.]: Springer-Verlag, 2001.
- KOSKO, B. *Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence*. [S.l.]: Prentice-Hall, 1992.
- KUNCHEVA, L. I.; STEIMANN, F. Fuzzy diagnosis. *Artificial Intelligence in Medicine*, v. 16, n. 2, p. 121–128, 1999.
- LABELLE, H.; ROUSSOULY, P.; BERTHONNAUD, E. The importance of spino pelvic balance in l5 s1 developmental spondylolisthesis. *SPINE*, v. 30, n. 6, p. 27–34, 2005.
- MAIRE, F. Rule-extraction by backpropagation of polyhedra. *Neural Networks*, v. 12, n. 4–5, p. 717–725, 1999.
- MASUOKA, R. et al. Neurofuzzy systems fuzzy inference using a structured neural network. In: *Proceedings of the International Conference on Fuzzy Logic and Neural Networks*. [S.l.: s.n.], 1990. p. 173–177.
- MERCÚRIO, R. *Dor nas Costas Nunca Mais*. [S.l.]: Manole, São Paulo, 1998.
- OEHLER, K. L.; GRAY, R. M. Combining image compression and classification using vector quantization. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 17, n. 5, p. 461–473, 1995.
- OHNO-MACHADO, L.; ROWLAND, T. Neural network applications in physical medicine and rehabilitation. *American Journal of Physical Medicine & Rehabilitation*, v. 78, n. 4, p. 392–398, 1999.
- OMLIN, C. W.; GILES, C. L.; MILLER, C. Heuristics for the extraction of rules from discrete-time recurrent neural networks. In: *Proceedings International Joint Conference on Neural Networks 1992*. [S.l.: s.n.], 1992. I, p. 33–38.
- PAPIK, K. et al. Application of neural networks in medicine - a review. *Medical Science Monitor*, v. 4, n. 3, p. 538–546, 1998.



- RAMESH, A. N. et al. Artificial intelligence in medicine. *Annals of the Royal College of Surgeons of England*, v. 86, n. 5, p. 334–338, 2004.
- REGGIA, J. A. Neural computation in medicine. *Artificial Intelligence in Medicine*, v. 5, n. 2, p. 143–157, 1993.
- ROBERT, C. et al. Bibliometric overview of the utilization of artificial neural networks in medicine and biology. *Scientometrics*, v. 59, n. 1, p. 117–130, 2004.
- SCHOLLHORN, W. I. Applications of artificial neural nets in clinical biomechanics. *Clinical Biomechanics*, v. 19, n. 9, p. 876–898, 2004.
- SETIONO, R. Extracting rules from neural networks by pruning and hidden-unit splitting. *Neural Computation*, v. 9, n. 1, p. 205–225, 1997.
- SETIONO, R. Extracting m-of-n rules from trained neural networks. *IEEE Transactions on Neural Networks*, v. 11, n. 2, p. 512–519, 2000.
- SPECHT, D. F. Generation of polynomial discriminant functions for pattern recognition. *IEEE Transactions on Electronic Computers*, EC-16, n. 3, p. 308–319, 1967.
- SPECHT, D. F. Probabilistic neural networks. *NNks*, v. 3, p. 109–118, 1990.
- STEIMANN, F. On the use and usefulness of fuzzy sets in medical AI. *Artificial Intelligence in Medicine*, v. 21, n. 1-3, p. 131–137, 2001.
- TAHA, I.; GHOSH, J. Symbolic interpretation of artificial neural networks. *IEEE Transactions on Knowledge and Data Engineering*, v. 11, n. 3, p. 448–463, May/June 1999.
- THOPSON, J. R.; TAPIA, R. A. *Nonparametric Function Estimation, Modeling, and Simulation*. Philadelphia: Society for Industrial and Applied Mathematics, 1990.
- THRUN, S. Extracting rules from artificial neural networks with distributed representations. In: *Advances in Neural Information Processing Systems 7*. [S.l.: s.n.], 1995.
