

Felipe Mancini

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA
CLASSIFICAÇÃO DE PADRÕES POSTURAS EM CRIANÇAS
RESPIRADORAS BUCAIS

Tese apresentada à Universidade Federal de São Paulo – Escola Paulista de Medicina, para obtenção do Título de Mestre em Ciências pelo programa de pós-graduação em Informática em Saúde.

SÃO PAULO

2007

Felipe Mancini

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA
CLASSIFICAÇÃO DE PADRÕES POSTURAIS EM CRIANÇAS
RESPIRADORAS BUCAIS

Tese apresentada à Universidade Federal de São Paulo – Escola Paulista de Medicina, para obtenção do Título de Mestre em Ciências pelo programa de pós-graduação em Informática em Saúde.

Orientador: Ivan Torres Pisa

Co-orientador: Antonio C. Roque S. Filho

SÃO PAULO

2007

Mancini, Felipe

Aplicação de redes neurais artificiais na classificação de padrões posturais em crianças respiradoras bucais

Felipe Mancini./Felipe Mancini. -- São Paulo, 2007.

xx, 94f.

Tese (Mestrado) – Universidade Federal de São Paulo. Programa de Pós-graduação em Informática em Saúde.

Título em inglês: Application of artificial neural networks in the classification of posture profiles in mouth-breathing children

1.Redes Neurais Artificiais. 2. Postura. 3. Respiração Bucal. 4. Técnicas de Apoio para a Decisão

**UNIVERSIDADE FEDERAL DE SÃO PAULO
ESCOLA PAULISTA DE MEDICINA
DEPARTAMENTO DE INFORMÁTICA EM SAÚDE**

Programa de Pós-graduação em Informática em Saúde

Coordenador: Daniel Sigulem

Vice-coordenador: Carlos José Reis de Campos

“Por mais que na batalha se vença a um ou mais inimigos, a vitória sobre si mesmo é a maior de todas”.

Buda Sakyamuni

Dedicatória

Dedico esta obra aos meus pais, Armando e Ângela, que sempre me apoiaram e incentivaram.

Agradecimentos

À minha namorada Ana Carolina e a minha irmã Marília pelo apoio e paciência.

À CAPES pelo apoio financeiro.

Ao prof. Daniel Sigulem pela dedicação à informática em saúde.

Ao prof. Carlos Campos pelo extremo comprometimento dado à pós-graduação e aos alunos.

Ao prof. Domingos Alves pelas idéias e opiniões omitidas neste trabalho de pesquisa.

Ao prof. Jacques Wainer pela paciência em esclarecer pontos importantes deste trabalho.

Ao prof. Paulo Paiva em participar da banca de pré-defesa desta dissertação de mestrado.

Ao prof. Marcos Biczuk pela participação nesta banca de defesa da minha dissertação

À profa. Viviane Bernando pela paciência e pelo apoio.

À Claudia e Paulo Lopes pelas opiniões emitidas neste trabalho.

Ao prof. Paulo Pinheiro pela ajuda na tradução de textos e pelas opiniões emitidas neste trabalho.

Aos pós-graduandos e ao pessoal do DIS pela amizade e ajuda.

À Valdice pela ajuda e paciência.

Por fim à Dra. Liu Chiao Yi e à profa. Shirley Pignatari pelo comprometimento cedido a este trabalho.

E por último - e não menos importante - ao prof. Ivan Pisa pela amizade, paciência, comprometimento e por apostar neste trabalho de pesquisa. Ivan, muito obrigado.

Suporte Financeiro

Esse trabalho recebeu suporte financeiro da CAPES via bolsa de mestrado, no período de setembro de 2005 a agosto de 2007 (23 meses).

Lista de publicações

- Mancini F, Liu CY, Pignatari SSN, Roque AC, Pisa IT. Aplicação de Redes Neurais Artificiais no Diagnóstico e Evolução Clínica da Postura em Crianças Respiradoras Bucais e Nasais. Revista de Informática Teórica e Aplicada. No prelo 2007.
- Mancini F, Liu CY, Pignatari SSN, Alves D, Pisa, IT. Análise Qualitativa da Postura em Crianças Respiradoras Bucais. Fisioter Mov. No prelo 2007.
- Mancini F, Liu CY, Pignatari SSN, Alves D, Pisa, IT. Aplicação de Redes Neurais Artificiais no Auxílio ao Diagnóstico de Crianças Respiradoras Bucais e Nasais [CD-ROM]. In: X Congresso Brasileiro de Informática em Saúde; 2006; Florianópolis. Anais. São Paulo: Sociedade Brasileira de Informática em Saúde; 2006.
- Mancini F, Roque AC, Pisa, IT. Classificação de Padrões em Avaliação Postural [CD-ROM]. In: 2º Congresso Brasileiro de Telemedicina e Telessaúde; 2005; São Paulo. Anais. São Paulo: Conselho Brasileiro de Telemedicina e Telessaúde; 2005.
- Ducatti MA, Mancini F, Pisa IT, Campos CJR. Elaboração de uma Revista Científica Eletrônica da Área de Informática em Saúde – RECIS [CD-ROM]. In: X Congresso Brasileiro de Informática em Saúde; 2006; Florianópolis. Anais. São Paulo: Sociedade Brasileira de Informática em Saúde; 2006.

Banca de Mestrado

O Programa de Pós-Graduação em Informática em Saúde do Departamento de Informática em Saúde da UNIFESP convidou para a Defesa Pública da tese do Curso de Mestrado do candidato Felipe Mancini, sob título “Aplicação de Redes Neurais Artificiais na Classificação de Padrões Posturais em Crianças Respiradoras Bucais”, em 13 de agosto de 2007, 10 horas, no Anfiteatro Octávio Ribeiro Ratto (Rua Pedro de Toledo nº 781).

A banca foi presidida pelo Prof. Dr. Ivan Torres Pisa e contou com os seguintes membros:

- Prof. Dr. Domingos Alves, Doutor em Física pela Universidade de São Paulo;
- Prof. Dr. Marcio Biczuk do Amaral, Doutor pela Universidade Nacional em Chibas-Japão;
- Profa. Dra. Shirley Shizue Nagata Pignatari, Doutora pelo Departamento de Otorrinolaringologia e Cirurgia de Cabeça e Pescoço da UNIFESP;
- Suplente: Prof. Dr. Fabrício Alves Barbosa da Silva, Architecture des Systemes Integres/Informatique, Universite de Paris VI-França.

Após aula expositiva e arguição, o candidato foi considerado APROVADO para receber o título de Mestre em Ciências, Área de Informática em Saúde, pela UNIFESP.

Índice

Índice de Figuras	xiv
Índice de Tabelas	xvii
Resumo	xix
Abstract	xx
1 Introdução	1
2 Objetivos	5
3 Materiais e Métodos	6
3.1 Aprovações do Comitê de Ética em Pesquisa e Conflito de Interesse	8
3.2 Bases de Dados.....	9
3.2.1 <i>Base de Dados 1</i>	9
3.2.2 <i>Base de Dados 2</i>	11
3.2.3 <i>Protocolo de Coleta do Banco de Dados</i>	11
3.3 Padrão Ouro.....	16
3.4 Redes Neurais Artificiais e a Classificação de Padrões.....	17
3.4.1 <i>Mapa Auto-organizável (SOM)</i>	19
3.4.2 <i>Aprendizagem por Quantização Vetorial (LVQ)</i>	22
3.4.3 <i>Perceptron</i>	23
3.4.4 <i>Backpropagation (BP)</i>	24
3.5 Seleção de Parâmetros e Modelos.....	25
3.5.1 <i>K-fold</i>	26
3.5.2 <i>Leave-one-out (LOO)</i>	26
3.6 Padrão de Entrada.....	27
3.7 Configuração dos Modelos de RNA.....	27
3.8 Análise Estatística.....	28
3.8.1 <i>Teste t de Student</i>	28
3.8.2 <i>Especificidade e Sensibilidade</i>	28
3.8.3 <i>Curva ROC</i>	29
3.9 Softwares Utilizados	30
3.9.1 <i>Análise da Postura e Músculo Diafragma</i>	30
3.9.2 <i>Implementação dos Modelos de RNA</i>	30
3.9.3 <i>Classificação Automática da Postura</i>	30
3.9.4 <i>Análises Estatísticas</i>	31

3.10	Hardware e Sistema Operacional	31
3.11	Software e Algoritmos Desenvolvidos	31
4	Resultados	33
4.1	Investigação do Perfil Postural de Crianças Respiradoras Bucais.....	33
4.2	Seleção do Modelo para Classificação Automática da Postura de Crianças Respiradoras Bucais	37
4.2.1	<i>Five-fold</i>	37
4.2.2	<i>Three-fold Estendido</i>	39
4.2.3	<i>Leave-one-out (LOO)</i>	43
4.3	Classificação Automática da Postura de Crianças Respiradoras Bucais.....	47
4.3.1	<i>Validação do Software</i>	47
4.3.2	<i>Software para Classificação Automática da Postura de Crianças Respiradoras Bucais</i> 51	
5	Discussão	54
5.1	SOM Aplicado na Determinação do Perfil Postural de Crianças Respiradoras Bucais 54	
5.2	Seleção de Modelo	57
5.3	Software para Classificação de Padrões Posturais de Crianças Respiradoras Bucais 60	
6	Conclusão	61
7	Trabalhos Futuros.....	62
8	Referências.....	63
	Anexo 1 – Parecer do Comitê de Ética em Pesquisa	68
	Anexo 2 – Parecer do Comitê de Ética em Pesquisa da Dra. Liu (2006) ...	69
	Anexo 3 – Termo de Consentimento Livre e Esclarecido da Dra. Liu (2006)	70
	Anexo 4 – Aprovação para Utilização da Base de Dados	71
	Anexo 5 – Valores Numéricos Apresentados pela Figura 16	72

Índice de Figuras

Figura 1: Ilustração do processo metodológico aplicado neste trabalho.	7
Figura 2: Representação dos pontos e ângulos utilizados na avaliação postural, indicando (a) lordose cervical; (b) cifose torácica; (c) lordose lombar; (d) posição da pelve (Liu, 2006).	15
Figura 3: Abordagem clássica para reconhecimento de padrões utilizando RNA (Haykin, 1999).	18
Figura 4: Ilustração do mapa de características (Haykin, 1999).	20
Figura 5: Mosaico de Voronoi (Roque, 2007).	22
Figura 6: Ilustração do hiperplano como fronteira de decisão para um problema de classificação de padrões bidimensionais de duas classes (Haykin, 1999).	24
Figura 7: Grafo arquitetural de um MLP (Haykin, 1999).	25
Figura 8: Ilustração do processo <i>k-fold</i> . Para cada iteração, o subconjunto de dados sombreado é usado para validar o modelo treinado com os dados restantes (Haykin, 1999).	26
Figura 9: Exemplo de duas curvas ROC comparando o desempenho de diferentes classificadores de padrões (A e B).	29
Figura 10: Mapa gerado após o treinamento do SOM. Cada hexágono representa um neurônio, com sua identificação no lado superior esquerdo. No interior de cada hexágono está desenhado um círculo ou um quadrado. O quadrado indica que o neurônio representa crianças respiradoras nasais e o círculo indica que representa crianças respiradoras bucais. Dentro de cada círculo e quadrado está mostrada a quantidade de crianças respiradoras bucais (número acima) e de crianças respiradoras nasais (número abaixo) agrupadas sob o neurônio correspondente.	34
Figura 11: Representação das quatro classes distintas obtidas a partir da análise das médias dos atributos de cada neurônio, conforme listadas pela Tabela 9, seguindo os agrupamentos gerados pela Figura 10 e validado com especialista. As classes 1 e 2, vermelha e azul respectivamente, representam respiradores bucais típicos. A classe 3, amarela, representa a	

fronteira entre respiradores bucais e nasais e a classe 4, cinza, representa respiradores nasais.....	36
Figura 12: Função densidade da distribuição para diferentes padrões de entrada. O primeiro gráfico representa a distribuição da especificidade e o segundo gráfico representa a distribuição da sensibilidade. A cor vermelha mostra a distribuição de PE5, a cor azul mostra a distribuição de PE4, a cor marrom mostra a distribuição de PE1, a cor cinza mostra a distribuição de PE3 e a cor rosa mostra a distribuição de PE2.....	40
Figura 13: Representação do corte para cálculo da curva ROC para os algoritmos de aprendizagem competitiva (SOM e LVQ). Para cada item (a, b, c e d) foram realizados 50 treinamentos individuais, sendo calculada a especificidade e sensibilidade média dos pacientes pertencentes aos neurônios pintados em vermelho. Estes valores foram utilizados para traçar a curva ROC.	42
Figura 14: Curva ROC para o <i>3-fold</i> estendido. A cor vermelha mostra a curva ROC do LVQ e a cor azul mostra a curva ROC do SOM.....	42
Figura 15: Curva ROC para o <i>leave-one-out</i> . A cor vermelha mostra a curva ROC do LVQ e a cor azul mostra a curva ROC do SOM.....	44
Figura 16: Resultado de 8 testes individuais para análise da generalização do LVQ na classificação automática da postura em crianças respiradoras bucais. Para facilitar a visualização da sensibilidade e especificidade, foram calculados e mostrados seus respectivos complementos. O erro de quantização foi calculado por meio da diferença do erro de quantização dos 52 pacientes treinados (totalidade de pacientes de BD1) com erro de quantização em cada incremento. Dados completos no Anexo 5 (pág. 72).	46
Figura 17: Rótulo para cada neurônio do LVQ. Cada hexágono representa um neurônio e o número de cada neurônio é representado no lado superior esquerdo. Os neurônios em verde (1, 4 e 7) são classificados como respiradores nasais e os neurônios em vermelho (2, 3, 5, 6, 8 e 9) são classificados como respiradoras bucais.....	47

Figura 18: Análise da especificidade do software. Cada hexágono representa um neurônio, o número de cada neurônio é representado no lado superior esquerdo e a quantidade de pacientes classificados em cada neurônio é representada no centro do hexágono.	48
Figura 19: Análise da sensibilidade do software. Cada hexágono representa um neurônio, o número de cada neurônio é representado no lado superior esquerdo e a quantidade de pacientes classificados em cada neurônio é representada no centro do hexágono.	49
Figura 20: Distribuição dos pacientes, a partir da análise do LVQ, que não necessitam realizar intervenção fisioterapêutica (a) e necessitam realizar intervenção fisioterapêutica (b).	50
Figura 21: Subtração de cada neurônio do mapa (a) da Figura 20 pelo mapa (b) da mesma figura. Em cada neurônio está indicado o valor deste cálculo. Caso o neurônio possua um valor negativo, encontra-se nessa região maior número de pacientes com necessidade de realizar intervenção fisioterapêutica. Caso o neurônio esteja com o valor positivo, encontra-se nessa região maior número de pacientes sem necessidade de realizar intervenção fisioterapêutica.....	50
Figura 22: Tela do software construído para classificação automática da postura. O PERFIL A representa criança com perfil postural de respiradora bucal com alterações severas da postura; o PERFIL B representa criança com perfil postural de respiradora bucal com alterações moderadas da postura; o PERFIL C representa criança com perfil postural de respiradora bucal com alterações leves da postura; o PERFIL C e D representam criança com perfil postural de respiradora nasal com alterações leves da postura.	52
Figura 23: Paciente classificado no software para classificação postural de crianças respiradoras bucais. Neste caso, a criança foi classificada com o PERFIL A.	53

Índice de Tabelas

Tabela 1: Quantidade de pacientes para cada base de dados (BD1 e BD2).	9
Tabela 2: Variáveis de BD1.....	9
Tabela 3: Valor médio de cada variável para cada categoria de pacientes da BD1. RN representa pacientes da categoria respirador nasal e RB representa os pacientes da categoria respirador bucal.....	10
Tabela 4: Quantidade de pacientes agrupados em BD1 para cada classe de etiologia. A obstrução da orofaringe (amígdala) é representada pela letra G seguida por um número romano - I indica 25% de obstrução da orofaringe, II indica 50% de obstrução da orofaringe, III indica 100% de obstrução da orofaringe e IV indica 100% de obstrução da orofaringe –, a adenóide é representada pela letra A seguida pela porcentagem de obstrução da rinofaringe. O símbolo + representa a associação de diferentes fatores etiológicos.	10
Tabela 5: Variáveis da BD2.....	11
Tabela 6: Valor médio de cada variável para cada categoria de pacientes da BD2. RN representa pacientes da categoria respirador nasal e RB representa os pacientes da categoria respirador bucal.....	11
Tabela 7: Diferentes conjuntos de dados de BD1 utilizados como padrões de entrada e seus respectivos rótulos. O número entre parênteses mostra a quantidade de variáveis utilizadas para cada subconjunto.	27
Tabela 8: Aplicação do teste t de <i>Student</i> em todas as variáveis de BD1.	33
Tabela 9: Média de cada atributo para o conjunto de pacientes agrupados em cada neurônio, conforme representados pela Figura 10.	35
Tabela 10: Quantidade de pacientes das classes das crianças respiradoras bucais 1 (C1) e das crianças respiradoras bucais 2 (C2) contabilizada para cada categoria de etiologia (Tabela 4).	37
Tabela 11: Cinco testes individuais empregando o algoritmo <i>5-fold</i> para todos os modelos de RNA e padrão de entrada usados neste trabalho. Os itens (a), (b), (c), (d) e (e) mostram os valores de sensibilidade (s) e especificidade (e) para os testes.....	38

Tabela 12: Tempo de treinamento e validação dos modelos de RNA para 400 diferentes combinações.	39
Tabela 13: Valor médio da sensibilidade (s) e especificidade (e) calculado a partir dos 50 valores de pico de cada distribuição da Figura 12 e apresentado como entrada aos modelos de RNA.....	41
Tabela 14: Valores numéricos dos pontos das curvas ROC do SOM e LVQ para o 3-fold estendido. As curvas ROC finais são mostradas na Figura 14. (s) representa a sensibilidade e (e) representa a especificidade.	43
Tabela 15: Valores de especificidade (e) e sensibilidade (s) médios para os diferentes padrões de entrada apresentados aos modelos de RNA, utilizando <i>leave-one-out</i> como algoritmo de seleção de modelo.....	43
Tabela 16: Valores numéricos dos pontos das curvas ROC do SOM e LVQ para o <i>leave-one-out</i> . As curvas ROC finais são mostradas na Figura 15. (s) representa a sensibilidade e (e) representa a especificidade.	44

Resumo

Aplicação de redes neurais artificiais na classificação de padrões posturais em crianças respiradoras bucais

Felipe Mancini – felipe-pg@dis.epm.br

A respiração bucal crônica é uma síndrome que pode promover alterações na postura corporal. Por existirem diferentes etiologias é possível que existam diferentes categorias de alterações posturais associadas à respiração bucal. Métodos estatísticos têm sido propostos a fim de realizar modelagem não-linear com alta dimensionalidade de dados biomédicos, entre eles destacam-se as redes neurais artificiais (RNA). RNA são ferramentas estatísticas que realizam mapeamentos não-lineares entre um conjunto de variáveis de entrada e um conjunto de variáveis de saída. O objetivo deste trabalho é utilizar o mapa auto-organizável (SOM) na investigação do perfil postural de crianças respiradoras bucais e desenvolver um software utilizando RNA que classifique automaticamente o perfil postural de crianças respiradoras bucais. Para esta investigação utilizou-se uma base de dados de avaliação postural de 84 crianças, sendo 52 respiradoras bucais e 32 respiradoras nasais, contendo variáveis antropométricas, medidas da excursão do diafragma e postura corporal. Quatro algoritmos de RNA – SOM, *perceptron*, *backpropagation* e aprendizagem por quantização vetorial (LVQ) – tiveram seus desempenhos avaliados por meio de técnicas de validação cruzada, buscando-se o modelo mais adequado na extração de características e classificação do perfil postural. Na investigação postural foram definidas 4 classes distintas por meio do SOM englobando respiradores bucais e nasais. Na classificação da postura, o LVQ apresentou sensibilidade 0,98 e especificidade 0,97 utilizando o conjunto de dados de treinamento. Para o conjunto de dados de validação, o LVQ apresentou sensibilidade 0,95 e especificidade 0,90. Além disto, o software baseado no LVQ realizou corretamente (100% de acerto) a classificação da postura de crianças respiradoras bucais, de acordo com uma escala de gravidade arbitrária.