- THRUN, S. B.; BALA, J.; BLOEDORN, E. *The MONK's Problems: A Performance Comparison of Different Learning Algorithms*. Pittsburgh, PA, 1991.
- TOWELL, G.; SHAVLIK, J. W. The extraction of refined rules from knowledge-based neural networks. *Machine Learning*, v. 13, n. 1, p. 71–101, 1993.
- TRIBASTONE, F. *Tratado de Exercícios Corretivos: aplicados à reeducação motora postural*. [S.l.]: Manole, São Paulo, 2001.
- TSAKONAS, A. et al. Evolving rule-based systems in two medical domains using genetic programming. *Artificial Intelligence in Medicine*, v. 32, n. 3, p. 195–216, 2003.
- TSUKIMOTO, H. On continuously valued logical functions satisfying all axioms of classical logic. *Syst. Comput. Japan*, v. 25, n. 12, p. 33–41, 1994.
- TSUKIMOTO, H. Extracting rules from trained neural networks. *IEEE Transactions on Neural networks*, v. 11, n. 2, p. 377–389, 2000.

- VERDERI, E. *Hérnia de Disco Lombar: Causas, procedimentos e recuperação*. [S.l.]: Programa nacional de extensão universitária (Apostila) - FMU , São Paulo, 2004.
- VON DER MALSBURG, C. Self-organization in the brain. In: ARBIB, M. (Ed.). *The Handbook of Brain Theory and Neural Networks*. 2nd. ed. Cambridge, MA: MIT Press, 2003. p. 1002–1005.
- WATANABE, S. *Pattern Recognition: Human and Mechanical*. [S.l.]: Willey, New York, 1985.
- WEBB, A. *Statistical Pattern Recognition*. 2nd. ed. [S.l.]: John Wiley & Sons, 2002.
- XIE, Q. B.; LASZLO, C. A.; WARD, R. Vector quantization technique for nonparametric classifier design. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 15, p. 326–330, 1993.
- ZHOU, Z.; CHEN, S.; CHEN, Z. A statistics based approach for extracting priority rules from trained neural networks. In: . [S.l.: s.n.], 2000. v. 3, p. 401–406.
- ZHOU, Z.; JIANG, Y.; CHEN, S. Extracting symbolic rules from trained neural network ensembles. *AI Communications*, v. 16, n. 1, p. 3–15, 2003.
- ZINI, G. Artificial intelligence in hematology. *Hematology*, v. 10, n. 5, p. 393–400, 2005.

## *APÊNDICE A – Base de Dados*

A base de dados agrupada possui 310 amostras, das quais: 60 pertencem a indivíduos com hérnia de disco, 150 a indivíduos com espondilolistese e 100 a indivíduos saudáveis. Cada uma das amostras desta base possui seis características, relacionadas aos parâmetros angulares sagitais do sistema espinopélvico, que são: ângulo de incidência pélvica, ângulo de versão pélvica, ângulo de lordose, declive sacral, raio pélvico e grau de deslizamento. Na tabela a seguir são apresentados os valores para cada uma das amostras.

incidência pélvica	versão pélvica	ângulo de lordose	declive sacral	raio pélvico	grau de deslizamento	classe
63.02	22.55	39.60	40.47	98.672	-0.25	hérnia de disco
39.05	10.06	25.01	28.99	114.40	4.564	hérnia de disco
68.83	22.21	50.09	46.61	105.98	-3.53	hérnia de disco
69.29	24.65	44.31	44.64	101.86	11.21	hérnia de disco
49.71	9.652	28.31	40.06	108.16	7.918	hérnia de disco
40.25	13.92	25.12	26.32	130.32	2.230	hérnia de disco
53.43	15.86	37.16	37.56	120.56	5.988	hérnia de disco
45.36	10.75	29.03	34.61	117.27	-10.6	hérnia de disco
43.79	13.53	42.69	30.25	125.00	13.28	hérnia de disco
36.68	5.010	41.94	31.67	84.241	0.664	hérnia de disco
49.70	13.04	31.33	36.66	108.64	-7.82	hérnia de disco
31.23	17.71	15.5	13.51	120.05	0.499	hérnia de disco
48.91	19.96	40.26	28.95	119.32	8.028	hérnia de disco
53.57	20.46	33.1	33.11	110.96	7.044	hérnia de disco
57.30	24.18	46.99	33.11	116.80	5.766	hérnia de disco
44.31	12.53	36.09	31.78	124.11	5.415	hérnia de disco
63.83	20.36	54.55	43.47	112.30	-0.62	hérnia de disco
31.27	3.144	32.56	28.13	129.01	3.623	hérnia de disco
38.69	13.44	31.0	25.25	123.15	1.429	hérnia de disco

incidência pélvica	versão pélvica	ângulo de lordose	declive sacral	raio pélvico	grau de deslizamento	classe
41.72	12.25	30.12	29.47	116.58	-1.24	hérnia de disco
43.92	14.17	37.83	29.74	134.46	6.451	hérnia de disco
54.91	21.06	42.19	33.85	125.21	2.432	hérnia de disco
63.07	24.41	53.99	38.65	106.42	15.77	hérnia de disco
45.54	13.06	30.29	32.47	117.98	-4.98	hérnia de disco
36.12	22.75	29.0	13.36	115.57	-3.23	hérnia de disco
54.12	26.65	35.32	27.47	121.44	1.571	hérnia de disco
26.14	10.75	14.0	15.38	125.20	-10.0	hérnia de disco
43.58	16.50	46.99	27.07	109.27	8.992	hérnia de disco
44.55	21.93	26.78	22.61	111.07	2.652	hérnia de disco
66.87	24.89	49.27	41.98	113.47	-2.00	hérnia de disco
50.81	15.40	42.52	35.41	112.19	10.86	hérnia de disco
46.39	11.07	32.13	35.31	98.774	6.386	hérnia de disco
44.93	17.44	27.78	27.49	117.98	5.569	hérnia de disco
38.66	12.98	39.99	25.67	124.91	2.703	hérnia de disco
59.59	31.99	46.56	27.59	119.33	1.474	hérnia de disco
31.48	7.826	24.28	23.65	113.83	4.393	hérnia de disco
32.09	6.989	35.99	25.10	132.26	6.413	hérnia de disco
35.70	19.44	20.7	16.26	137.54	-0.26	hérnia de disco
55.84	28.84	47.69	26.99	123.31	2.812	hérnia de disco
52.41	19.01	35.87	33.40	116.55	1.694	hérnia de disco
35.49	11.70	15.59	23.79	106.93	-3.46	hérnia de disco
46.44	8.395	29.03	38.04	115.48	2.045	hérnia de disco
53.85	19.23	32.77	34.62	121.67	5.329	hérnia de disco
66.28	26.32	47.49	39.95	121.21	-0.79	hérnia de disco
56.03	16.29	62.27	39.73	114.02	-2.32	hérnia de disco
50.91	23.01	46.99	27.89	117.42	-2.52	hérnia de disco
48.33	22.22	36.18	26.10	117.38	6.481	hérnia de disco
41.35	16.57	30.70	24.77	113.26	-4.49	hérnia de disco