Palavras-chave: Redes neurais artificiais, postura, respiração bucal, técnicas de apoio para a decisão.

Abstract

Application of artificial neural networks in the classification of posture profiles in mouth-breathing children

Felipe Mancini – felipe-pg@dis.epm.br

Mouth breathing is a chronic syndrome which may bring about posture changes. Due to the various existing etiologies of this syndrome, many different characteristic posture changes may be associated with this breathing condition. Statistical methods have been proposed for non-linear, high dimension biomedical data modeling, including artificial neural networks (ANN). ANN are statistical tools capable to deal with non-linear associations, which can be used to determine characteristic posture profiles shown by mouth-breathing children. The aim of the present study was to explore the use of self-organizing map (SOM) in an investigation into the posture profile of mouth breathing children, and in the development of an artificial-neural-network (ANN)-based software tool to automatically classify the posture profile of these children. This investigation was carried out using a database comprising the anthropometric variables, excursion of the diaphragm and posture measurements of 84 children – 52 mouth breathers and 32 nasal breathers. The performance of 4 ANN algorithms – SOM, perceptron, back propagation and learning vector quantization (LVQ) – was assessed by cross validation in order to find out the most suitable model for extracting characteristics and for classifying postural profile. Four different classes were defined for investigating the posture of mouth and nasal breathers with SOM. The analysis of performance in classifying posture showed that LVQ achieved sensitivity and specificity rates of 0.98 and 0.97, respectively, when using the training data set, and 0.95 and 0.90, respectively, when using the validation data set. Furthermore, LVQ performed correctly the classification of posture in 100% of mouth-breathing children according to an arbitrary severity scale.

Keywords: neural networks, posture, mouth breathing, clinical decision support systems.

1 Introdução

A respiração é a primeira função vital desenvolvida por ocasião do nascimento, estabelecendo-se como principal função do organismo. A cavidade nasal tem papel fundamental na fisiologia respiratória, promovendo a filtração, aquecimento e umidificação do ar inspirado, fazendo com que este chegue aos pulmões na temperatura ideal, favorecendo uma oxigenação adequada ao organismo. A cavidade bucal só intervém neste processo quando o ar inspirado não é suficiente, geralmente causado por uma obstrução nasal (Hungria, 1995; Carvalho, 1996).

A respiração bucal na infância resulta em queixa freqüente nos consultórios do pediatra, do alergologista e do otorrinolaringologista. Vários são os fatores que podem originar a respiração bucal, sendo a rinite alérgica possivelmente a causa mais comum de obstrução crônica das vias aéreas, afetando de 15 a 20% da população, sendo a hipertrofia das amígdalas, localizadas na orofaringe, e adenóides, localizadas na rinofaringe, a segunda causa da respiração bucal. Sabe-se atualmente que a respiração bucal crônica é uma síndrome, considerada com seis meses de evolução, e pode promover alterações no desenvolvimento odontológico, crânio-facial e na postura corporal (Schinestsck, 1986; Aragão, 1988; Lusvarghi, 1999; Pizarro, 2003).

Devido ao aumento da resistência nasal no respirador bucal, o trabalho ventilatório apresenta-se aumentado (Martucci et al., 1992; Ribeiro et al., 2002; Rodrigues & Bérzin, 2004). Segundo Benatti (2001), os músculos acessórios da inspiração passam a ser solicitados, o que leva a um movimento inspiratório proeminente do tórax superior. São assim chamados, pois atuam numa atividade física exacerbada ou quando ocorre um aumento do esforço inspiratório (Jardim, 1989; Guyton, 1992).

O movimento inspiratório proeminente do tórax superior, segundo Hruska (1997), Farah & Tanaka (1997), pode influenciar a mecânica tóraco-abdominal, alterando a excursão e o posicionamento do músculo diafragma, que é responsável por 70% de toda atividade respiratória e sua zona de aposição devido à redução da pressão intra-abdominal. Este fato levaria então ao

desenvolvimento de deformidades torácicas, como a elevação das últimas costelas, o deslocamento superior da caixa torácica e o aumento da lordose lombar.

Dada à complexidade biomecânica da postura, que possibilita a integração funcional dos vários segmentos, é possível entender que, frente à alteração de uma unidade biomecânica, ocorra refinamento dos sistemas de controle postural, acomodações das estruturas corporais próximas ou distantes, através de compensações. Dessa forma, podemos observar que alterações de funções e do posicionamento de estruturas do sistema estomatognático levam a compensação da curvatura da coluna vertebral.

Assim, devido ao fato dos músculos atuarem de forma sinérgica e serem organizados em cadeias (Rocabado, 1979; Ribeiro et al., 2003), a estrutura corporal pode ser interpretada como um sistema não-linear. Como exemplo, Liu (2006) não detectou nenhuma correlação linear entre a distância excursionada pelo músculo diafragma e o comportamento das curvaturas da coluna vertebral. A prática clínica evidencia uma correlação, possivelmente detectada utilizando uma análise estatística não-linear.

A não-linearidade e a alta dimensionalidade são características presentes na modelagem de dados biomédicos (Shortliffe & Barnett, 2000; Villmann, 2002). Especificamente, modelos estatísticos convencionais podem apresentar dificuldades em extrair características de um repositório de dados biomédicos, principalmente por apresentar limitações no reconhecimento de comportamento não-linear entre um conjunto de variáveis ou atributos (Lisboa, 2002). Estas deficiências tornam-se significativas principalmente quando é necessário aplicar modelos estatísticos com o foco de apontar categorias ou determinar padrões de um conjunto de dados.

Para realizar estes tipos de análise, diferentes métodos têm sido propostos, baseados em técnicas estatísticas paramétricas e não-paramétricas, técnicas de reconhecimento de padrões e de *clustering* (Akay, 2000; Duda et al., 2000). Um dos métodos mais populares que tem se mostrado eficiente para a análise de dados biomédicos é o de redes neurais artificiais (RNA) (Lisboa et al., 2000; Lisboa, 2002; Castellani e Castellani, 2003). RNA são sistemas com-

postos por unidades de processamento simples, interligadas entre si por conexões ponderadas que executam operações em paralelo e de forma distribuída (Roque, 2007; Haykin, 1999). As redes neurais artificiais podem ser aplicadas como ferramentas de análise estatística semi paramétrica de dados (Bishop, 1995; Príncipe et al., 2000). O seu amplo uso em aplicações biomédicas deve-se a fato de que elas representam ferramentas genéricas para realizar mapeamentos não-lineares entre um conjunto de variáveis de entrada e um conjunto de variáveis de saída (Bishop, 1995).

Foi realizada em 17/05/2007 uma pesquisa no site da PubMed (<http://www.ncbi.nlm.nih.gov>) com o descritor “*neural networks*” (código MeSH H01.548.635.310.500) e termo “*medical*” utilizando o operador AND e o sistema de pesquisa padrão da PubMed. Foram encontrados 1410 artigos para esta pesquisa. Utilizado o mesmo padrão de pesquisa com os descritores “*neural networks*” (código MeSH H01.548.635.310.500) e “*posture*” (código MeSH G11.427.713.700) foram encontrados 52 artigos, porém, nenhum destes relatam a aplicação de RNA na análise da postura em crianças respiradoras bucais. Realizado novamente o mesmo padrão de pesquisa com os descritores “*neural networks*” (código MeSH H01.548.635.310.500) e “*mouth breathing*” (código MeSH C08.618.659) não foi encontrado nenhum trabalho. Desta maneira, nenhum estudo que tenha aplicado RNA na análise da postura em crianças respiradoras bucais foi encontrado no PubMed.

A importância deste estudo pode ser observada pelo fato da respiração bucal apresentar diferentes etiologias. Assim, é possível apresentar diferentes categorias de postura pertencentes a esta síndrome. Neste caso, RNA possivelmente podem auxiliar na análise e classificação automática da postura de crianças respiradoras bucais.

A fim de traçar o perfil postural e auxiliar o profissional da saúde na classificação automática da postura em crianças respiradoras bucais, este trabalho está dividido nos seguintes capítulos:

- Capítulo 1: aqui apresentado;
- Capítulo 2 (pág. 5): neste capítulo é informado o objetivo deste trabalho;

- Capítulo 3 (pág 6): neste capítulo são detalhados os materiais e métodos utilizados;
- Capítulo 4 (pág 33): neste capítulo são mostrados os resultados deste trabalho. Os resultados são divididos em 3 seções:
 - Na seção 4.1 (pág. 33) é realizada a investigação do perfil postural de crianças respiradoras bucais;
 - Na seção 4.2 (pág. 37) é determinado modelo de RNA para a classificação automática da postura em crianças respiradoras bucais;
 - Na seção 4.3 (pág. 47) é realizada a validação e são detalhadas as funcionalidades do software de classificação automática da postura de crianças respiradoras bucais;
- Capítulo 5 (pág 54): neste capítulo são discutidos os resultados obtidos;
- Capítulo 6 (pág. 61): neste capítulo é apresentado a conclusão deste trabalho.
- Capítulo 7 (pág 62): neste capítulo são propostos estudos futuros que podem decorrer deste trabalho.

2 Objetivos

Este trabalho possui os seguintes objetivos:

- Aplicar RNA na investigação do perfil postural de crianças respiradoras bucais;
- Desenvolver um software utilizando RNA que classifique automaticamente o perfil postural de crianças respiradoras bucais.

3 Materiais e Métodos

A fim de facilitar o entendimento da metodologia aplicada neste trabalho foi elaborada a Figura 1. A partir desta figura é possível identificar que este trabalho se baseia em duas bases de dados. A primeira é utilizada para treinar os modelos de RNA (BD1) e a segunda é utilizada para realizar a validação do software de classificação postural de crianças respiradoras bucais (BD2).

A primeira fase deste trabalho é mostrada pela chave “seleção de parâmetros” da Figura 1. Porém, antes de detalhar esta etapa, é necessário informar que foram escolhidos quatro modelos de RNA, para a tarefa de classificação da postura em crianças respiradoras bucais: mapa auto-organizável (SOM, self-organizing map) (Kohonen, 1997), *perceptron* (Haykin, 1999), algoritmo de retropropagação (BP, *backpropagation*) (Haykin, 1999), aprendizagem por quantização vetorial (LVQ, learning vector quantization) (Kohonen, 1997). Na seção 3.4 (pág. 17) é apresentada a justificativa da escolha destes modelos de RNA para a tarefa citada, bem como as propriedades das RNA para a classificação de padrões de dados biomédicos. Voltando à fase “seleção de parâmetros”, foi aplicado um algoritmo de validação cruzada conhecido como *leave-one-out* (LOO) (Burnham, 2004) – citado na Figura 1 – a fim de determinar a melhor configuração dos parâmetros dos modelos de RNA para a classificação da postura em crianças respiradoras bucais. O *leave-one-out* é detalhado na seção 4.2.3 (pág. 43) e os parâmetros adotados para os modelos de RNA são informados na seção 3.7 (pág 27).

A segunda fase deste trabalho é mostrada pela chave “seleção de modelo” da Figura 1. Nesta etapa foi selecionado o modelo de RNA dentre os pesquisados que apresentou melhor desempenho no diagnóstico de respirador bucal. Para isso foram aplicados dois algoritmos de validação cruzada. Estes são detalhados na seção 3.5 (pág. 25), e os resultados do desempenho dos algoritmos de RNA para a tarefa citada são listados na seção 4.2 (pág 37). Além disso, o SOM é utilizado para determinar o perfil postural de crianças respiradoras bucais. Esta análise é apresentada na seção 4.1 (pág 33).

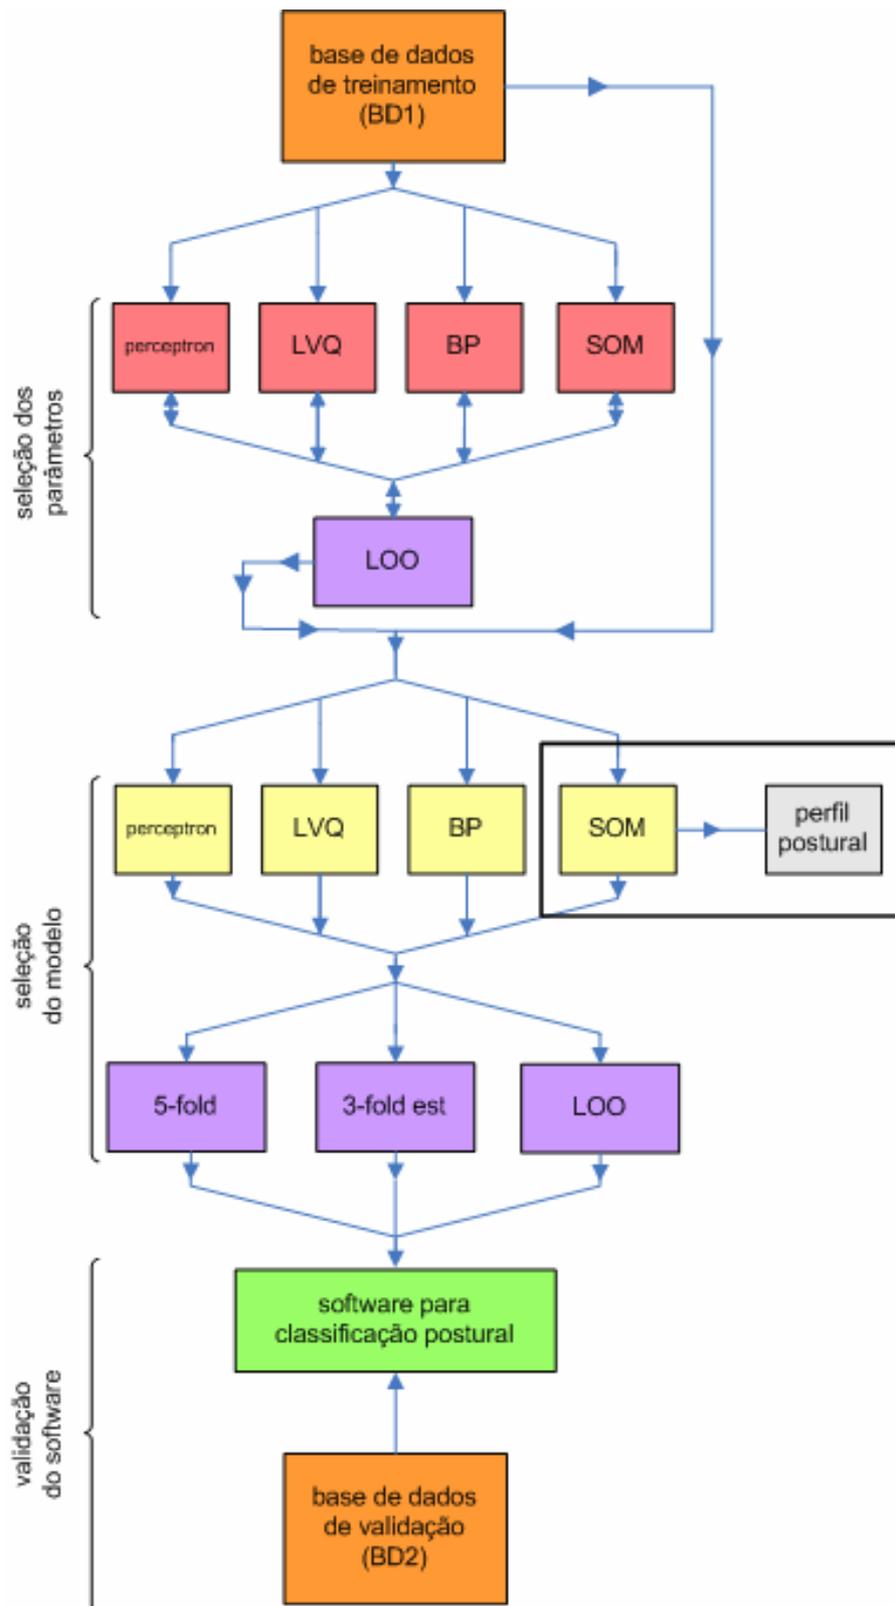


Figura 1: Ilustração do processo metodológico aplicado neste trabalho.

Após determinar o modelo de RNA para classificar a postura de crianças respiradoras bucais, o modelo escolhido é aplicado como reconhecedor de padrões para o software de classificação automática de postura de crianças respiradoras bucais. A fase “validação do software” possui duas principais etapas:

- Validação do software utilizando BD2 – esta validação é realizada para o diagnóstico de criança respiradora bucal/nasal;
- Determinação de classes de postura das crianças respiradoras bucais. Em BD2 consta opinião do especialista sobre a necessidade de cada criança respiradora bucal em realizar intervenção postural (vide seção 3.3 – pág 16). Este parâmetro também é utilizado para determinar a classificação postural.

3.1 Aprovações do Comitê de Ética em Pesquisa e Conflito de Interesse

O Comitê de Ética em Pesquisa da Universidade Federal de São Paulo sob o processo CEP 0997/05 aprovou na data de 16/07/2005 este projeto de pesquisa. Esta aprovação é mostrada no Anexo 1 (pág. 68).

O estudo aqui apresentado utiliza a base de dados da tese de doutorado da Dra. Liu Chiao Yi (2006). O Comitê de Ética em Pesquisa da Universidade Federal de São Paulo sob o processo CEP 1611/03 aprovou na data de 16/01/2004 o projeto de pesquisa de doutorado da Dra. Liu Chiao Yi. Esta aprovação é mostrada no Anexo 2 (pág. 69) e no Anexo 3 (pág. 70) consta o Termo de Consentimento Livre e Esclarecido (TCLE) utilizado. O anexo 4 (pág. 71) mostra aprovação da Dra. Liu Chiao Yi para a utilização da sua base de dados neste trabalho (Liu, 2006).

Os autores deste trabalho afirmam a não existência de conflito de interesse em relação a sua realização e os resultados obtidos.

3.2 Bases de Dados

O trabalho aqui apresentado utilizou a base de dados de Liu (2006) coletado no ano de 2004 contendo dados da avaliação postural de 84 crianças, divididos em duas bases de dados – BD1 e BD2. Deste total, 52 foram previamente diagnosticadas como respiradoras bucais e 32 foram previamente diagnosticadas como respiradoras nasais.

Das 84 crianças analisadas neste trabalho, dados de 52 crianças estão presentes em BD1, sendo 30 diagnosticadas como respiradoras bucais e 22 diagnosticadas como respiradoras nasais. Dados das outras 32 crianças estão presentes em BD2, sendo 10 diagnosticadas como respiradoras bucais e 22 diagnosticadas como respiradoras bucais. A Tabela 1 mostra a quantidade de pacientes para cada base de dados. As duas próximas seções detalham cada base de dados utilizada neste estudo (BD1 e BD2).

	BD1	BD2	BD1 + BD2
Respirador bucal	30	22	52
Respirador nasal	22	10	32
Total	52	32	84

Tabela 1: Quantidade de pacientes para cada base de dados (BD1 e BD2).