40.55	17.97	34.0	22.57	121.04	-1.53	hérnia de disco
41.76	17.89	20.03	23.86	118.36	2.062	hérnia de disco
55.28	20.44	34.0	34.84	115.87	3.558	hérnia de disco
74.43	41.55	27.7	32.87	107.94	5.000	hérnia de disco
50.20	29.76	36.10	20.44	128.29	5.740	hérnia de disco
30.14	11.91	34.0	18.23	112.68	11.46	hérnia de disco
41.17	17.32	33.46	23.85	116.37	-9.56	hérnia de disco
47.65	13.27	36.67	34.38	98.249	6.273	hérnia de disco
43.34	7.467	28.06	35.88	112.77	5.753	hérnia de disco
46.85	15.35	38.0	31.50	116.25	1.662	hérnia de disco
43.20	19.66	35.0	23.54	124.84	-2.91	hérnia de disco
48.10	14.93	35.56	33.17	124.05	7.947	hérnia de disco
74.37	32.05	78.77	42.32	143.56	56.12	espondilolistese
89.68	32.70	83.13	56.97	129.95	92.02	espondilolistese
44.52	9.433	51.99	35.09	134.71	29.10	espondilolistese
77.69	21.38	64.42	56.30	114.81	26.93	espondilolistese

incidência pélvica	versão pélvica	ângulo de lordose	declive sacral	raio pélvico	grau de deslizamento	classe
76.14	21.93	82.96	54.21	123.93	10.43	espondilolistese
83.93	41.28	61.99	42.64	115.01	26.58	espondilolistese
78.49	22.18	59.99	56.30	118.53	27.38	espondilolistese
75.64	19.33	64.14	56.30	95.903	69.55	espondilolistese
72.07	18.94	50.99	53.13	114.21	1.010	espondilolistese
58.59	-0.26	51.49	58.86	102.04	28.05	espondilolistese
72.56	17.38	51.99	55.17	119.19	32.10	espondilolistese
86.90	32.92	47.79	53.97	135.07	101.7	espondilolistese
84.97	33.02	60.85	51.95	125.65	74.33	espondilolistese
55.51	20.09	43.99	35.41	122.64	34.55	espondilolistese
72.22	23.07	90.99	49.14	137.73	56.80	espondilolistese
70.22	39.82	68.11	30.39	148.52	145.3	espondilolistese
86.75	36.04	69.22	50.71	139.41	110.8	espondilolistese
58.78	7.667	53.33	51.11	98.501	51.58	espondilolistese
67.41	17.44	60.14	49.96	111.12	33.15	espondilolistese
47.74	12.08	38.99	35.65	117.51	21.68	espondilolistese
77.10	30.46	69.48	46.63	112.15	70.75	espondilolistese
74.00	21.12	57.37	52.88	120.20	74.55	espondilolistese
88.62	29.08	47.56	59.53	121.76	51.80	espondilolistese
81.10	24.79	77.88	56.30	151.83	65.21	espondilolistese
76.32	42.39	57.19	33.92	124.26	50.12	espondilolistese
45.44	9.906	44.99	35.53	163.07	20.31	espondilolistese
59.78	17.87	59.20	41.90	119.31	22.12	espondilolistese
44.91	10.21	44.63	34.69	130.07	37.36	espondilolistese
56.60	16.80	41.99	39.80	127.29	24.01	espondilolistese
71.18	23.89	43.69	47.29	119.86	27.28	espondilolistese
81.65	28.74	58.23	52.90	114.76	30.60	espondilolistese
70.95	20.15	62.85	50.79	116.17	32.52	espondilolistese
85.35	15.84	71.66	69.50	124.41	76.02	espondilolistese
58.10	14.83	79.64	43.26	113.58	50.23	espondilolistese
94.17	15.38	67.70	78.79	114.89	53.25	espondilolistese
57.52	33.64	50.90	23.87	140.98	148.7	espondilolistese
96.65	19.46	90.21	77.19	120.67	64.08	espondilolistese