3.2.1 Base de Dados 1

Conforme informado no início deste capítulo, a BD1 é utilizada para o treinamento dos modelos de RNA. A Tabela 2 mostra as variáveis deste repositório de dados. A Tabela 3 mostra a média para cada uma das variáveis de BD1.

Antropométricos	Diafragma	Postura
Sexo	Tamanho da excursão do lado direito (PD)	Lordose cervical
Idade		Lordose lombar
Peso		Cifose torácica
Altura	Tamanho da excursão do lado esquerdo (PE)	Posição da pelve
IMC		
Raça		

Tabela 2: Variáveis de BD1.

	Peso	Altura	PD	PE	Lordose Cervical	Lordose Lombar	Cifose Torácica	Posição Pélvica
RN	37,7	1,4	1,3	1,3	52,2	120,0	41,0	7,0
RB	30,0	1,3	0,9	0,9	60,3	102,0	46,0	10,0

Tabela 3: Valor médio de cada variável para cada categoria de pacientes da BD1. RN representa pacientes da categoria respirador nasal e RB representa os pacientes da categoria respirador bucal.

Além das variáveis mostradas na Tabela 2, a etiologia é outro atributo presente apenas em BD1. A quantidade de pacientes agrupados em BD1 para cada classe de etiologia é mostrada na Tabela 4.

Etiologia	Quantidade de Pacientes
Rinite Alérgica (RA)	9
G II + A 20% + RA	1
G II + A 40% + RA	3
G III + A 60% + RA	3
G III + A 70% + RA	4
G IV + A 80% + RA	5
G IV + A 90%	2
Funcional	2
Desvio do Sépto	1
Total	30

Tabela 4: Quantidade de pacientes agrupados em BD1 para cada classe de etiologia. A obstrução da orofaringe (amígdala) é representada pela letra G seguida por um número romano - I indica 25% de obstrução da orofaringe, II indica 50% de obstrução da orofaringe, III indica 100% de obstrução da orofaringe e IV indica 100% de obstrução da orofaringe -, a adenóide é representada pela letra A seguida pela porcentagem de obstrução da rinofaringe. O símbolo + representa a associação de diferentes fatores etiológicos.

De maneira geral, conforme informado no capítulo 1, as etiologias da respiração bucal podem ser a rinite alérgica, ou obstrução da orofaringe (amígdala) – representada pela letra G da Tabela 4, seguida por um número romano (I indica 25% de obstrução da orofaringe, II indica 50% de obstrução da orofaringe, III indica 100% de obstrução da orofaringe e IV indica 100% de obstrução da orofaringe) –, ou a adenóide – representada pela letra A da Tabela 4 seguida pela porcentagem de obstrução da rinofaringe –, ou o desvio de septo. A

presença de um ou mais fatores etiológicos associados podem ser detectados em crianças respiradoras bucais.

3.2.2 Base de Dados 2

Conforme informado no início deste capítulo, a BD2 é utilizada para validar o software de classificação postural. A Tabela 5 mostra as variáveis deste repositório de dados. A variável “Intervenção fisioterapêutica” é detalhada na seção 3.3 (pág. 16). A Tabela 6 mostra a média para cada um das variáveis de BD2.

Lordose cervical
Lordose lombar
Cifose torácica
Posição da pelve
Intervenção fisioterapêutica

Tabela 5: Variáveis da BD2.

	Lordose Cervical	Lordose Lombar	Cifose Torácica	Posição Pélvica
RN	54,0	116,2	35,3	7,0
RB	64,5	100,4	40,7	10,1

Tabela 6: Valor médio de cada variável para cada categoria de pacientes da BD2. RN representa pacientes da categoria respirador nasal e RB representa os pacientes da categoria respirador bucal.

3.2.3 Protocolo de Coleta do Banco de Dados

O foco desta seção é detalhar o protocolo de coleta da base de dados da tese de doutorado de Liu (2006). Como informado nas seções anteriores, esta base de dados é utilizada neste trabalho para realizar a extração de característica e classificação de padrões de crianças respiradoras bucais.

Crítérios de Inclusão

- Pertencer à faixa etária de cinco a 12 anos;
- Apresentar respiração predominantemente bucal ou nasal por um período superior aos últimos seis meses;

- Ambos os sexos;
- Termo de Consentimento Livre e Esclarecido assinado pelo responsável conforme apresentado no Anexo 3 (pág. 70).

Critérios de Exclusão

- Má formação crânio-facial congênita;
- Doença músculo-esquelética de ordem sistêmica;
- Traumas ortopédicos e doenças respiratórias.

Critérios de Classificação de Respiração Bucal

Foram consideradas respiradoras bucais crianças que apresentaram todas as características:

- Palato ogival;
- Lábio superior encurtado e inferior evertido;
- Falta de vedamento labial;
- Mordida aberta anterior;
- Respiração bucal constatada durante a anamnese;
- Confirmação do responsável que a criança respira de forma predominante pela boca durante os últimos seis meses.

Anamnese e Exame Físico Otorrinolaringológico

Todos os participantes foram submetidos à anamnese e ao exame físico otorrinolaringológico, para determinar os grupos respiradores bucais e nasais. Fizeram parte do grupo respirador bucal, as crianças que apresentaram respiração predominantemente bucal por um período superior a seis meses, com etiologias variadas, como rinite alérgica, hipertrofia adenoamigdaliana, desvio de septo e respiração bucal por hábito.

Exame Videofluoroscópico

O exame videofluoroscópico foi realizado no Departamento de Diagnóstico por Imagem da Universidade Federal de São Paulo. Após a identificação

dos grupos controle e RB, por um otorrinolaringologista, as crianças foram encaminhadas para a realização do exame videofluoroscópico.

Os exames foram realizados em aparelho de raios X Medicor modelo EDR 750B, com intensificador de imagem, sistema de televisão padrão 525 linhas, 60 Hz e entrelaçamento 2:1 com saída *loop through*, através da qual imagens foram transferidas para fita VHS, em aparelho vídeo/monitor Philco, modelo PVC-7400.

Foi colado sobre os mamilos bilateralmente um metal medindo 0,1cm de largura e 1.8 cm de comprimento, permitindo sua visualização na imagem gravada. A importância deste metal foi permitir aplicar em fórmula a medida real deslocada pelo diafragma.

Foi registrada inicialmente a imagem de excursão do músculo diafragma do lado direito e em seguida do lado esquerdo. Para cada lado, foram gravados quatro ciclos respiratórios em repouso na posição ortostática, com os raios X em incidência ântero-posterior (AP), os pés foram mantidos paralelos e os braços ao longo do corpo. A criança foi orientada a manter os olhos abertos direcionados para o horizonte e não houve interferência verbal para a correção postural. O tronco apresentou-se desnudo, e na presença de calça que comprimisse o abdômem, foi orientada a retirada desta.

Dos quatro ciclos respiratórios gravados, um único ciclo com movimento mais harmônico foi selecionado para análise. Foram excluídos os ciclos que apresentaram movimentos bruscos de tronco, como: tosse, espirro, riso, susto ou fala.

Análise da Excursão Diafragmática

Para analisar a distância excursionada pelo músculo diafragma foram utilizados os seguintes equipamentos: 1) um microcomputador Desktop Pentium 4 3.6GHz, com HD de 200 GB, memória RAM 1,0 GB com uma placa de vídeo de 256MB, uma placa de captura de imagens marca Pinnacle[®] modelo PRO ONE RTDV; 2) um vídeo cassete SVHS marca Sony[®] modelo SVO 5800; 3) um monitor de vídeo Sony[®] TRINITRON modelo PVM 1352Q; 4) uma controladora de vídeo Sony[®] modelo RM450. Foram utilizados dois softwares: 1) A-

dobe Premiere PRO[®] 6.5 para as capturas das imagens em movimento em formato digital seguido de congelamento do quadro selecionado; 2) Adobe Photoshop 5.5[®] para a análise dos quadros obtidos. Estes softwares também são listados na seção 3.9.1 (pág. 30). Os quadros selecionados do ponto mais alto e do ponto mais baixo atingido pela cúpula diafragmática durante um ciclo respiratório foram sobrepostos, partindo como ponto de referência fixa para a sobreposição o ângulo reto formado por uma determinada vértebra selecionada, que deverá ser o mesmo para as duas imagens. O quadro superior foi levemente clareado, permitindo a observação simultânea dos dois quadros. Foram traçadas arestas do ponto mais alto para o ponto mais baixo da cúpula diafragmática, permitindo a mensuração da distância deslocada.

Avaliação Postural - Curvaturas Analisadas

A Figura 2 (pág. 15) lista os pontos e ângulos utilizados na avaliação postural das crianças presentes em BD1 e BD2. Para a análise, quando são abordados os termos lordose cervical, cifose torácica, lordose lombar e posição da pelve deve-se levar em consideração os três pontos e ângulos listados na Figura 2, itens (a), (b), (c) e (d), respectivamente, representando: (a) lordose cervical: trágus da orelha, acrômio e C7, sendo o acrômio a vértice do ângulo, preconizamos que quanto maior o valor angular, maior a anteriorização da posição da cabeça e menor a lordose cervical; (b) cifose torácica: L1, acrômio, T7, sendo L1 a vértice do ângulo, preconizamos que quanto maior o valor angular, maior a cifose torácica; (c) lordose lombar: espinha íliaca ântero-superior, L1 e trocanter maior, sendo a espinha íliaca ântero-superior a vértice do ângulo, preconizamos que quanto menor o valor angular, maior a lordose lombar; (d) posição da pelve: face lateral do espaço interarticular da articulação do joelho, espinha íliaca ântero-superior e trocanter maior, sendo a face lateral do espaço interarticular da articulação do joelho a vértice do ângulo, preconizando que quanto maior o valor angular, maior a anteversão da pelve.

Avaliação Postural - Realização das Fotografias

Todos os sujeitos foram submetidos à avaliação postural que foi feita com o auxílio de uma fotografia em norma lateral esquerda para cada participante, preconizando a observação das curvaturas da coluna em vista sagital.

Pequenas bolas de isopor preparadas previamente com fita adesiva dupla face foram utilizadas como marcadores e colocadas em pontos anatômicos específicos: acrômio, C7, trágus da orelha, T7, L1, EIAS, trocanter maior. A escolha dos pontos anatômicos ocorreu em função de critérios como possibilitar análises clínicas relevantes, privilegiar acidentes ósseos de fácil localização advindas dos conhecimentos de anatomia palpatória.

Todos os participantes foram fotografados vestindo obrigatoriamente trajes de banho, descalços com os pés unidos e paralelos e os cabelos foram presos, quando necessário, para permitir a observação da região cervical. Os voluntários foram orientados a manter os olhos abertos para o horizonte e não houve interferência verbal para a correção postural (Liu et al., 2003). Um fio de prumo de 1,0 m foi colocado ao lado esquerdo, próximo do participante.

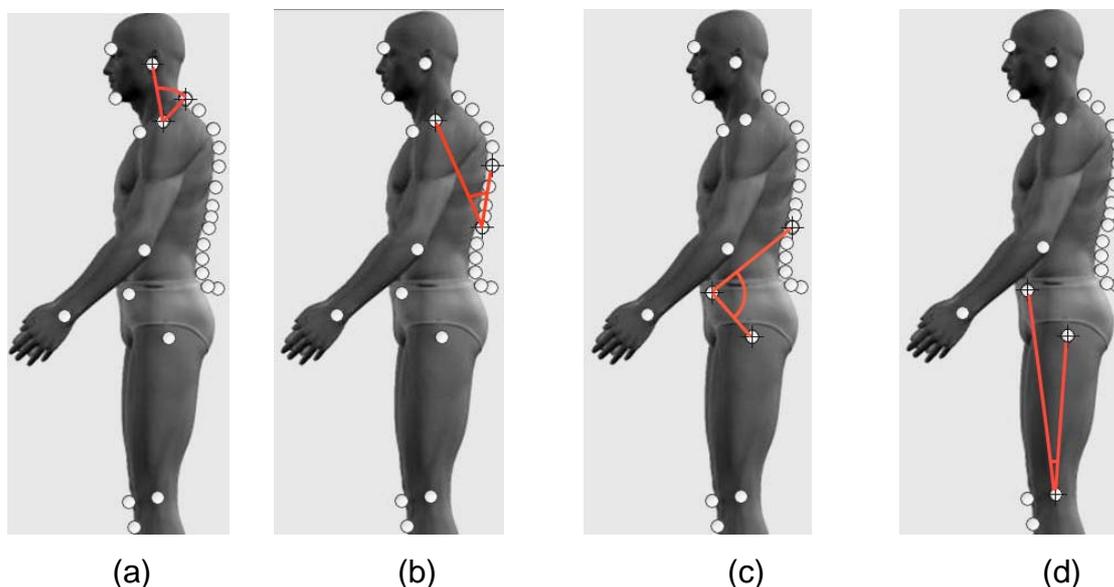


Figura 2: Representação dos pontos e ângulos utilizados na avaliação postural, indicando (a) lordose cervical; (b) cifose torácica; (c) lordose lombar; (d) posição da pelve (Liu, 2006).

Uma fotografia foi realizada com a criança em posição ortostática, sobre uma escada de dois degraus com 42 cm de altura, 15 cm de largura e 34 cm de comprimento, tendo como fundo uma parede de cor branca. A câmera fotográfica SonyR Cyber-shot® 2.0 *mega pixels* foi girada e travada à 90° da posição horizontal com a finalidade de focar longitudinalmente o corpo dos indivíduos. Ela foi posicionada a uma distância de 4,0 m da parede, sobre um tripé de 1,50 m de altura e ajustada para que as arestas inferiores do foco da lente fotográfica fossem coincidentes com as arestas correspondentes à largura do segundo degrau da escada em que o paciente estava apoiado. (Liu et al., 2003).

Avaliação Postural - Análise das Fotografias

Foi utilizado o software para análise postural (SAPO) (Duarte et al., 2006) conforme listado na seção 3.2.3 (pág. 11).

A análise das fotos obedeceu à seguinte seqüência: abertura da foto, zoom de 40%, calibração da imagem a partir do fio de prumo, marcação dos pontos anatômicos e produção de relatório sobre a localização dos pontos no espaço a partir das coordenadas X (horizontal) e Y (vertical).

O fio de prumo garante ao programa o alinhamento vertical das imagens, que podem possivelmente estar rotacionadas, para um mesmo plano e a mensuração de seu comprimento permite a calibração das medidas angulares em valores reais.

3.3 Padrão Ouro

A fisioterapeuta Dra. Liu Chiao Yi realizou a validação dos agrupamentos detectados pelo extrator de características e também emitiu diagnóstico quanto à necessidade dos pacientes da BD2 de realizar intervenção fisioterapêutica. A opinião do especialista foi adotada como padrão ouro e foi utilizada para determinar classes de postura das crianças respiradoras bucais do software para classificação automática da postura.

3.4 Redes Neurais Artificiais e a Classificação de Padrões

Originalmente, as pesquisas em RNA têm sido motivadas pelo reconhecimento de que o cérebro humano é superior no processamento e na execução de uma grande variedade de tarefas, comparando-se ao computador digital (Haykin, 1999; Roque, 2007). Uma RNA representa um processador paralelo, constituído de unidades de processamento simples, que armazena conhecimento experimental e o torna disponível para uso (Haykin, 1999). Assemelha-se ao cérebro humano em dois aspectos (Haykin, 1999):

- O conhecimento é construído pela rede neural a partir de informação proveniente de um ambiente e por meio de um processo de aprendizagem, neste caso, computacional;
- As conexões entre neurônios artificiais, conhecidas como pesos sinápticos, são utilizadas para armazenar este conhecimento adquirido.

Neste contexto, a aprendizagem é um processo pelo qual os parâmetros livres de uma RNA são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida (Haykin, 1999). Um conjunto pré-estabelecido de regras definidas para a solução de um problema de aprendizagem é denominado um algoritmo de aprendizagem. Não há um algoritmo único de aprendizagem para se projetar uma RNA. De fato, há uma variedade de algoritmos de aprendizagem, cada qual oferecendo vantagens específicas (Haykin, 1999). Desta maneira, um algoritmo de aprendizagem define basicamente a estrutura de treinamento de um modelo de RNA e tem implicação direta na formação de seus parâmetros.

Porém, uma dificuldade quanto à aplicação prática das RNA decorre quando queremos determinar um modelo de RNA para fazer um estudo específico. Na verdade, a escolha de um modelo de RNA particular é influenciada pela tarefa de aprendizagem que ela deve executar (Haykin, 1999). De maneira geral, seis tarefas de aprendizagem podem ser executadas utilizando-se RNA (Haykin, 1999): associação de padrões, reconhecimento de padrões, aproximação de funções, controle, filtragem e formação de feixe. Destas, Cross et al. (1995) indicam que durante a prática clínica utiliza-se mais frequentemente a função associativa de padrões. De fato, sabe-se que a associação é uma ca-

racterística proeminente da memória humana, e todos os modelos de cognição utilizam a associação de uma forma ou de outra como operação fundamental (Anderson & Sutton, 1995).

Particularmente, a regra de modelar sistemas para a decisão médica pode ser similar a métodos estatísticos para reconhecimento de padrões (Reggia, 1993). O reconhecimento de padrões, também denominado classificador de padrões (Haykin, 1999), é formalmente conceituado como o processo pelo qual um padrão ou sinal recebido é atribuído a uma classe dentre um número pré-determinado de classes, também denominadas categorias. Uma RNA realiza a identificação de padrões passando inicialmente por uma seção de treinamento, durante a qual se apresenta repetidamente à rede um conjunto de dados de entrada junto com a categoria a qual cada padrão particular pertence. Posteriormente, a rede é capaz de identificar a classe de um novo padrão devido à informação que ela extraiu dos dados de treinamento (Haykin, 1999).

Em termos genéricos, as máquinas de reconhecimento de padrões que utilizam RNA podem assumir uma das duas formas:

- A máquina de reconhecimento é dividida em duas partes: uma rede não-supervisionada para extração de características e uma rede supervisionada para classificação, como mostrado na Figura 3. Este método segue a abordagem tradicional de reconhecimento estatístico de padrões (Duda et al., 2000; Fukunaga, 1990);
- A máquina de reconhecimento é projetada como uma única rede de múltiplas camadas utilizando um algoritmo de aprendizagem supervisionada (Haykin, 1999).

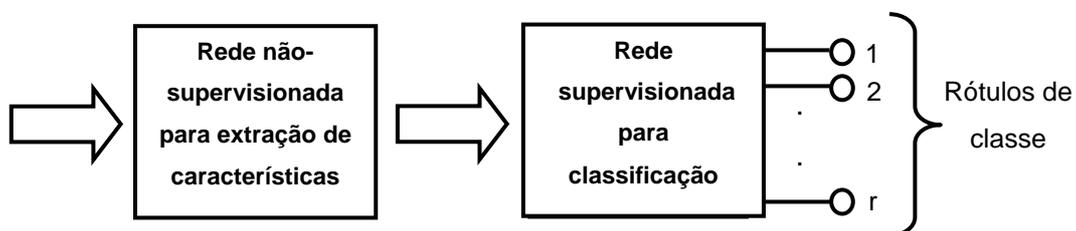


Figura 3: Abordagem clássica para reconhecimento de padrões utilizando RNA (Haykin, 1999).

Neste estudo o SOM, ou mapa auto-organizável, é aplicado para a tarefa de extração de características. Esta escolha deu-se pela propriedade deste modelo de RNA em “transformar um padrão de sinal incidente de dimensão arbitrária em um mapa discreto uni ou bidimensional, e realizar esta transformação adaptativamente de uma maneira topologicamente ordenada” (Haykin, 1999). Este método permite realizar o agrupamento de dados multidimensionais de um repositório de dados e como resposta o SOM fornece uma representação bidimensional topologicamente ordenada dos dados, de maneira que dados com características intrínsecas similares tendem a ficar em regiões vizinhas (Haykin, 1999).

Como informado anteriormente, foram escolhidos os seguintes algoritmos para realizar o diagnóstico do respirador bucal: *perceptron*, BP, LVQ e o SOM. Apesar do diagnóstico de respirador nasal/bucal ser realizado no consultório do fisioterapeuta, o modelo de RNA que apresentar maior número de acertos para esta tarefa pode ser aplicado para a tarefa de classificação automática da postura de crianças respiradoras bucais.

A escolha do *perceptron* ocorreu devido a sua característica de realizar linearmente a separação entre classes (Roque, 2007), a do BP ocorreu pelo motivo de ser um dos modelos de RNA mais populares na classificação de dados biomédicos (Pesonen, 1996; Ng & Chong, 2006), a do SOM ocorreu por apresentar resultados importantes na classificação de dados biomédicos (Lisboa, 2002) e a do LVQ ocorreu por ser um modelo de RNA supervisionado baseado na aprendizagem competitiva (Kohonen, 1997).

Segue abaixo características destes algoritmos na classificação de padrões em dados biomédicos.

3.4.1 Mapa Auto-organizável (SOM)

O SOM baseia-se em um algoritmo de aprendizagem não supervisionada conhecida como aprendizagem competitiva (Haykin, 1999). Uma vez que o algoritmo do SOM tenha convergido, o mapa de características calculado mostra características estatísticas importantes do espaço de entrada. Uma ilustração deste fato é apresentada de forma esquemática na Figura 4. Nesta, consi-

dere que I representa um espaço de entrada de dados contínuo e O , um espaço de saída discreto, cuja topologia é definida dispondo-se um conjunto de neurônios artificiais como os nós computacionais de uma grade. Suponha que E represente uma transformação não-linear chamado de mapa de características, que desenha o espaço de entrada I para o espaço de saída O , como mostrado por (Haykin, 1999):

$$E: I \rightarrow O . \quad (1)$$

Desta forma, dado um vetor de entrada x , o algoritmo do SOM primeiro identifica um neurônio artificial com a melhor relação, ou seja, o neurônio artificial vencedor $i(x)$ no espaço de saída O , de acordo com o mapa de características E . O vetor de peso sináptico w_i do neurônio artificial $i(x)$ pode então ser visto como um ponteiro para aquele neurônio artificial no espaço de entrada I ; isto é, os elementos sinápticos do vetor w_i podem ser vistos como as coordenadas da imagem do neurônio artificial i projetada no espaço de entrada (Haykin, 1999).

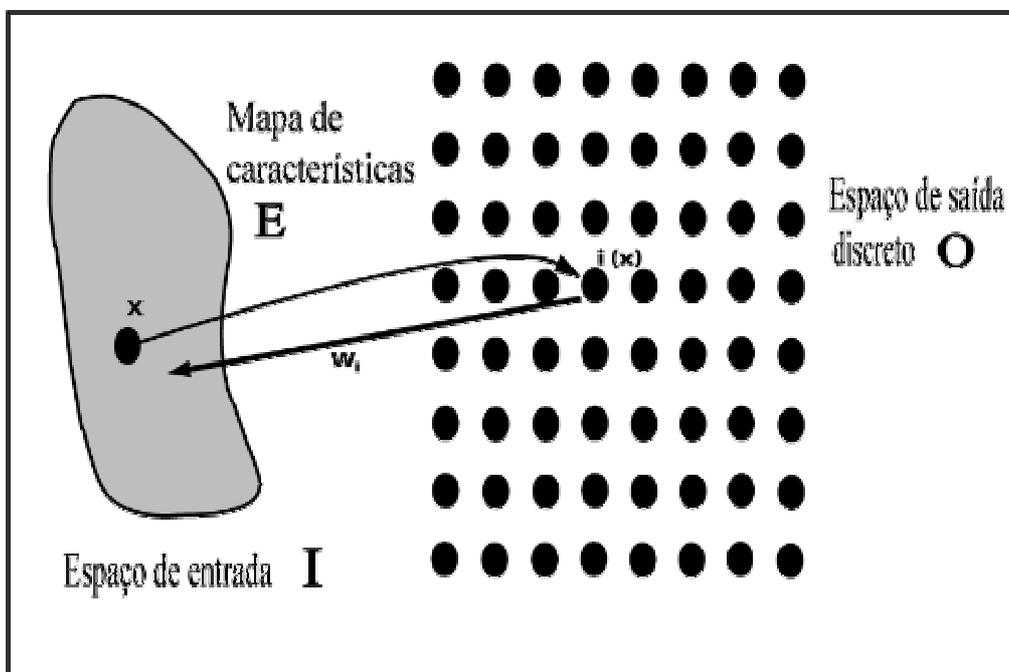


Figura 4: Ilustração do mapa de características (Haykin, 1999).

O mapa de características E possui as seguintes propriedades (Haykin, 1999):

- Propriedade 1 - Aproximação do espaço de entrada. O mapa de características E , representado pelo conjunto de vetores de pesos sinápticos $\{w_j\}$ no espaço de saída O , fornece uma boa aproximação para o espaço de entrada I ;
- Propriedade 2 - Ordenação topológica. O mapa de características E calculado pelo algoritmo do SOM é ordenado topologicamente, sendo que a localização espacial de um neurônio artificial na grade corresponde a um domínio particular ou característica dos padrões de entrada;
- Propriedade 3 - Seleção de características. A partir dos dados do espaço de entrada com uma distribuição não-linear, o SOM é capaz de selecionar um conjunto das melhores características para aproximar a distribuição subjacente.

Como citado anteriormente, no reconhecimento de padrões o primeiro passo é a extração (seleção) de características, que normalmente é realizada de uma maneira não-supervisionada. O objetivo desta etapa é selecionar um conjunto razoavelmente pequeno de padrões, no qual está concentrado o conteúdo de informação essencial dos dados de entrada (a ser classificado) (Haykin, 1999). O SOM pode ser aplicado também para a tarefa de seleção de características, porque além de realizar a redução de dimensionalidade ou compressão de dados (Gersho et al., 1992) (ver propriedade 1), este modelo de RNA realiza uma representação fiel das características relevantes dos vetores de entrada (propriedade 2), resultando na seleção de um conjunto das características do espaço de entrada (propriedade 3).

O segundo passo no reconhecimento de padrões é a classificação dos dados, cujas características selecionadas dos dados de entrada são atribuídas às classes individuais. A abordagem clássica para o desenvolvimento de uma máquina reconhecedora de padrões é utilizar, de alguma forma, um modelo supervisionado (Duda et al., 2000). Porém, Haykin (1999) cita que o SOM pode realizar a classificação dos dados. Este fato ocorre pela característica do SOM de rotular a cada neurônio artificial atributos similares do conjunto de entrada.

3.4.2 Aprendizagem por Quantização Vetorial (LVQ)

O LVQ baseia-se na aprendizagem não supervisionada e utiliza a técnica de aprendizagem supervisionada, podendo ser aplicado para a classificação de padrões de dados biomédicos (Pesonen, 1996). Neste modelo de RNA um vetor é representante de todos os possíveis vetores que estiverem na sua vizinhança. Se ligarmos os vetores por linhas e cortarmos perpendicularmente nos seus pontos médios, as linhas de corte se unirão e formarão uma divisão do espaço que é chamada de mosaico de Voronoi ou vetores de Voronoi (Roque, 2007). O contínuo de pontos que pertence ao interior de uma das regiões do mosaico é representado pelo vetor protótipo correspondente. A Figura 5 ilustra o mosaico de Voronoi.

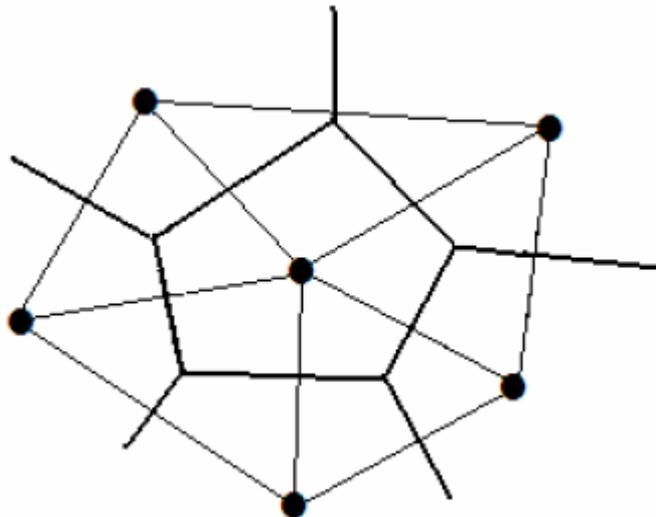


Figura 5: Mosaico de Voronoi (Roque, 2007).

Suponha que um vetor de entrada x é tomado aleatoriamente do espaço de entrada. Se os rótulos da classe do vetor de entrada x e um vetor de Voronoi w concordarem, o vetor de Voronoi w é movido em direção ao vetor de entrada x , por outro lado, se rótulos da classe do vetor de entrada x e do vetor de Voronoi w discordarem, o vetor de Voronoi w será afastado do vetor de entrada x (Haykin, 1999). Por fim, a disposição espacial de cada rótulo do vetor de Voronoi w representa um conjunto isolado do vetor de entrada de maneira topologicamente ordenada. Desta maneira, dado um novo vetor de entrada y é possível estabelecer o seu respectivo rótulo no vetor w . Por meio desta

característica, e como informado acima, o LVQ pode ser aplicado como um classificador de padrões.

3.4.3 Perceptron

O *perceptron* é a forma mais simples de uma RNA usada para a classificação de padrões ditos linearmente separáveis – padrões que se encontram em lados opostos de um hiperplano – e utiliza como princípio básico aprendizagem por correção de erros (Haykin, 1999).

O objetivo do *perceptron* é classificar corretamente o conjunto de estímulos aplicados externamente x_1, x_2, \dots, x_m em uma das duas classes ℓ_1 ou ℓ_2 . A regra de decisão para classificação é atribuir o ponto apresentado pelas entradas x_1, x_2, \dots, x_m à classe ℓ_1 , se a saída do perceptron for +1, e à classe ℓ_2 , se ela for -1 (Haykin, 1999).

Para compreender melhor o comportamento do *perceptron* para a tarefa da classificação de padrões, normalmente se traça um mapa das regiões de decisão no espaço de sinal m -dimensional abrangido pelas m variáveis de entrada x_1, x_2, \dots, x_m . Na forma mais simples do *perceptron*, existem duas regiões separadas por um hiperplano definido por (Haykin, 1999):

$$\sum_{i=1}^m w_i x_i + b = 0. \quad (2)$$

Este fato está ilustrado na Figura 6 para o caso de duas variáveis x_1 e x_2 , para o qual a fronteira de decisão toma a forma de uma linha reta. Um ponto $(x_1$ e $x_2)$ que se encontra acima da linha de fronteira é atribuído à classe ℓ_1 e um ponto $(x_1$ e $x_2)$ que está abaixo da linha de fronteira é atribuído à classe ℓ_2 (Haykin, 1999).

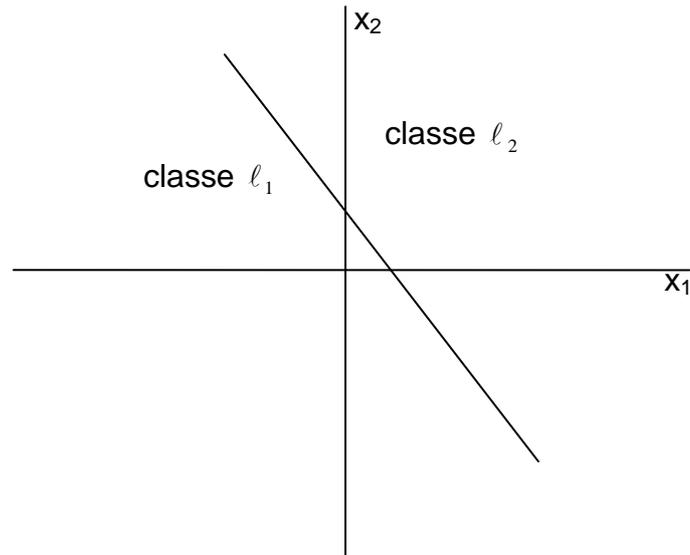


Figura 6: Ilustração do hiperplano como fronteira de decisão para um problema de classificação de padrões bidimensionais de duas classes (Haykin, 1999).

3.4.4 Backpropagation (BP)

O algoritmo BP é baseado na regra de aprendizagem por correção de erro e consiste em dois passos por meio das diferentes camadas da rede (Haykin, 1999): um passo para frente e um passo para trás. No passo para frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga por meio da rede. Durante o passo da propagação, os pesos sinápticos da rede são todos fixos. Durante o passo para trás os pesos sinápticos são todos ajustados de acordo com uma regra de correção de erro. Especificamente, a resposta real da rede é subtraída de uma resposta desejada para produzir um sinal de erro. Durante o passo para trás, os pesos sinápticos são ajustados para fazer com que a resposta da rede se mova para mais perto da resposta desejada, em um sentido estatístico.

O BP é aplicado às redes conhecidas como *perceptrons* de múltiplas camadas (MLP, *multilayer perceptron*) que consistem em uma camada de entrada de neurônios computacionais, uma ou mais camadas ocultas de neurônios computacionais e uma camada de saída de neurônios computacionais. A Figura 7 mostra o grafo arquitetural de um MLP, sendo que neste modelo de RNA todos os neurônios, em qualquer camada, estão conectados com todos os neurônios da camada anterior (Haykin, 1999).

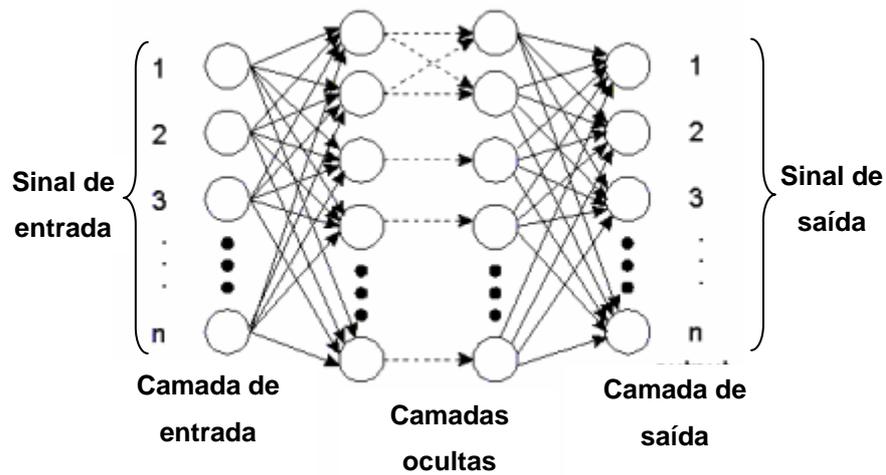


Figura 7: Grafo arquitetural de um MLP (Haykin, 1999).

Cada neurônio oculto ou de saída de um MLP é projetado para realizar o cálculo funcional da saída de um neurônio, que é expresso como uma função não-linear do sinal de entrada e dos pesos sinápticos associados com neurônio (Haykin, 1999). Desta maneira, algoritmo BP aplicado ao MLP realiza uma classificação de padrões de maneira não-linear e de natureza estocástica; isto é, tem a tendência de convergir em torno da direção de um mínimo da superfície de erros, e pode ser aplicado para a tarefa de reconhecimento de padrões (Haykin, 1999).

3.5 Seleção de Parâmetros e Modelos

É necessário determinar estruturas (parâmetros) dos modelos RNA adequadas para a tarefa de reconhecimento de padrões. A fim de realizar essas determinações, algoritmos de seleção de parâmetros são utilizados. Como exemplo podemos citar um método de generalização de estimativa de erro baseado em reamostragem conhecido como validação cruzada (*cross-validation*) (Kovaki 1995, Burnham, 2004). A validação cruzada pode ser aplicada na seleção de melhores modelos de RNA para uma determinada tarefa de classificação de padrões.

Segue abaixo análise dos dois algoritmos de validação cruzada utilizados neste trabalho. Estes foram aplicados para a tarefa de seleção de parâmetros e modelos.

3.5.1 K-fold

O algoritmo *k-fold* consiste em dividir o conjunto disponível de N exemplos em K subconjuntos, $K > 1$. O modelo é treinado com todos os subconjuntos, exceto um, e o erro de validação é medido testando-o com este subconjunto deixado de lado no treinamento. Este procedimento é repetido para um total de K iterações, cada vez usando um subconjunto diferente para a validação, como ilustrado na Figura 8 para $K = 5$ (Burnham, 2004). No trabalho aqui apresentado, o desempenho dos modelos de RNA é avaliado pela média da sensibilidade e especificidade (Massad, 2004) obtida na validação sobre todas as tentativas do experimento.

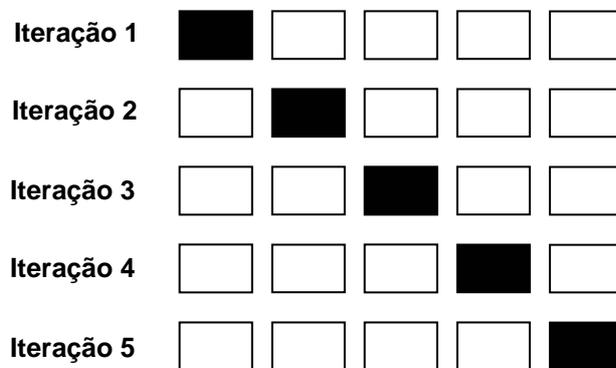


Figura 8: Ilustração do processo *k-fold*. Para cada iteração, o subconjunto de dados sombreado é usado para validar o modelo treinado com os dados restantes (Haykin, 1999).

3.5.2 Leave-one-out (LOO)

No algoritmo *leave-one-out*, $N - 1$ exemplos são usados para treinar o modelo, e este é validado testando-o sobre o exemplo deixado de fora. O experimento é repetido para um total de N vezes, cada vez deixando de fora um exemplo diferente para a validação (Burnham, 2004). Especificamente, a especificidade e a sensibilidade média para todas as N tentativas são utilizadas para avaliar o desempenho dos modelos de RNA utilizados neste trabalho.

3.6 Padrão de Entrada

Neste estudo são testados para os diferentes modelos de RNA diferentes padrões de entrada de BD1. Para facilitar o apontamento do padrão de entrada, será informado seu rótulo conforme listado na Tabela 7.

Padrão de Entrada	Rótulo do Padrão de Entrada
Comportamento das curvaturas da coluna vertebral (4) e excursão do músculo diafragma (2)	PE1
Comportamento das curvaturas da coluna vertebral (4), excursão do músculo diafragma (2), peso (1) e altura (1)	PE2
Comportamento das curvaturas da coluna vertebral (4)	PE3
Excursão do músculo diafragma (2)	PE4
Peso (1) e altura (1)	PE5

Tabela 7: Diferentes conjuntos de dados de BD1 utilizados como padrões de entrada e seus respectivos rótulos. O número entre parênteses mostra a quantidade de variáveis utilizadas para cada subconjunto.

3.7 Configuração dos Modelos de RNA

Após testes computacionais e aplicando-se o algoritmo de validação cruzada *leave-one-out*, segue a configuração final dos parâmetros dos quatro modelos de RNA utilizados neste trabalho:

- *Perceptron* – Estrutura da rede: 1 neurônio na camada de saída. Número máximo de épocas para treinamento: 100.
- BP: Estrutura da rede: 20 neurônios na primeira camada oculta, 5 neurônios na segunda camada oculta e 1 neurônio na camada de saída. Função de treinamento: Levenberg-Marquardt (Hagan, 1994). Número máximo de épocas para treinamento: 100.