74.72	19.75	82.73	54.96	109.35	33.30	espondilolistese
77.65	22.43	93.89	55.22	123.05	61.21	espondilolistese
58.52	13.92	41.46	44.59	115.51	30.38	espondilolistese
84.58	30.36	65.47	54.22	108.01	25.11	espondilolistese
79.93	18.77	63.31	61.16	114.78	38.53	espondilolistese
70.39	13.46	61.19	56.92	102.33	25.53	espondilolistese
49.78	6.466	52.99	43.31	110.86	25.33	espondilolistese
77.40	29.39	63.23	48.01	118.45	93.56	espondilolistese
65.00	27.60	50.94	37.40	116.58	7.015	espondilolistese
65.01	9.838	57.73	55.17	94.738	49.69	espondilolistese
78.42	33.42	76.27	45.0	138.55	77.15	espondilolistese
63.17	6.330	62.99	56.84	110.64	42.60	espondilolistese

incidência pélvica	versão pélvica	ângulo de lordose	declive sacral	raio pélvico	grau de deslizamento	classe
68.61	15.08	63.01	53.53	123.43	39.49	espondilolistese
63.90	13.70	62.12	50.19	114.12	41.42	espondilolistese
84.99	29.61	83.35	55.38	126.91	71.32	espondilolistese
42.02	-6.55	67.89	48.57	111.58	27.33	espondilolistese
69.75	19.27	48.49	50.47	96.491	51.16	espondilolistese
80.98	36.84	86.96	44.14	141.08	85.87	espondilolistese
129.8	8.404	48.38	121.4	107.69	418.5	espondilolistese
70.48	12.48	62.41	57.99	114.19	56.90	espondilolistese
86.04	38.75	47.87	47.29	122.09	61.98	espondilolistese
65.53	24.15	45.77	41.37	136.44	16.37	espondilolistese
60.75	15.75	43.19	45.0	113.05	31.69	espondilolistese
54.74	12.09	40.99	42.64	117.64	40.38	espondilolistese
83.87	23.07	87.14	60.80	124.64	80.55	espondilolistese
80.07	48.06	52.40	32.00	110.70	67.72	espondilolistese
65.66	10.54	56.48	55.12	109.16	53.93	espondilolistese
74.71	14.32	32.5	60.39	107.18	37.01	espondilolistese
48.06	5.687	57.05	42.37	95.443	32.83	espondilolistese
70.67	21.70	59.18	48.97	103.00	27.81	espondilolistese
80.43	16.99	66.53	63.43	116.43	57.78	espondilolistese
90.51	28.27	69.81	62.24	100.89	58.82	espondilolistese
77.23	16.73	49.77	60.49	110.69	39.78	espondilolistese
50.06	9.120	32.16	40.94	99.712	26.76	espondilolistese
69.78	13.77	57.99	56.00	118.93	17.91	espondilolistese
69.62	21.12	52.76	48.50	116.80	54.81	espondilolistese
81.75	20.12	70.56	61.63	119.42	55.50	espondilolistese
52.20	17.21	78.09	34.99	136.97	54.93	espondilolistese
77.12	30.34	77.48	46.77	110.61	82.09	espondilolistese
88.02	39.84	81.77	48.17	116.60	56.76	espondilolistese
83.39	34.31	78.42	49.08	110.46	49.67	espondilolistese
72.05	24.70	79.87	47.35	107.17	56.42	espondilolistese
85.09	21.06	91.73	64.02	109.06	38.03	espondilolistese
69.56	15.40	74.43	54.16	105.06	29.70	espondilolistese
89.50	48.90	72.00	40.60	134.63	118.3	espondilolistese
85.29	18.27	100.7	67.01	110.66	58.88	espondilolistese
60.62	20.59	64.53	40.03	117.22	104.8	espondilolistese
60.04	14.30	58.03	45.73	105.13	30.40	espondilolistese
85.64	42.68	78.75	42.95	105.14	42.88	espondilolistese