- LVQ – Estrutura da rede: 3 x 3 neurônios. Inicialização dos vetores protótipos: linear. Relação de vizinhança: hexagonal. Quantidade de épocas: 100. Taxa de aprendizado utilizado no treinamento: 0,01.
- SOM – Estrutura da rede: 3 x 3 neurônios. Inicialização dos vetores protótipos: linear. Relação de vizinhança: hexagonal. Função de vizinhança: gaussiana. Algoritmo de treinamento: em lote (Kohonen, 1997).

3.8 Análise Estatística

O foco desta seção é apresentar as características fundamentais dos modelos estatísticos utilizados neste trabalho.

3.8.1 Teste t de Student

O teste t de *Student* é utilizado para verificar se existem diferenças médias significativas entre dois grupos (ou seja, se os grupos são diferentes). Este teste é aplicado para dados registrados entre pares e que ambos possuam, obrigatoriamente, distribuição normal. A distribuição normal pode ser detectada, por exemplo, analisando o gráfico da função da densidade da distribuição. Para este tipo de gráfico, uma distribuição normal apresenta formato de sino (ou seja, unimodal e discreta) (Massad, 2004).

Como resposta, o teste t de *Student* apresenta o valor de p . Caso o valor de p seja menor que 0,05 (5% de nível de significância), o teste t de *Student* mostra que existem diferenças médias significativas entre os dados analisados (Massad, 2004).

3.8.2 Especificidade e Sensibilidade

Supondo que temos uma amostra de indivíduos portadores de uma patologia determinada por algum teste “padrão ouro”. A capacidade de um classificador de padrões para identificar os indivíduos patológicos a partir da comparação de sua resposta com o padrão ouro é chamada de sensibilidade (Massad, 2004).

Quando temos uma amostra de indivíduos sadios e queremos saber a capacidade do classificador de padrões em mostrar a resposta correta para este conjunto, esta resposta é chamada de especificidade (Massad, 2004).

3.8.3 Curva ROC

A curva característica Receiver Operating Characteristic (ROC) é um diagrama que correlaciona a sensibilidade com o complemento da especificidade atingido por um classificador, por meio da variação do corte de um ou mais parâmetros do teste. A curva ROC é utilizada para escolher o melhor classificador de padrões para uma determinada tarefa (Metz, 1978; Massad, 2004).

Por exemplo, a Figura 9 mostra duas curvas ROC para os classificadores hipotéticos A e B, e o desempenho destes é dado a partir do cálculo da área de cada curva. A maior área sob a curva ROC (AUC, *area under curve*) determina o melhor classificador para um determinado problema de reconhecimento de padrões (Metz, 1978).

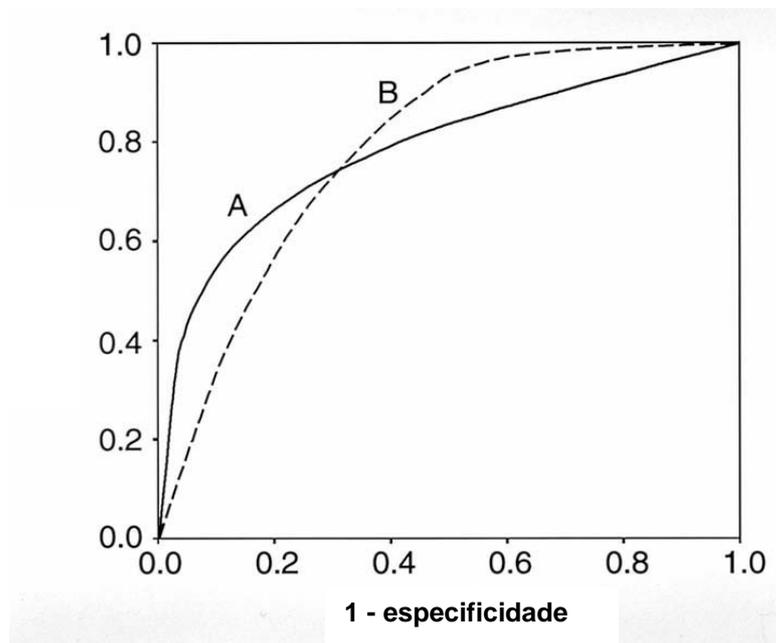


Figura 9: Exemplo de duas curvas ROC comparando o desempenho de diferentes classificadores de padrões (A e B).

3.9 Softwares Utilizados

Diferentes tipos de software foram utilizados para a solução de tarefas distintas neste trabalho, conforme descrição apresentada nas seções a seguir.

3.9.1 Análise da Postura e Músculo Diafragma

Conforme informado na seção 3.2.3 (pág. 11), em sua tese de doutorado Liu (2006) utilizou o Adobe Premiere PRO[®] 6.5 para as capturas das imagens em movimento em formato digital seguido de congelamento do quadro selecionado e Adobe Photoshop 5.5[®] para a análise dos quadros obtidos. O software para avaliação postural (SAPO) (Duarte, 2006) foi utilizado para analisar o comportamento das curvaturas da coluna vertebral.

3.9.2 Implementação dos Modelos de RNA

Foi utilizado o pacote SOM Toolbox (Vesanto et al., 2000) para implementar o SOM e o LVQ e o Neural Networks Toolbox[®] (The MathWorks Inc.) para implementar o *perceptron* e o BP. Estes pacotes possibilitam o desenvolvimento dos modelos de RNA por meio do Matlab[®] (The MathWorks Inc.). A versão do Matlab utilizado neste trabalho foi a R14.

A determinação do Matlab como ferramenta de modelagem deu-se pela variedade de algoritmos e funções disponíveis tanto para análise estatística, como para simulação de RNA. Existem outros softwares de simulação, inclusive sistemas gratuitos como o Scilab (<http://www.scilab.org>) e Octave (<http://www.octave.org>), porém estes não apresentam as funcionalidades disponíveis no Matlab necessárias a este trabalho.

3.9.3 Classificação Automática da Postura

O software final obtido por meio da escolha do modelo de RNA característico para classificação da postura em crianças respiradoras bucais foi implementado em Visual Basic 6.0[®] (Microsoft Corporation), utilizando como banco de dados o Microsoft Access[®] 2002 (Microsoft Corporation).

Foi desenvolvida uma biblioteca dinâmica (DLL) baseada no Matlab e o SOM Toolbox com os vetores protótipos treinados a partir do modelo de RNA escolhido para a classificação automática da postura em crianças respiradoras bucais. O Visual Basic 6.0 utiliza essa DLL para realizar a classificação da postura de crianças respiradoras bucais.

O Visual Basic foi escolhido para esse trabalho devido ao domínio do autor deste trabalho nesta linguagem e ambiente de programação.

3.9.4 Análises Estatísticas

Para realizar as análises estatísticas presentes neste trabalho foi utilizado o Matlab em conjunto com Statistics Toolbox[®] (The MathWorks Inc.).

3.10 Hardware e Sistema Operacional

Para este estudo foi utilizado um microcomputador com a seguinte configuração:

- Sistema Operacional: Windows XP Professional 32 bits;
- Placa-mãe: Asus A8V-Deluxe;
- Processador: Athlon 64 3300+;
- Memória RAM: 1 Giga bytes;
- Disco rígido: 80 Giga bytes.

3.11 Software e Algoritmos Desenvolvidos

Segue anexo a este trabalho um CD contendo 2 pastas, sendo:

- Pasta `algoritmos`: apresenta os algoritmos desenvolvidos nesta dissertação, contendo os seguintes arquivos desenvolvidos em Matlab:
 - `convergenciaLeaveoneout.m`: calcula resultados apresentados na Figura 16 dessa dissertação;
 - `fiveFold.m`: realiza o cálculo do *five-fold*;
 - `threeFold.m`: realiza o cálculo do *three-fold*;
 - `leaveoneout.m`: realiza o cálculo do *leave-one-out*;

- ROCLeaveoneout.m: calcula a curva ROC utilizando o algoritmo *leave-one-out*;
- ROCThreeFold.m: calcula a curva ROC utilizando o algoritmo *t-hree-fold*;
- mostraBMU: algoritmo para calcular paciente a ser classificado. Utilizado como base para DLL gerada nesta dissertação;
- Pasta SCPB: arquivo de instalação do SCPB - Software para Classificação da Postura de Crianças Respiradoras Bucais.

As demais informações sobre o conteúdo do CD e sobre como proceder em seu uso estão disponíveis no arquivo `leiametext` na raiz do CD.

4 Resultados

Os resultados deste trabalho são apresentados em três fases. Primeiramente, é realizada extração de características do BD1 utilizando o SOM, a fim de determinar classes de crianças respiradoras bucais. Posteriormente, por meio dos algoritmos de seleção de modelos é determinado o modelo de RNA característico para a classificação automática da postura de crianças respiradoras bucais. Por último, é realizada a validação do software desenvolvido neste estudo.

4.1 Investigação do Perfil Postural de Crianças Respiradoras Bucalis

A fim de determinar o padrão de entrada utilizado para classificar perfis posturais de crianças respiradoras bucais, Liu (2006) aplicou o teste t de *Student* em todos os atributos de BD1 para verificar se existem diferenças médias significativas entre grupo respirador bucal e nasal. A Tabela 8 mostra os resultados.

Atributos	P
lordose cervical	0,03
lordose lombar	0,01
cifose torácica	0,02
posição pélvica	0,01
PD	0,01
PE	0,01
peso	0,89
altura	0,78

Tabela 8: Aplicação do teste t de *Student* em todas as variáveis de BD1.

Por meio da Tabela 8, foram utilizados como padrão de entrada ao SOM para classificar perfis posturais de crianças respiradoras bucais todos os atributos de BD1, exceto peso e altura, pois estes não apresentaram diferenças médias significativas ($p > 0,05$).

A Figura 10 mostra a rede SOM após o seu treinamento, utilizando o padrão de entrada listado acima e as configurações dos seus parâmetros conforme listado no capítulo 3 (pág. 6). Pode-se identificar que a rede divide o pa-

drão de entrada em duas categorias bem definidas, conforme representado pela Figura 10. Os neurônios 1, 2, 3, 4 e 7 representam crianças respiradoras bucais e os neurônios 5, 6, 8 e 9 representam crianças caso controle. A Tabela 9 mostra a média de cada atributo para o conjunto de pacientes agrupados em cada neurônio

O único erro cometido nessa representação ocorre para o neurônio 8, que é um neurônio de rótulo “respirador bucal” e que corretamente representa quatro crianças desta classe, mas, erroneamente, representa também uma criança respiradora bucal. Portanto, dos 52 casos usados para se avaliar o desempenho da rede, apenas um é classificado erroneamente.

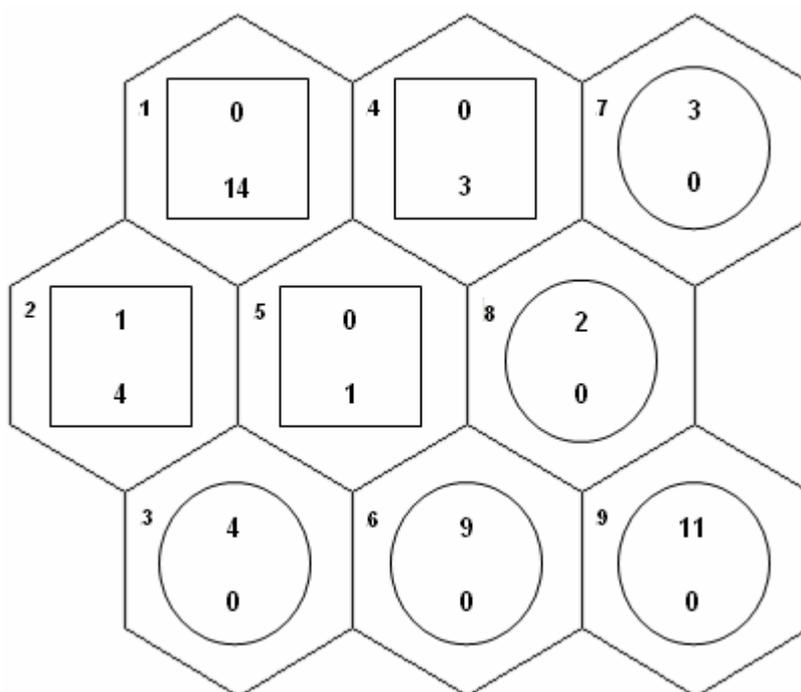


Figura 10: Mapa gerado após o treinamento do SOM. Cada hexágono representa um neurônio, com sua identificação no lado superior esquerdo. No interior de cada hexágono está desenhado um círculo ou um quadrado. O quadrado indica que o neurônio representa crianças respiradoras nasais e o círculo indica que representa crianças respiradoras bucais. Dentro de cada círculo e quadrado está mostrada a quantidade de crianças respiradoras bucais (número acima) e de crianças respiradoras nasais (número abaixo) agrupadas sob o neurônio correspondente.

Neurônio	Lordose Cervical	Lordose Lombar	Cifose Torácica	Posição da Pelve	PD	PE
1	56,30	97,40	48,50	11,00	0,71	0,77
2	50,00	109,30	46,20	10,70	0,90	0,92
3	53,10	113,10	47,00	7,70	0,93	0,95
4	65,60	100,00	44,20	10,00	0,92	0,91
5	58,50	105,30	42,20	7,80	1,20	1,20
6	43,10	117,90	44,00	6,40	1,20	1,00
7	65,50	109,10	41,50	8,90	0,94	1,00
8	63,10	117,30	39,70	7,20	1,00	1,00
9	51,70	121,40	41,40	6,90	1,46	1,47

Tabela 9: Média de cada atributo para o conjunto de pacientes agrupados em cada neurônio, conforme representados pela Figura 10.

Por meio da Tabela 9 e da Figura 10 e de validações com especialista, foi possível classificar os sujeitos em duas classes de respiradores bucais típicos. Estas classes são apresentadas na Figura 11 e possuem as seguintes características:

- **Classe 1 das crianças respiradoras bucais típicas:** esta classe é representada pelos sujeitos agrupados no neurônio 9 da Figura 10 (cor vermelha da Figura 11). Estes apresentam a distância da excursão do diafragma 50% menor, se comparado com o agrupamento das crianças respiradoras nasais típicas, e uma acentuada lordose lombar e anteverção da pelve. A lordose cervical possui o valor próximo à média dos sujeitos respiradores nasais – vide Tabela 3 (pág. 10).
- **Classe 2 das crianças respiradoras bucais típicas:** esta classe é representada pelos sujeitos agrupados no neurônio 6 e 3 (cor azul da Figura 11). Estes apresentam a distância da excursão do diafragma cerca de 25% maior, se comparado com o subgrupo 1 das crianças respiradoras bucais típicas. A lordose cervical apresenta um valor 27% menor se comparado com os sujeitos respiradores nasais típicos.

Além disto, há pacientes agrupados na região representada pela cor amarela da Figura 11. Porém, devido a pouca quantidade destes agrupados em seus devidos neurônios (vide Figura 10), torna-se inviável obter uma classificação final. Conforme validação do especialista, pacientes agrupados nesta área foram classificados como “fronteira”. Além disto, a cor cinza da Figura 11 representa a classe dos pacientes respiradores nasais.

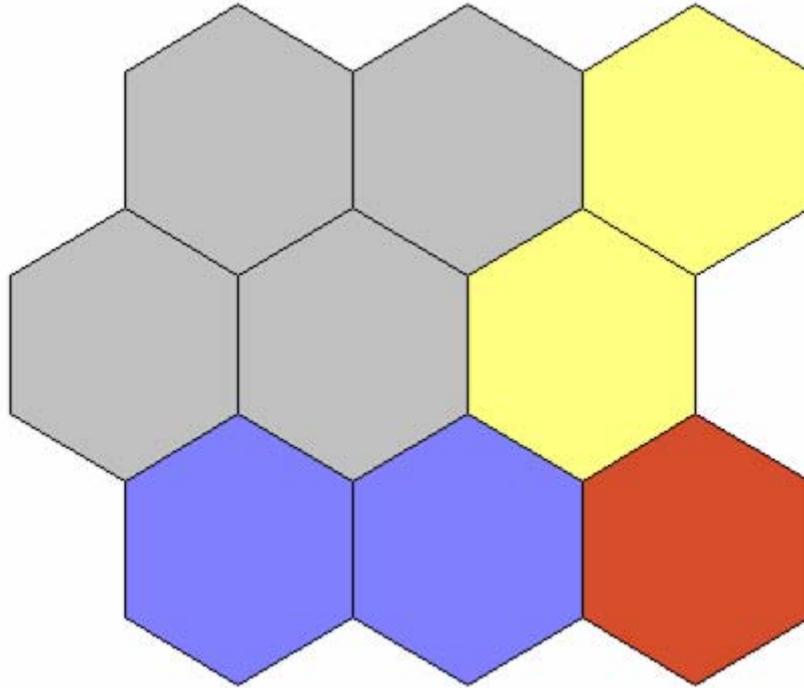


Figura 11: Representação das quatro classes distintas obtidas a partir da análise das médias dos atributos de cada neurônio, conforme listadas pela Tabela 9, seguindo os agrupamentos gerados pela Figura 10 e validado com especialista. As classes 1 e 2, vermelha e azul respectivamente, representam respiradores bucais típicos. A classe 3, amarela, representa a fronteira entre respiradores bucais e nasais e a classe 4, cinza, representa respiradores nasais.

A Tabela 10 mostra a quantidade de pacientes agrupados em cada classe de etiologia para a classe das crianças respiradoras bucais 1 e 2.

Etiologia	C1	C2
Rinite Alérgica (RA)	2	6
G II + A 20% + RA	0	1
G II + A 40% + RA	0	3
G III + A 60% + RA	1	1
G III + A 70% + RA	3	1
G IV + A 80% + RA	3	0
G IV + A 90%	1	1
Funcional	1	0
Desvio de Septo	0	0
Total	11	13

Tabela 10: Quantidade de pacientes das classes das crianças respiradoras bucais 1 (C1) e das crianças respiradoras bucais 2 (C2) contabilizada para cada categoria de etiologia (Tabela 4).

4.2 Seleção do Modelo para Classificação Automática da Postura de Crianças Respiradoras Bucalis

Conforme informado na seção 3.4 (pág. 17) os modelos de RNA utilizados para a tarefa de classificação automática de padrões de crianças respiradoras bucais são: *perceptron*, BP, LVQ e o SOM. Os parâmetros utilizados para todos os modelos de RNA são listados na seção 3.7 (pág. 27).

4.2.1 Five-fold

Para o algoritmo do *k-fold* foi utilizado o valor de $k = 5$ (5-fold) para calcular a sensibilidade e especificada dos modelos de RNA usando os diferentes padrões de entrada (Tabela 7). Foram realizados cinco testes individuais, cujos resultados são mostrados na Tabela 11.

Por meio da Tabela 11, pode-se verificar que existem diferentes valores para os diferentes testes (a), (b), (c), (d) e (e), impossibilitando qualquer conclusão a partir do *5-fold*.

Modelos de RNA	SOM		LVQ		BP		Perceptron	
Padrões de Entrada	e	s	e	s	e	s	e	s
PE1	0,87	0,94	0,93	0,93	0,88	0,85	0,90	0,73
PE2	0,90	0,93	0,77	0,89	0,82	0,92	0,90	0,84
PE3	0,96	0,85	0,78	0,96	0,92	0,82	0,85	0,95
PE4	0,77	0,84	0,73	0,78	0,75	0,80	0,48	0,93
PE5	0,50	0,64	0,43	0,66	0,35	0,61	0,70	0,45

(a)

Modelos de RNA	SOM		LVQ		BP		Perceptron	
Padrões de Entrada	e	s	e	s	e	s	e	s
PE1	0,92	0,96	0,97	0,92	0,85	0,82	0,93	0,32
PE2	0,93	0,90	0,90	0,93	0,89	0,89	0,85	0,45
PE3	0,93	0,89	0,90	0,91	0,85	0,92	0,82	0,35
PE4	0,73	0,82	0,66	0,87	0,74	0,79	0,70	0,34
PE5	0,55	0,63	0,39	0,56	0,38	0,51	0,91	0,10

(b)

Modelos de RNA	SOM		LVQ		BP		Perceptron	
Padrões de Entrada	e	s	e	s	e	s	e	s
PE1	0,94	0,90	0,94	0,89	0,90	0,77	0,93	0,28
PE2	0,88	0,91	0,81	0,87	0,84	0,95	0,88	0,31
PE3	0,88	0,93	0,85	0,87	0,90	0,93	0,88	0,31
PE4	0,70	0,75	0,69	0,78	0,83	0,69	0,82	0,27
PE5	0,52	0,54	0,46	0,55	0,36	0,43	0,85	0,19

(c)

Modelos de RNA	SOM		LVQ		BP		Perceptron	
Padrões de Entrada	e	s	e	s	e	s	e	s
PE1	0,88	0,92	0,93	0,89	0,87	0,76	0,27	0,80
PE2	0,88	0,98	0,85	0,82	0,90	0,92	0,27	0,87
PE3	1,00	0,84	0,77	0,87	0,93	0,87	0,30	0,93
PE4	0,75	0,76	0,78	0,81	0,82	0,80	0,23	0,95
PE5	0,48	0,52	0,37	0,61	0,23	0,66	0,20	0,85

(d)

Modelos de RNA	SOM		LVQ		BP		Perceptron	
Padrões de Entrada	e	s	e	s	e	s	e	s
PE1	0,97	0,91	0,97	0,87	0,74	0,94	0,27	0,97
PE2	0,97	0,90	0,91	0,87	0,90	0,90	0,24	0,97
PE3	0,94	0,90	0,85	0,93	0,92	0,80	0,35	0,97
PE4	0,62	0,80	0,61	0,77	0,58	0,71	0,40	0,91
PE5	0,59	0,69	0,38	0,69	0,18	0,67	0,10	0,87

(e)

Tabela 11: Cinco testes individuais empregando o algoritmo 5-fold para todos os modelos de RNA e padrão de entrada usados neste trabalho. Os itens (a), (b), (c), (d) e (e) mostram os valores de sensibilidade (s) e especificidade (e) para os testes.

4.2.2 Three-fold Estendido

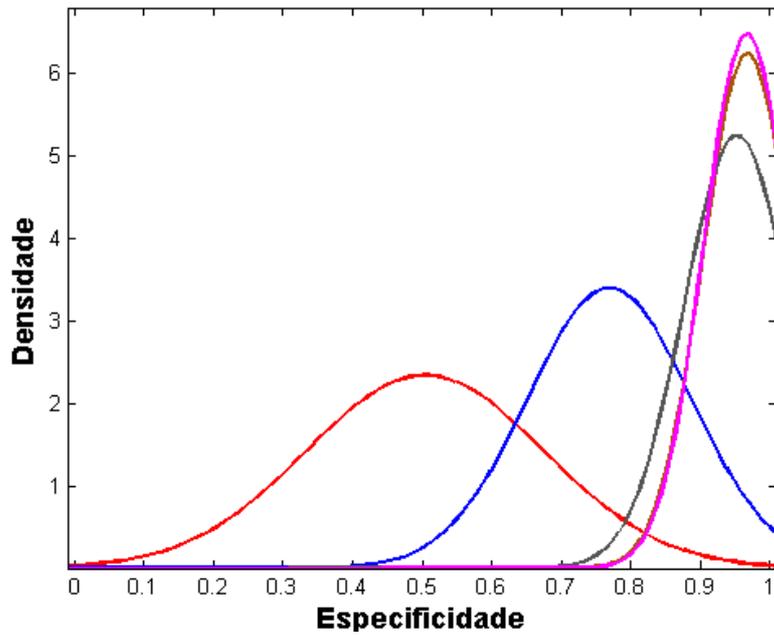
Uma sugestão para que não existam diferentes valores para os resultados do *k-fold* é calcular a média da sensibilidade e especificidade para todas as possíveis combinações presentes no sorteio da divisão dos pacientes para cada *k*. No caso do *3-fold*, utilizando 2/3 dos dados para treinamento (35 pacientes) e 1/3 para validação (17), obtemos uma combinação C_{52}^{17} que resulta em $2,2 \cdot 10^{13}$ diferentes combinações.

Utilizando todos os modelos de RNA determinados neste estudo, e para a totalidade de combinações, o sistema levará aproximadamente três milhões de anos para realizar todos os testes para todas as combinações. Este valor foi obtido multiplicando o tempo que cada modelo de RNA leva para treinar e validar uma combinação por $2,2 \cdot 10^{13}$. O desempenho de tempo para treinar e validar 400 diferentes combinações dos modelos de RNA está listado na Tabela 12. Foram adotadas 400 combinações, pois a partir deste valor o Matlab não apresentou variação de tempo entre cada treinamento/validação.

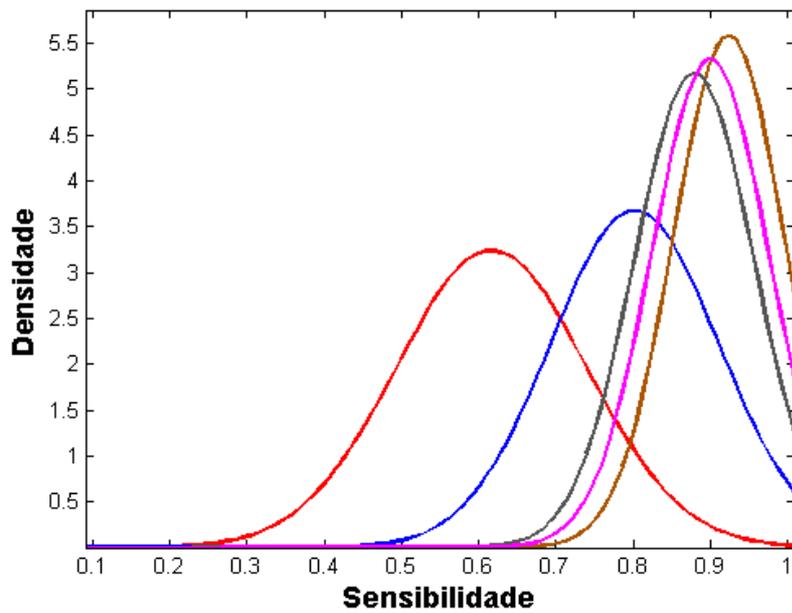
Modelo de RNA	Tempo (s)
SOM	47
LVQ	262
BP	758
<i>Perceptron</i>	576

Tabela 12: Tempo de treinamento e validação dos modelos de RNA para 400 diferentes combinações.

Uma alternativa foi utilizar 10^5 diferentes combinações do conjunto de dados do modelo de RNA que apresentou melhor desempenho de tempo (SOM, Tabela 12). Foram realizados treinamentos e validações individuais para diferentes conjuntos de dados apresentados como padrão de entrada (Tabela 7, pág. 9), obtendo valores de sensibilidade e especificidade individuais para cada combinação. Para determinar as combinações a serem utilizadas como treinamento e validação dos modelos de RNA, foram calculadas as distribuições para os valores individuais de sensibilidade e especificidade dos diferentes conjuntos de dados. As funções densidade das distribuições são mostradas na Figura 12.



(a)



(b)

Figura 12: Função densidade da distribuição para diferentes padrões de entrada. O primeiro gráfico representa a distribuição da especificidade e o segundo gráfico representa a distribuição da sensibilidade. A cor vermelha mostra a distribuição de PE5, a cor azul mostra a distribuição de PE4, a cor marrom mostra a distribuição de PE1, a cor cinza mostra a distribuição de PE3 e a cor rosa mostra a distribuição de PE2.

Sendo assim, foi determinado arbitrariamente 0,5% dos valores de pico para cada distribuição da Figura 12, totalizando em 50 diferentes combinações para cada padrão de entrada. Estas combinações foram aplicadas como padrão de entrada aos modelos de RNA e a Tabela 13 mostra seus valores de sensibilidade e especificidade médias.

Modelos de RNA Padrões de Entrada	SOM		LVQ		BP		Perceptron	
	e	s	e	s	e	s	e	s
PE1	0,97	0,92	0,88	0,87	0,88	0,91	0,38	0,97
PE2	0,97	0,90	0,94	0,89	0,82	0,82	0,38	0,95
PE3	0,95	0,87	0,92	0,92	0,87	0,87	0,37	0,97
PE4	0,78	0,79	0,72	0,83	0,72	0,77	0,37	0,96
PE5	0,49	0,62	0,40	0,58	0,39	0,66	0	1

Tabela 13: Valor médio da sensibilidade (s) e especificidade (e) calculado a partir dos 50 valores de pico de cada distribuição da Figura 12 e apresentado como entrada aos modelos de RNA.

Por meio da Tabela 13, o maior valor de sensibilidade e especificidade foi determinado pelo SOM, utilizando como conjunto de dados os valores do PE1. Porém, como a técnica de videofluoroscopia não é utilizada na prática clínica devido a problemas financeiros, o conjunto de dados que apresentou maior valor de especificidade e sensibilidade foram os valores do PE3. Desta maneira, foi traçada a curva ROC para os dois modelos de RNA (SOM e LVQ) que apresentaram melhores taxas de acerto para PE3 a fim de determinar o modelo de RNA característico para a tarefa de classificação automática da postura de crianças respiradoras bucais.

Porém, para a curva ROC ser traçada, é necessário determinar o corte para o classificador. O corte apresentado para o LVQ e SOM possui a mesma configuração, listado na Figura 13.

Após determinar o corte, conforme listado na Figura 13, foram calculadas e traçadas as curvas ROC do LVQ e SOM para o 3-fold estendido, conforme representado na Figura 14. A Tabela 14 (pág. 43) mostra os valores numéricos dos pontos das curvas ROC do SOM e LVQ para o 3-fold estendido.

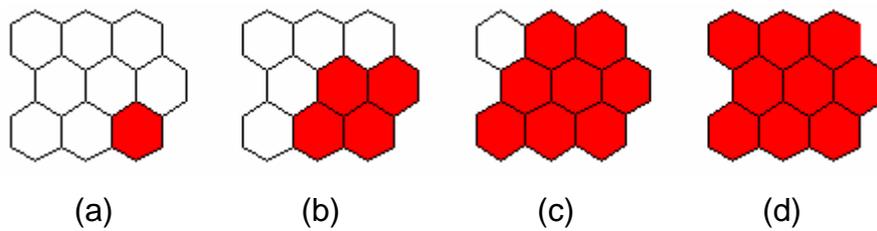


Figura 13: Representação do corte para cálculo da curva ROC para os algoritmos de aprendizagem competitiva (SOM e LVQ). Para cada item (a, b, c e d) foram realizados 50 treinamentos individuais, sendo calculada a especificidade e sensibilidade média dos pacientes pertencentes aos neurônios pintados em vermelho. Estes valores foram utilizados para traçar a curva ROC.

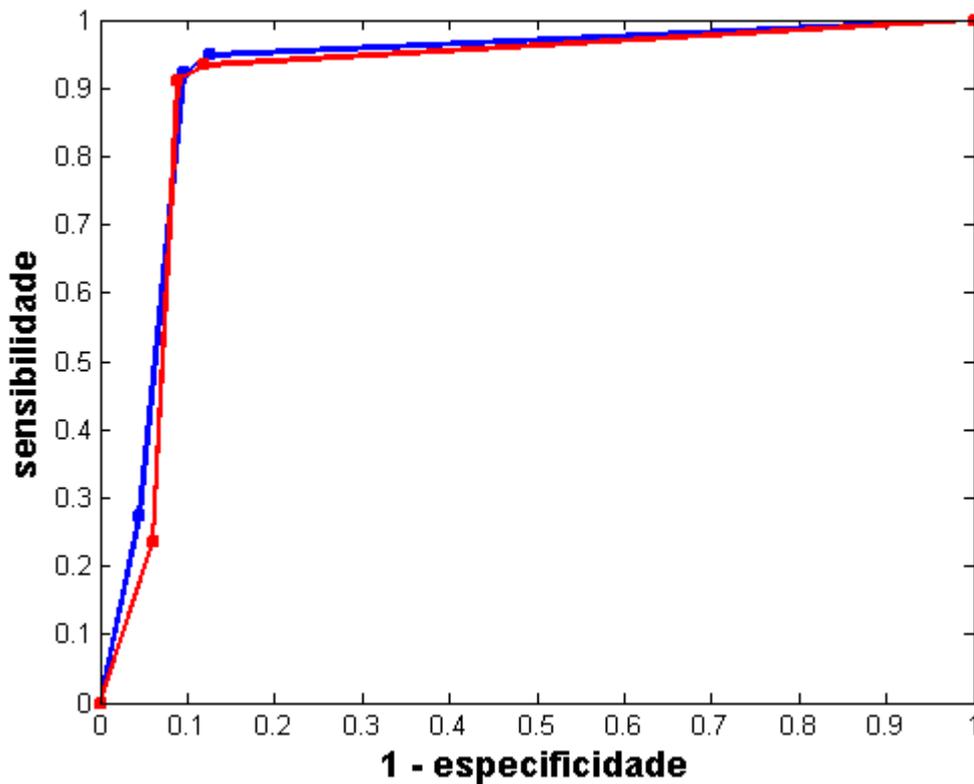


Figura 14: Curva ROC para o 3-fold estendido. A cor vermelha mostra a curva ROC do LVQ e a cor azul mostra a curva ROC do SOM.

A partir da Figura 14 foi calculada a área abaixo da curva ROC para o LVQ e o SOM, apresentando, respectivamente, valor de 0,91 e 0,92. A partir do 3-fold estendido, estes valores mostram que, dentre os modelos estudados, o SOM é melhor modelo de RNA para a tarefa de extração de característica e classificação de padrões de postura em crianças respiradoras bucais.

SOM		LVQ	
s	e	s	e
0,00	0,00	0,00	0,00
0,06	0,33	0,07	0,45
0,10	0,93	0,08	0,96
0,11	0,95	0,13	0,98
1,00	1,00	1,00	1,00

Tabela 14: Valores numéricos dos pontos das curvas ROC do SOM e LVQ para o 3-*fold* estendido. As curvas ROC finais são mostradas na Figura 14. (s) representa a sensibilidade e (e) representa a especificidade.

4.2.3 Leave-one-out (LOO)

Aplicando o *leave-one-out* como algoritmo para seleção de modelos, utilizando os atributos listados na Tabela 7 (pág. 27) como padrões de entrada aos modelos de RNA foram obtidos valores de especificidade e sensibilidade médios listados na Tabela 15.

Modelos de RNA Padrões de Entrada	SOM		LVQ		BP		Perceptron	
	e	s	e	s	e	s	e	s
PE1	0,97	0,97	0,99	0,90	0,98	0,94	0,73	0,98
PE2	0,98	0,95	1,00	0,96	0,86	0,94	0,63	1,00
PE3	0,98	0,93	0,98	0,97	0,96	0,90	0,73	0,98
PE4	0,88	0,87	0,88	0,90	0,88	0,90	0,67	1,00
PE5	0,80	0,76	0,73	0,76	0,67	0,76	0,57	1,00

Tabela 15: Valores de especificidade (e) e sensibilidade (s) médios para os diferentes padrões de entrada apresentados aos modelos de RNA, utilizando *leave-one-out* como algoritmo de seleção de modelo.

Por meio da Tabela 15 observa-se que o maior valor de sensibilidade e especificidade foi determinado pelo LVQ, utilizando como conjunto de dados os valores do PE3. Foi traçada novamente a curva ROC a fim de determinar o modelo de RNA com melhor desempenho para a tarefa de classificação automática da postura de crianças respiradoras bucais. Foram utilizados os modelos de RNA (SOM e LVQ) que apresentaram maiores valores de especificidade

e sensibilidade para o algoritmo *leave-one-out* utilizando PE3 (vide Tabela 15). O corte utilizado foi o mesmo listado na seção 4.2.2 (pág. 39). A Figura 15 mostra as curvas ROC do SOM e LVQ para o *leave-one-out*. A Tabela 16 mostra os valores numéricos dos pontos das curvas ROC do SOM e LVQ para o *leave-one-out*.

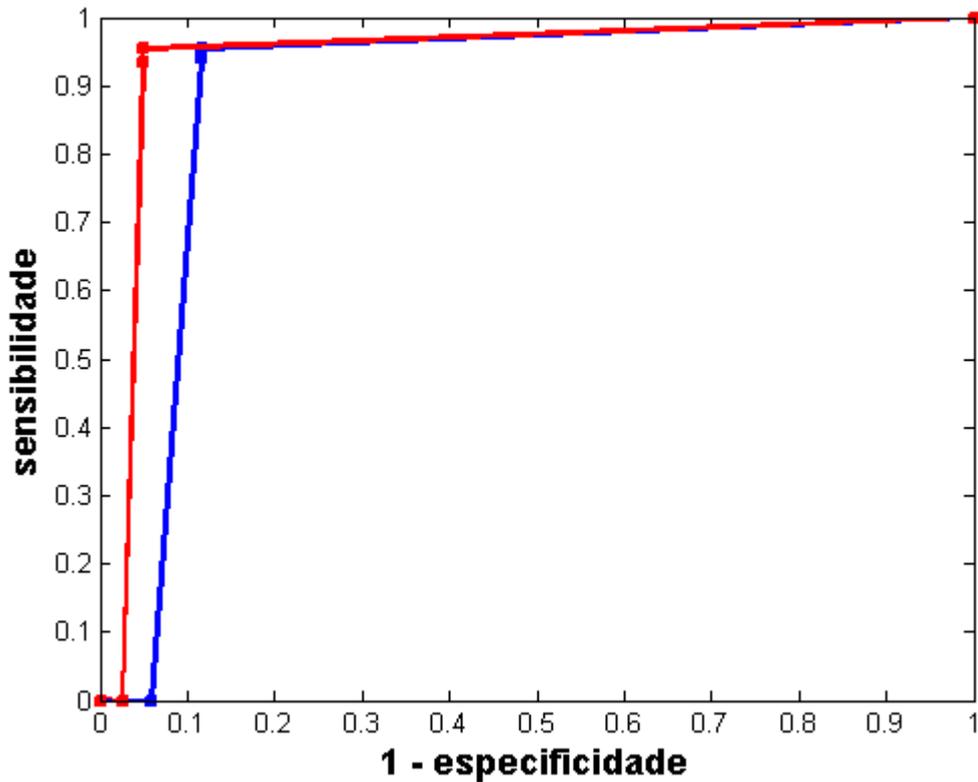


Figura 15: Curva ROC para o *leave-one-out*. A cor vermelha mostra a curva ROC do LVQ e a cor azul mostra a curva ROC do SOM.

SOM		LVQ	
s	e	s	e
0,00	0,00	0,00	0,00
0,05	0,00	0,02	0,00
0,11	0,94	0,05	0,93
0,11	0,95	0,05	0,95
1,00	1,00	1,00	1,00

Tabela 16: Valores numéricos dos pontos das curvas ROC do SOM e LVQ para o *leave-one-out*. As curvas ROC finais são mostradas na **Erro! A origem da referência não foi encontrada..** (s) representa a sensibilidade e (e) representa a especificidade.