85.58	30.45	78.23	55.12	114.86	68.37	espondilolistese
55.08	-3.75	55.99	58.84	109.91	31.77	espondilolistese
65.75	9.832	50.82	55.92	104.39	39.30	espondilolistese
79.24	23.94	40.79	55.30	98.622	36.70	espondilolistese
81.11	20.69	60.68	60.42	94.018	40.51	espondilolistese
48.03	3.969	58.34	44.06	125.35	35.00	espondilolistese
63.40	14.11	48.13	49.28	111.91	31.78	espondilolistese
57.28	15.14	63.99	42.13	116.73	30.34	espondilolistese

incidência pélvica	versão pélvica	ângulo de lordose	declive sacral	raio pélvico	grau de deslizamento	classe
41.18	5.792	42.86	35.39	103.34	27.66	espondilolistese
66.80	14.55	72.08	52.25	82.456	41.68	espondilolistese
79.47	26.73	70.65	52.74	118.58	61.70	espondilolistese
44.21	1.507	46.11	42.70	108.62	42.81	espondilolistese
57.03	0.345	49.19	56.68	103.04	52.16	espondilolistese
64.27	12.50	68.70	51.76	95.252	39.40	espondilolistese
92.02	35.39	77.41	56.63	115.72	58.05	espondilolistese
67.26	7.194	51.69	60.06	97.801	42.13	espondilolistese
118.1	38.44	50.83	79.69	81.024	74.04	espondilolistese
115.9	37.51	76.79	78.40	104.69	81.19	espondilolistese
53.94	9.306	43.10	44.63	124.39	25.08	espondilolistese
83.70	20.26	77.11	63.43	125.48	69.27	espondilolistese
56.99	6.874	57.00	50.11	109.97	36.81	espondilolistese
72.34	16.42	59.86	55.92	70.082	12.07	espondilolistese
95.38	24.82	95.15	70.55	89.307	57.66	espondilolistese
44.25	1.101	38.0	43.15	98.274	23.91	espondilolistese
64.80	15.17	58.83	49.63	111.67	21.40	espondilolistese
78.40	14.04	79.69	64.35	104.73	12.39	espondilolistese
56.66	13.45	43.76	43.21	93.692	21.10	espondilolistese
50.82	9.064	56.29	41.76	78.999	23.04	espondilolistese
61.41	25.38	39.09	36.02	103.40	21.84	espondilolistese
56.56	8.961	52.57	47.60	98.777	50.70	espondilolistese
67.02	13.28	66.15	53.74	100.71	33.98	espondilolistese
80.81	19.23	61.64	61.57	89.471	44.16	espondilolistese
80.65	26.34	60.89	54.30	120.10	52.46	espondilolistese
68.72	49.43	68.05	19.29	125.01	54.69	espondilolistese
37.90	4.479	24.71	33.42	157.84	33.60	espondilolistese
64.62	15.22	67.63	49.39	90.298	31.32	espondilolistese
75.43	31.53	89.59	43.89	106.82	54.96	espondilolistese
71.00	37.51	84.53	33.48	125.16	67.77	espondilolistese
81.05	20.80	91.78	60.25	125.43	38.18	espondilolistese
91.46	24.50	84.62	66.96	117.30	52.62	espondilolistese
81.08	21.25	78.76	59.82	90.071	49.15	espondilolistese
60.41	5.265	59.81	55.15	109.03	30.26	espondilolistese
85.68	38.65	82.68	47.03	120.84	61.95	espondilolistese
82.40	29.27	77.05	53.13	117.04	62.76	espondilolistese
43.71	9.811	51.99	33.90	88.434	40.88	espondilolistese
86.47	40.30	61.14	46.16	97.404	55.75	espondilolistese
74.46	33.28	66.94	41.18	146.46	124.9	espondilolistese
70.25	10.34	76.37	59.91	119.23	32.66	espondilolistese
72.64	18.92	67.99	53.71	116.96	25.38	espondilolistese