A partir da Figura 15 e dos pontos listados na Tabela 16 foi calculada a área sob a curva (AUC) para o LVQ e o SOM, apresentando, respectivamente, valor de 0,94 e 0,90. A partir do *leave-one-out*, estes valores mostram que o LVQ é o modelo de RNA com melhor desempenho para a tarefa de classificação de padrões de postura em crianças respiradoras bucais.

Além disto, por meio do *leave-one-out*, foram realizados testes para determinar a quantidade mínima de pacientes capaz de obter generalização ideal do LVQ para o problema de classificação automática da postura em crianças respiradoras bucais. Para isto, foram escolhidos aleatoriamente 10 pacientes e executado o *leave-one-out* somente para estes e foram calculadas a especificidade e sensibilidade média, o desvio-padrão da especificidade e sensibilidade e o erro de quantização. Foi inserido aleatoriamente mais um paciente e repetido o passo listado. Todo o processo foi repetido recorrentemente até os 52 pacientes de BD1. A Figura 16 mostra resultados de oito testes individuais do procedimento listado, sendo (a) o complemento da especificidade, (b) o complemento da sensibilidade, (c) o desvio-padrão da especificidade, (d) o desvio-padrão da sensibilidade e (e) o erro de quantização. Os resultados mostram que a partir da iteração 32 (equivalente a 41 pacientes) há uma oscilação da especificidade abaixo de 0,0091 e sensibilidade abaixo de 0,0084. Assim, é possível afirmar que a partir do 41º paciente, a variação dos valores de especificidade e sensibilidade do LVQ tornaram-se suficientemente pequenos para se considerar tal conjunto de dados significativos para o treinamento do algoritmo.

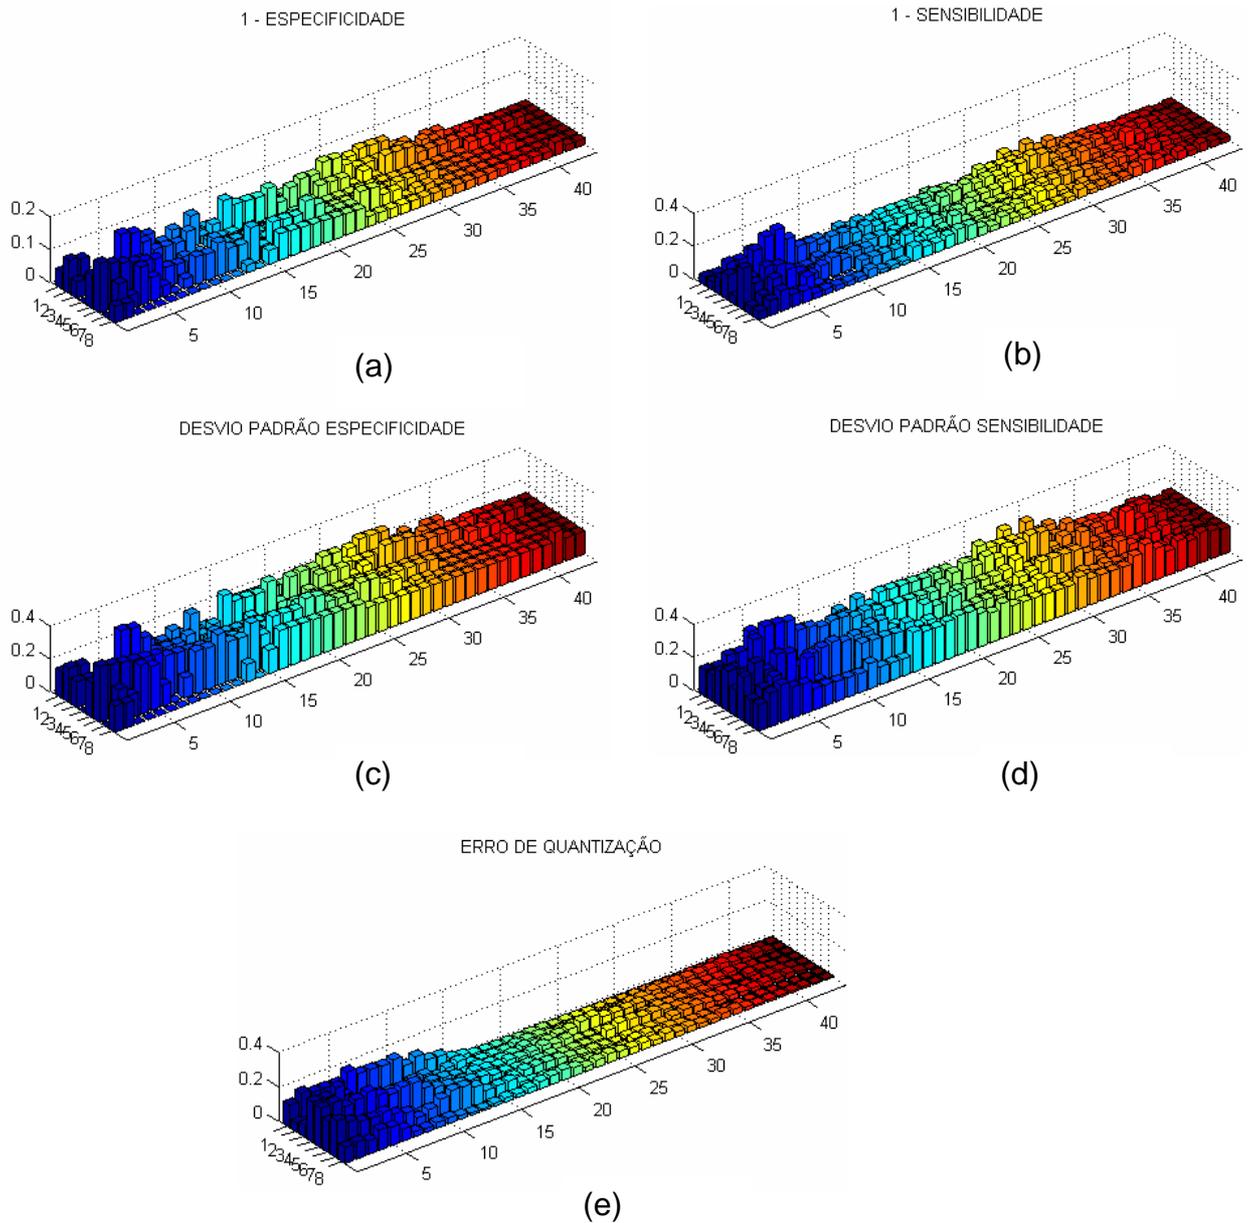


Figura 16: Resultado de 8 testes individuais para análise da generalização do LVQ na classificação automática da postura em crianças respiradoras bucais. Para facilitar a visualização da sensibilidade e especificidade, foram calculados e mostrados seus respectivos complementos. O erro de quantização foi calculado por meio da diferença do erro de quantização dos 52 pacientes treinados (totalidade de pacientes de BD1) com erro de quantização em cada incremento. Dados completos no Anexo 5 (pág. 72).

4.3 Classificação Automática da Postura de Crianças Respiradoras Bucais

Esta seção é dividida em duas partes. Na primeira é realizada a validação do software e determinadas as classes de postura das crianças respiradoras bucais. Na segunda é apresentada a interface do software para classificação da postura de crianças respiradoras bucais e suas principais funcionalidades.

4.3.1 Validação do Software

A fim de iniciar a análise da validação do software é necessário rotular cada neurônio como respirador bucal ou nasal. A Figura 17 mostra o rótulo para cada neurônio.

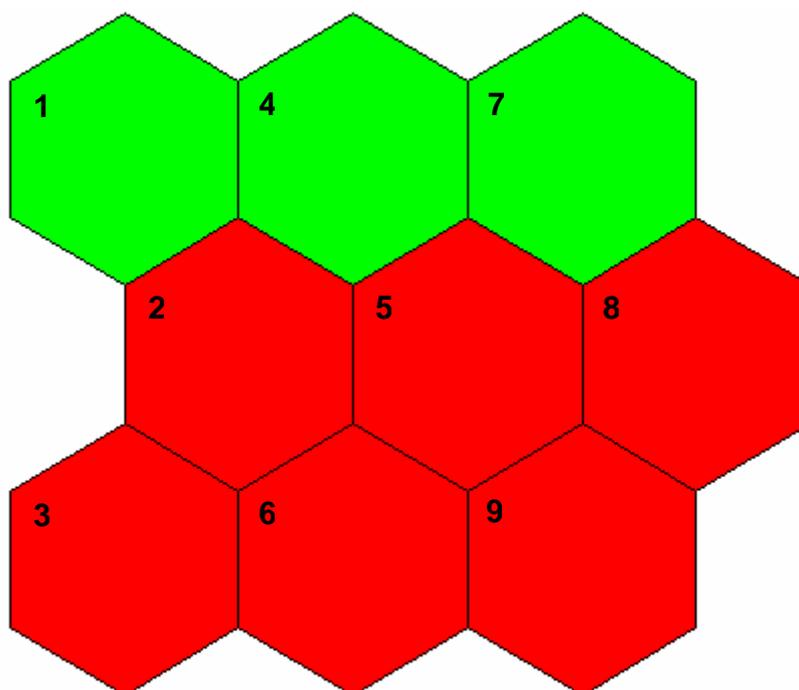


Figura 17: Rótulo para cada neurônio do LVQ. Cada hexágono representa um neurônio e o número de cada neurônio é representado no lado superior esquerdo. Os neurônios em verde (1, 4 e 7) são classificados como respiradores nasais e os neurônios em vermelho (2, 3, 5, 6, 8 e 9) são classificados como respiradoras bucais.

A fim de calcular a especificidade do software foram submetidos para análise os pacientes previamente diagnosticados como respiradores nasais em BD2 (10 pacientes). A Figura 18 mostra que o software classificou de maneira incorreta um paciente no neurônio 2. Desta maneira, a especificidade do sistema, a partir da análise de BD2, é de 0,90.

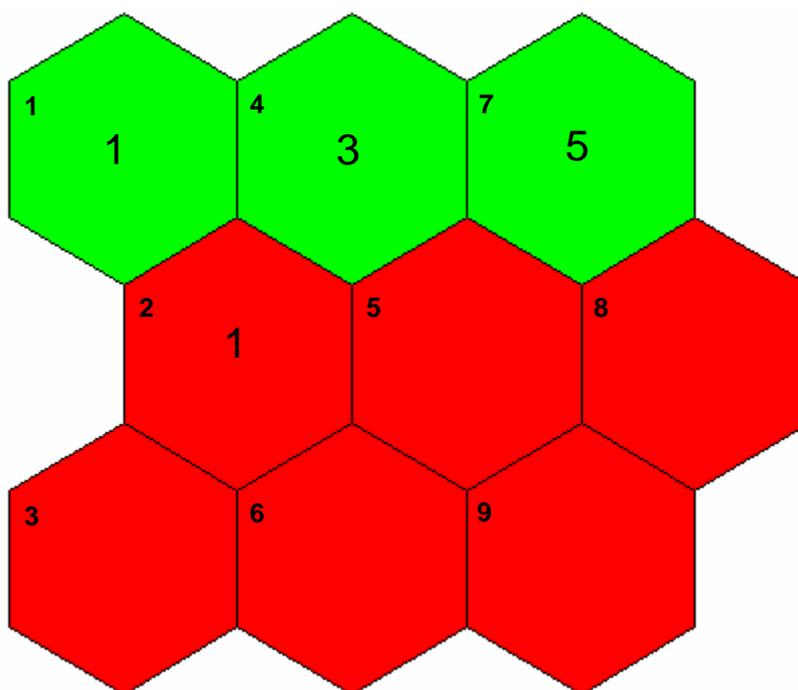


Figura 18: Análise da especificidade do software. Cada hexágono representa um neurônio, o número de cada neurônio é representado no lado superior esquerdo e a quantidade de pacientes classificados em cada neurônio é representada no centro do hexágono.

Com o objetivo de calcular a sensibilidade do software, foram submetidos para análise os pacientes previamente diagnosticados como respiradores bucais em BD2 (22 pacientes). Por meio da Figura 19 é mostrado que o software classificou de maneira incorreta um paciente no neurônio 7. Desta maneira, a sensibilidade do sistema, a partir da análise de BD2, é de 0,95.

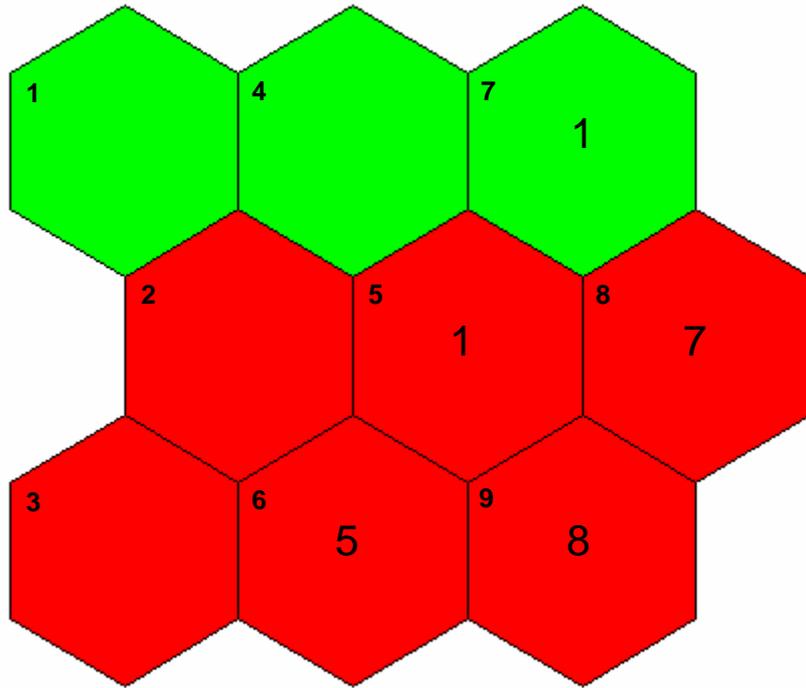


Figura 19: Análise da sensibilidade do software. Cada hexágono representa um neurônio, o número de cada neurônio é representado no lado superior esquerdo e a quantidade de pacientes classificados em cada neurônio é representada no centro do hexágono.

Além disto, conforme informado na seção 3.3 (pág. 16) o especialista emitiu a opinião da necessidade da criança respiradora bucal de realizar intervenção fisioterapêutica. Este parâmetro é utilizado para determinar a classificação da postura de crianças respiradoras bucais no LVQ. Das 22 crianças diagnosticadas como respiradoras bucais, 15 apresentaram necessidade de realizar intervenção fisioterapêutica e 7 não apresentaram essa necessidade. A Figura 20 mostra distribuição dos pacientes, a partir da análise do LVQ, que necessitam e não necessitam realizar intervenção fisioterapêutica em cada mapa.

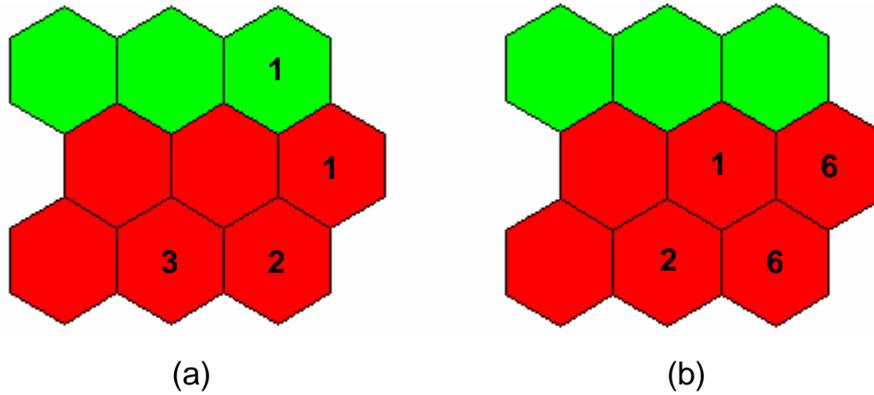


Figura 20: Distribuição dos pacientes, a partir da análise do LVQ, que não necessitam realizar intervenção fisioterapêutica (a) e necessitam realizar intervenção fisioterapêutica (b).

A fim de realizar a classificação da postura de crianças respiradoras bucais a partir dos agrupamentos gerados pelo LVQ utilizando como padrão de entrada PE3, foi realizada uma subtração de cada neurônio do mapa (a) da Figura 20 pelo mapa (b) da mesma figura. A resposta deste cálculo é mostrada pela Figura 21.

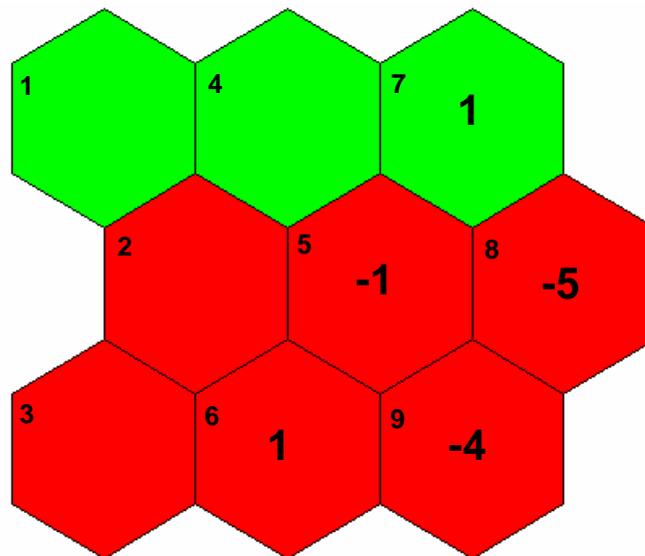


Figura 21: Subtração de cada neurônio do mapa (a) da Figura 20 pelo mapa (b) da mesma figura. Em cada neurônio está indicado o valor deste cálculo. Caso o neurônio possua um valor negativo, encontra-se nessa região maior número de pacientes com necessidade de realizar intervenção fisioterapêutica. Caso o neurônio esteja com o valor positivo, encontra-se nessa região maior número de pacientes sem necessidade de realizar intervenção fisioterapêutica.

A partir da Figura 21 é possível classificar os seguintes perfis posturais de crianças respiradoras bucais e nasais:

- Perfil A: os pacientes agrupados nos neurônios 8 e 9 da Figura 21 são pacientes respiradores bucais com alterações severas da postura (necessitam realizar intervenção fisioterapêutica), pois estes possuem o valor negativo em seus neurônios; os pacientes pertencentes a estes neurônios são identificados como perfil A;
- Perfil B: os pacientes agrupados nos neurônios 5 e 6 são pacientes respiradores bucais com alterações moderadas da postura, pois os números são próximos a zero; os pacientes pertencentes a estes neurônios são identificados como perfil B;
- Perfil C: os pacientes agrupados nos neurônios 2 e 3 são pacientes respiradores bucais com alterações leves da postura (não necessitam realizar intervenção fisioterapêutica); os pacientes pertencentes a estes neurônios são identificados como perfil C;
- Perfil D: os pacientes pertencentes ao neurônio 7 são respiradores bucais com alterações leves da postura e estão identificados como perfil D – esta escolha ocorreu pelo paciente respirador nasal que foi agrupado neste neurônio;
- Perfil E: os pacientes pertencentes ao neurônio 1 e 4 são pacientes respiradores nasais com alterações leves da postura e são identificados como perfil E.

4.3.2 Software para Classificação Automática da Postura de Crianças Respiradoras Bucalis

A Figura 22 mostra a interface gráfica do software para classificação automática da postura em crianças respiradoras bucais após a sua abertura. Este software possui apenas uma tela. No lado esquerdo, o médico ou o profissional da área de saúde cadastra o nome do paciente, seguido dos dados da avaliação postural (Lordose Cervical, Lordose Lombar, Cifose Torácica, Posição da Pelve). Após cadastrar o paciente, estes dados são armazenados no banco de dados Microsoft Access e estão prontos para serem classificados.