71.24	5.268	85.99	65.97	110.70	38.25	espondilolistese
63.77	12.76	65.36	51.00	89.822	55.99	espondilolistese
58.82	37.57	125.7	21.25	135.62	117.3	espondilolistese
74.85	13.90	62.69	60.94	115.20	33.17	espondilolistese

incidência pélvica	versão pélvica	ângulo de lordose	declive sacral	raio pélvico	grau de deslizamento	classe
75.29	16.67	61.29	58.62	118.88	31.57	espondilolistese
63.36	20.02	67.49	43.33	130.99	37.55	espondilolistese
67.51	33.27	96.28	34.23	145.60	88.30	espondilolistese
76.31	41.93	93.28	34.38	132.26	101.2	espondilolistese
73.63	9.711	62.99	63.92	98.727	26.97	espondilolistese
56.53	14.37	44.99	42.15	101.72	25.77	espondilolistese
80.11	33.94	85.10	46.16	125.59	100.2	espondilolistese
95.48	46.55	58.99	48.93	96.683	77.28	espondilolistese
74.09	18.82	76.03	55.27	128.40	73.38	espondilolistese
87.67	20.36	93.82	67.31	120.94	76.73	espondilolistese
48.25	16.41	36.32	31.84	94.882	28.34	espondilolistese
38.50	16.96	35.11	21.54	127.63	7.986	normal
54.92	18.96	51.60	35.95	125.84	2.001	normal
44.36	8.945	46.90	35.41	129.22	4.994	normal
48.31	17.45	47.99	30.86	128.98	-0.91	normal
45.70	10.65	42.57	35.04	130.17	-3.38	normal
30.74	13.35	35.90	17.38	142.41	-2.00	normal
50.91	6.676	30.89	44.23	118.15	-1.05	normal
38.12	6.557	50.44	31.56	132.11	6.338	normal
51.62	15.96	35.0	35.65	129.38	1.009	normal
64.31	26.32	50.95	37.98	106.17	3.118	normal
44.48	21.78	31.47	22.70	113.77	-0.28	normal
54.95	5.865	52.99	49.08	126.97	-0.63	normal
56.10	13.10	62.63	42.99	116.22	31.17	normal
69.39	18.89	75.96	50.50	103.58	-0.44	normal
89.83	22.63	90.56	67.19	100.50	3.040	normal
59.72	7.724	55.34	52.00	125.17	3.235	normal
63.95	16.06	63.12	47.89	142.36	6.298	normal
61.54	19.67	52.89	41.86	118.68	4.815	normal
38.04	8.301	26.23	29.74	123.80	3.885	normal
43.43	10.09	36.03	33.34	137.43	-3.11	normal
65.61	23.13	62.58	42.47	124.12	-4.08	normal
53.91	12.93	38.99	40.97	118.19	5.074	normal
43.11	13.81	40.34	29.30	128.51	0.970	normal
40.68	9.148	31.02	31.53	139.11	-2.51	normal
37.73	9.386	41.99	28.34	135.74	13.68	normal
63.92	19.97	40.17	43.95	113.06	-11.0	normal
61.82	13.59	63.99	48.22	121.77	1.296	normal
62.14	13.96	57.99	48.17	133.28	4.955	normal
69.00	13.29	55.57	55.71	126.61	10.83	normal
56.44	19.44	43.57	37.00	139.18	-1.85	normal
41.64	8.835	36.03	32.81	116.55	-6.05	normal
51.52	13.51	35.0	38.01	126.71	13.92	normal
39.08	5.536	26.93	33.55	131.58	-0.75	normal
34.64	7.514	42.99	27.13	123.98	-4.08	normal



incidência pélvica	versão pélvica	ângulo de lordose	declive sacral	raio pélvico	grau de deslizamento	classe
63.02	27.33	51.60	35.69	114.50	7.439	normal
47.80	10.68	53.99	37.11	125.39	-0.40	normal
46.63	15.85	39.99	30.78	119.37	9.064	normal
49.82	16.73	28.0	33.09	121.43	1.913	normal
47.31	8.573	35.56	38.74	120.57	1.630	normal
50.75	20.23	37.0	30.51	122.34	2.288	normal
36.15	-0.81	33.62	36.96	135.93	-2.09	normal
40.74	1.835	49.99	38.91	139.24	0.668	normal
42.91	-5.84	57.99	48.76	121.60	-3.36	normal
63.79	21.34	65.99	42.44	119.55	12.38	normal
72.95	19.57	61.00	53.37	111.23	0.813	normal
67.53	14.65	58.00	52.88	123.63	25.97	normal
54.75	9.752	47.99	45.0	123.03	8.235	normal
50.16	-2.97	41.99	53.13	131.80	-8.29	normal
40.34	10.19	37.96	30.15	128.00	0.458	normal
63.61	16.93	49.34	46.68	117.08	-0.35	normal
54.14	11.93	42.99	42.20	122.20	0.153	normal
74.97	14.92	53.73	60.05	105.64	1.594	normal
42.51	14.37	25.32	28.14	128.90	0.757	normal
33.78	3.675	25.5	30.11	128.32	-1.77	normal
54.50	6.819	46.99	47.68	111.79	-4.40	normal
48.17	9.594	39.71	38.57	135.62	5.360	normal
46.37	10.21	42.69	36.15	121.24	-0.54	normal
52.86	9.410	46.98	43.45	123.09	1.856	normal
57.14	16.48	42.84	40.65	113.80	5.015	normal
37.14	16.48	24.0	20.65	125.01	7.366	normal
51.31	8.875	56.99	42.43	126.47	-2.14	normal
42.51	16.54	41.99	25.97	120.63	7.876	normal
39.35	7.011	37.0	32.34	117.81	1.904	normal
35.87	1.112	43.45	34.76	126.92	-1.63	normal
43.19	9.976	28.93	33.21	123.46	1.741	normal
67.28	16.71	50.99	50.57	137.59	4.960	normal
51.32	13.63	33.25	37.69	131.30	1.788	normal
65.75	13.20	43.99	52.54	129.39	-1.98	normal
40.41	-1.32	30.98	41.74	119.33	-6.17	normal
48.80	18.01	51.99	30.78	139.15	10.44	normal
50.08	13.43	34.45	36.65	119.13	3.089	normal
64.26	14.49	43.90	49.76	115.38	5.951	normal
53.68	13.44	41.58	40.23	113.91	2.737	normal
48.99	13.11	51.87	35.88	126.39	0.535	normal
59.16	14.56	43.19	44.60	121.03	2.830	normal
67.80	16.55	43.25	51.25	119.68	4.867	normal
61.73	17.11	46.89	44.62	120.92	3.087	normal
33.04	-0.32	19.07	33.36	120.38	9.354	normal
74.56	15.72	58.61	58.84	105.41	0.599	normal

incidência pélvica	versão pélvica	ângulo de lordose	declive sacral	raio pélvico	grau de deslizamento	classe
44.43	14.17	32.24	30.25	131.71	-3.60	normal
36.42	13.87	20.24	22.54	126.07	0.179	normal
51.07	14.20	35.95	36.86	115.80	6.905	normal
34.75	2.631	29.50	32.12	127.13	-0.46	normal
48.90	5.587	55.49	43.31	137.10	19.85	normal
46.23	10.06	37.0	36.17	128.06	-5.10	normal
46.42	6.620	48.09	39.80	130.35	2.449	normal
39.65	16.20	36.67	23.44	131.92	-4.96	normal
45.57	18.75	33.77	26.81	116.79	3.131	normal
66.50	20.89	31.72	45.60	128.90	1.517	normal
82.90	29.89	58.25	53.01	110.70	6.079	normal
50.67	6.461	35.0	44.21	116.58	-0.21	normal
89.01	26.07	69.02	62.93	111.48	6.061	normal
54.60	21.48	29.36	33.11	118.34	-1.47	normal
34.38	2.062	32.39	32.31	128.30	-3.36	normal
45.07	12.30	44.58	32.76	147.89	-8.94	normal
47.90	13.61	36.0	34.28	117.44	-4.24	normal
53.93	20.72	29.22	33.21	114.36	-0.42	normal
61.44	22.69	46.17	38.75	125.67	-2.70	normal
45.25	8.693	41.58	36.55	118.54	0.214	normal
33.84	5.073	36.64	28.76	123.94	-0.19	normal