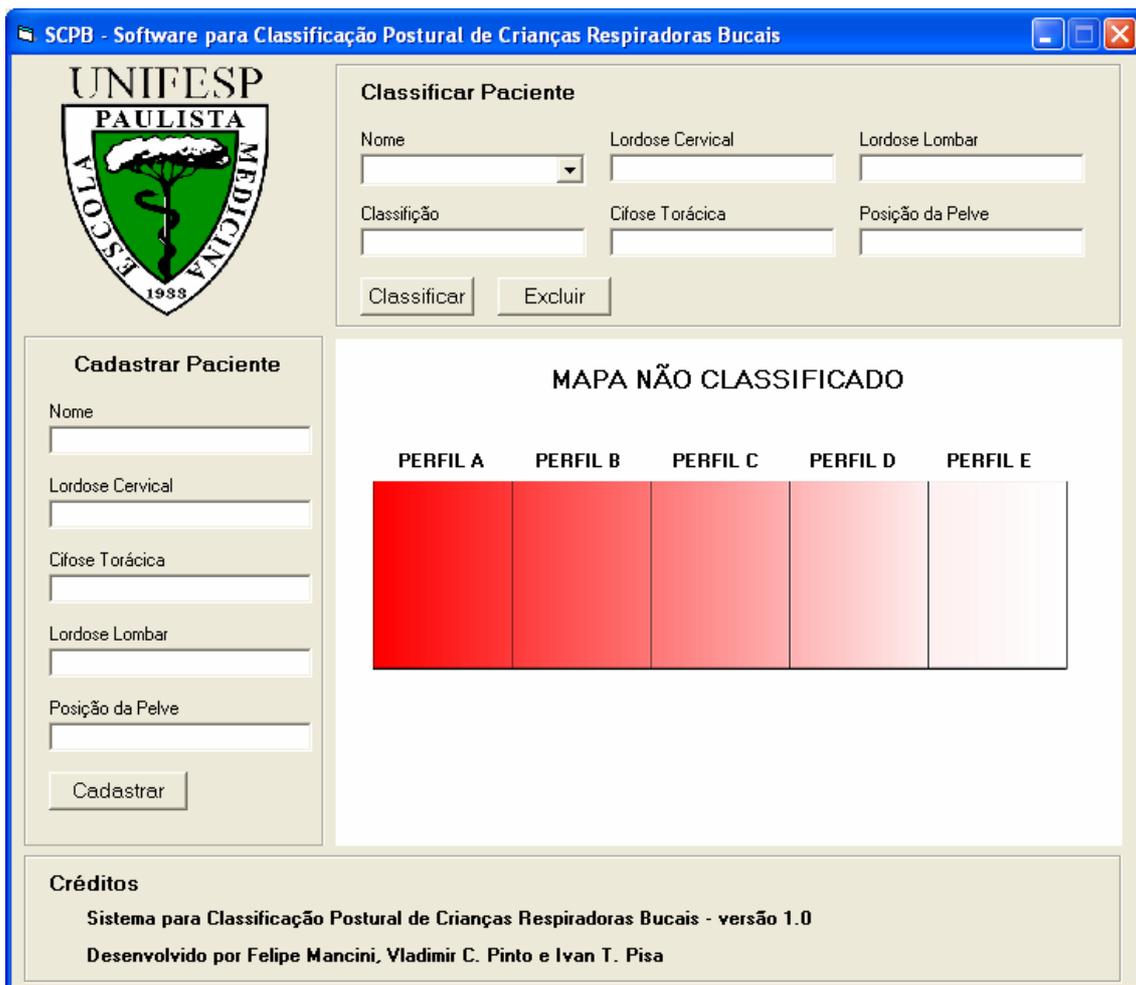


Figura 22: Tela do software construído para classificação automática da postura. O PERFIL A representa criança com perfil postural de respiradora bucal com alterações severas da postura; o PERFIL B representa criança com perfil postural de respiradora bucal com alterações moderadas da postura; o PERFIL C representa criança com perfil postural de respiradora bucal com alterações leves da postura; o PERFIL C e D representam criança com perfil postural de respiradora nasal com alterações leves da postura.

O usuário seleciona o nome do paciente na parte superior direita da tela e o mesmo é classificado por meio da biblioteca DLL gerada a partir do Matlab e o SOM Toolbox. A classificação do paciente também é gravada. A partir da bola preta representada na Figura 23 é possível identificar o paciente classificado.

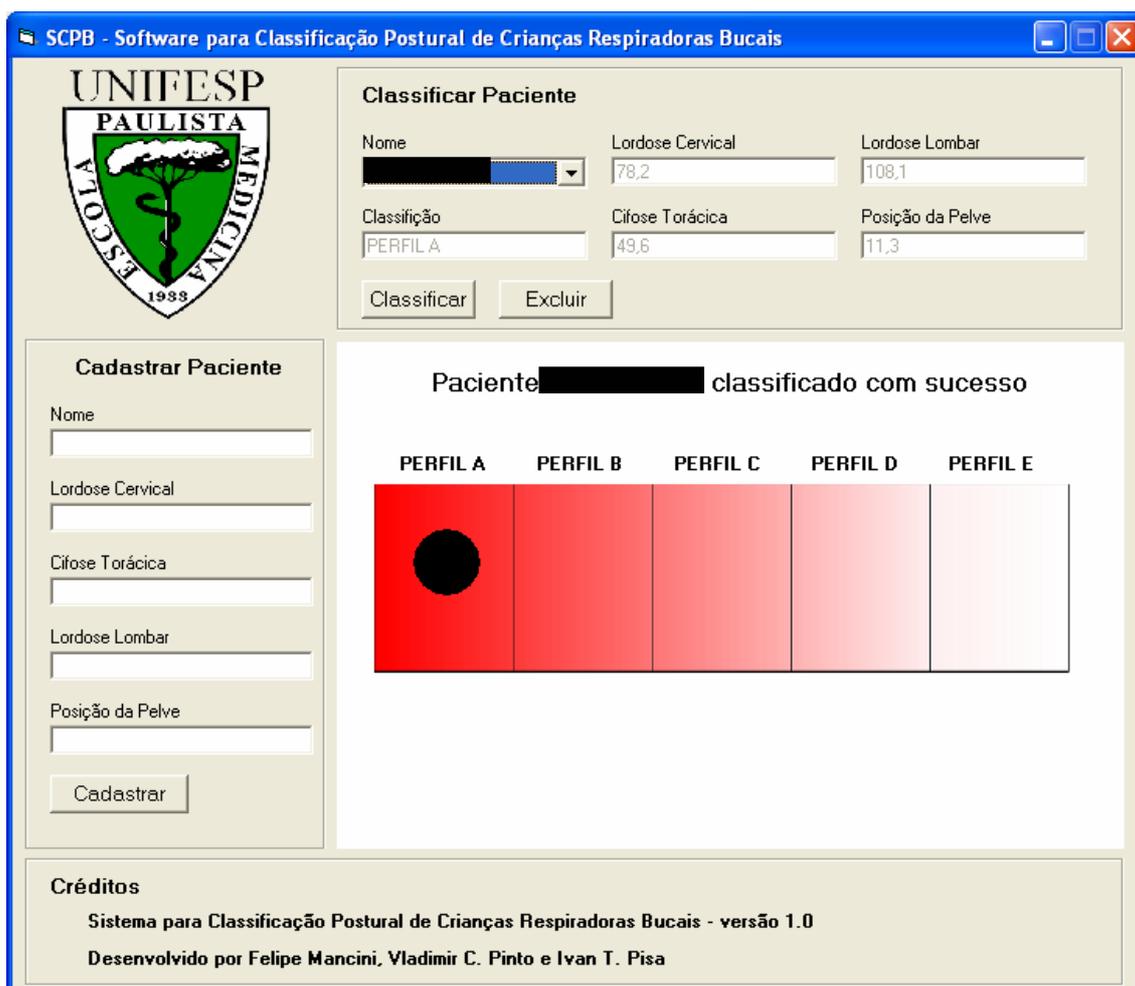


Figura 23: Paciente classificado no software para classificação postural de crianças respiradoras bucais. Neste caso, a criança foi classificada com o PERFIL A.

5 Discussão

A discussão sobre os resultados deste trabalho está dividida nas seções a seguir.

5.1 SOM Aplicado na Determinação do Perfil Postural de Crianças Respiradoras Bucais

A Revista Científica Neural Networks editada pela Sociedade Européia de Rede Neural (European Neural Network Society - ENNS), Sociedade Japonesa de Rede Neural (Japanese Neural Network Society - JNNS) e Sociedade Internacional de Rede Neural (International Neural Network Society - INNS) em seu Volume 19 (ano 2006) dedicou as edições 6 e 7 para discutir os avanços do SOM. Na edição 6, Cottrell & Verleysen (2006) citam que mais de 5000 diferentes publicações utilizaram o SOM como modelo de RNA aplicado na solução de problemas reais, e que outros trabalhos propuseram modificações no algoritmo original do SOM. Além disto, diferentes ferramentas como o SOM Toolbox (Vesanto, 2000) e o SOM Pak (http://www.cis.hut.fi/research/som_pak) foram desenvolvidas a fim de auxiliar a implementação computacional do SOM.

Todo este esforço auxiliou diretamente no entendimento das propriedades dos mapas de características e conseqüentemente na completude da aplicação prática do SOM no estudo exploratório de dados biomédicos. Este aspecto pode ser exemplificado a partir de trabalhos (Schonweiler et al., 1996; Pardey et al., 1996; He et al., 1997) que possuem mais de 10 anos de publicação e não aplicaram todas as propriedades dos mapas de características e apresentaram resultados incompletos. Trabalhos recentes (Barton, 2006; Grossi, 2005) aplicaram todas as propriedades do SOM para inspeção de dados biomédicos, apresentando resultados significativos.

De maneira geral, o processo de extração de características de um determinado repositório de dados biomédicos pode ser representado em duas fases:

- Na primeira fase, a partir do espaço de saída discreto gerado como resposta do SOM é possível em um primeiro momento verificar a redução de dimensionalidade de um padrão de entrada n-dimensional em um espaço bidimensional. Esta etapa baseia-se na propriedade 1 dos mapas de características. Por meio desta redução de dimensionalidade pode-se verificar a existência de agrupamentos característicos do espaço de entrada de dados pelo mapa de saída bidimensional;
- A segunda fase consiste em determinar quais são os atributos do conjunto de entrada mais característicos para cada neurônio artificial. Pode-se dizer que esta é a etapa da extração de características propriamente dita. Porém, no SOM, além de rotular cada neurônio artificial com atributos que caracterizam o padrão de entrada, também é possível determinar classes. Esta tarefa baseia-se nas propriedades 2 e 3 dos mapas de características, nos quais se definem agrupamentos a partir das similaridades estatisticamente mais importantes do padrão de entrada.

Este trabalho aplicou todas as propriedades do mapa de características, pois além de realizar a redução de dimensionalidade, foi possível determinar classes a partir dos agrupamentos gerados pelo SOM e compreender o perfil postural das crianças respiradoras bucais. Segundo o especialista, os pacientes agrupados nas classes das crianças respiradoras típicas possuem as seguintes características:

- Na classe 1 do respirador bucal típico encontramos a lordose cervical semelhante do grupo controle ou respirador nasal, associada a uma distância média de excursão do diafragma muito baixo. Godfrey et al. (1972) avaliaram a mobilidade tóraco-abdominal em indivíduos com e sem aumento de resistência das vias aéreas, através da plestimografia na qual eletrodos foram acoplados no tórax e concomitantemente foi realizada a espirometria. Foi constatado que o aumento da resistência de vias aéreas altera a expansibilidade ântero-posterior e látero-lateral do tórax e sugerem haver comprometimento na descida do músculo diafragma. A menor distância excursionada pelo diafragma no grupo respi-

rador bucal sugere uma menor quantidade de entrada de volume na corrente pulmonar pelo aumento da resistência nasal;

- Na classe 2 do respirador bucal típico encontramos uma lordose cervical muito diminuída se comparada com a média do grupo controle ou respirador nasal, associada à média da distância da excursão do diafragma maior que no subgrupo 1. Ribeiro et al. (2003) realizaram registros eletromiográficos nos músculos esternocleidomastoideo e trapézio superior em crianças respiradoras bucais. Observaram maior atividade elétrica destes músculos ao ser comparado com o grupo dos respiradores nasais, concluindo que a obstrução nasal leva a um maior esforço inspiratório, devido ao aumento da resistência nasal e à adequação da posição de cabeça e pescoço. Sugere-se assim que quando há uma obstrução nasal, ocorre uma anteriorização da posição da cabeça e perda da lordose cervical para ampliar o espaço aéreo. Ocorre um maior esforço dos músculos acessórios da inspiração e do diafragma na tentativa de suprimir esta demanda.

Além disto, foi verificado que os pacientes agrupados na classe 1, genericamente, apresentam diferentes características etiológicas se comparado aos pacientes agrupados na classe 2. Por meio da Tabela 10 (pág. 37) pode-se verificar que para a classe respirador bucal 1 encontra-se maior número de pacientes com GIII-IV, enquanto para a classe respirador bucal 2 encontra-se maior número de pacientes com GII e rinite alérgica. Devido a estas características, o especialista constatou que:

- Para a classe respirador bucal 1 a etiologia ocorre por fatores obstrutivos que permanecem até a retirada cirúrgica, levando à cronicidade da alteração respiratória e desencadeando a reação de compensações posturais, acometendo-se a efetividade da excursão do músculo diafragma. Como a manifestação é crônica devido à teoria das compensações em cadeias musculares, ocorre o comprometimento da pelve para melhor posicionamento da postura corporal;
- A rinite alérgica é sazonal e a sintomatologia aparece por fatores irritativos da mucosa nasal, desaparecendo quando o indivíduo não está mais

exposto aos fatores irritativos ou com o uso de medicamento. Dessa forma, não há manifestações permanentes desta sintomatologia e não ocorrem grandes alterações na mecânica da excursão do músculo diafragma. O aumento da lordose cervical ocorre para promover melhor posicionamento e para facilitar a entrada do fluxo aéreo para as vias respiratórias.

Quanto ao padrão de entrada utilizado para realizar a extração de características de BD1, podemos verificar a partir da Tabela 15 (pág. 43) que o valor PE1 apresentou maiores valores de sensibilidade e especificidade para BP, SOM e *perceptron*. Desta maneira, os valores do t de *Student* (Tabela 8, pág. 33) são concordantes com os valores de sensibilidade e especificidade na classificação de respiradores bucais, pois PE1 foi adotado como padrão de entrada para o estudo exploratório da postura em crianças respiradoras bucais.

5.2 Seleção de Modelo

A partir da Tabela 11 (pág. 38), pode-se mostrar que o algoritmo *5-fold* apresentou diferentes valores de sensibilidade e especificidade para diferentes conjuntos de testes realizados. Sendo assim, este algoritmo não foi utilizado para determinar o modelo de RNA aplicado na classificação automática da postura de crianças respiradoras bucais.

Estes diferentes valores obtidos pelo *5-fold* foram retirados a partir do *3-fold* estendido proposto neste trabalho. A curva ROC do *3-fold* adaptado, apresentada pela Figura 14 (pág. 42), mostra que o SOM é o algoritmo indicado para o problema analisado neste trabalho. Porém, devido à proximidade do valor da área do quadrante superior esquerdo da curva ROC (0,91 para o LVQ e 0,92 para o SOM), os resultados do LVQ não devem ser desprezados.

Foi utilizado o algoritmo do *leave-one-out* para auxiliar na determinação do modelo de RNA para a classificação automática da postura de crianças respiradoras bucais. A adoção de três algoritmos para seleção de modelo ocorreu pela característica do pequeno conjunto de dados utilizados neste trabalho. Segundo Kovaki (1995) e Haykin (1999), o *leave-one-out* é melhor aplicado

quando o repositório apresenta esta mesma característica (pequeno conjunto de dados). Este estudo reitera essa característica, principalmente pela propriedade do *leave-one-out* em realizar a validação com um paciente, sendo possível obter uma maior aproximação no treinamento do modelo final da RNA.

Por meio da curva ROC do *leave-one-out* apresentada na Figura 15 (pág. 44), o LVQ foi escolhido como o modelo de RNA indicado para a classificação automática da postura de crianças respiradoras bucais. Este resultado contradiz, de certa maneira, o resultado obtido pelo *3-fold* estendido. Isto ocorreu, devido à característica do *3-fold* em realizar o treinamento da RNA com 2/3 dos pacientes. Conforme informado acima, como o *leave-one-out* aproxima o treinamento/validação da RNA ao modelo final adotado, foi escolhido o LVQ como modelo de RNA para análise do problema abordado neste trabalho.

Além disso, foi analisada a quantidade mínima de pacientes capaz de obter generalização no treinamento da RNA. Por meio da Figura 16 (pág. 46) é possível verificar que, aproximadamente, a partir da recorrência 40 (50 pacientes analisados), ocorre estabilidade da especificidade, sensibilidade bem como seus respectivos desvios-padrão. Desta maneira, treinar o LVQ com os 52 pacientes representa a melhor generalização na classificação automática da postura em crianças respiradoras bucais para BD1. O erro de quantização, também representado na Figura 16 (e) (pág. 46), não apresentou resultado satisfatório para esta análise. Isto ocorreu, pois a partir da iteração 15 houve estabilização do erro de quantização, porém a especificidade e sensibilidade bem como seus desvios-padrão não se estabilizaram.

Pesonen et al. (1996), Markeya et al. (2003) e Ng & Chong (2006) comparam o desempenho do SOM e BP para diferentes problemas de classificação de padrões de dados biomédicos. Em todos os trabalhos, BP apresentou maiores valores de sensibilidade e especificidade, se comparado ao SOM. Conforme informado na seção 3.4 (pág. 17), apesar do SOM poder ser aplicado para a tarefa de classificação de padrões, este modelo de RNA possui paradigma de treinamento não supervisionado e sua aplicação é indicada para a tarefa de extração de características (Hudson, 2000). Este trabalho também verificou que o SOM apresenta limitações na classificação de padrões, principalmente por

apresentar baixos valores de sensibilidade. Este fato também é verificado por Pesonen (1996).

Pesonen et al. (1996) e Dieterle et al. (2003) também compararam o desempenho do LVQ e BP para diferentes problemas de classificação de padrões de dados biomédicos. Em ambos os trabalhos, LVQ e BP apresentaram valores similares de sensibilidade e especificidade. Especificamente neste trabalho, LVQ apresentou maior taxa de acertos para PE3 (0,98 para sensibilidade e 0,97 para especificidade no diagnóstico de crianças respiradoras bucais utilizando o conjunto de dados de treinamento, e valores de 0,95 para sensibilidade e 0,90 para especificidade utilizando o conjunto de dados de validação) se comparado ao BP (Tabela 15, pág. 43). Este fato pode estar ligado ao pequeno conjunto de dados utilizados para treinamento, pois Pesonen (1996) utilizou 991 pacientes para treinamento e Dieterle (2003) utilizou 206 pacientes para treinamento.

Por meio da Tabela 15 (pág. 43) pode-se verificar que o *perceptron* apresentou, em conjunto, menores valores de sensibilidade (0,98) e especificidade (0,73) para qualquer PE3, se comparado a outros modelos de RNA. Desta maneira, a aplicação de método linear de reconhecimento de padrões não é a melhor solução adotada para classificar padrões posturais de crianças respiradoras bucais.

Além de apresentar maiores valores de sensibilidade (0,98) e especificidade (0,97), outro lado positivo da aplicação do LVQ na classificação de dados biomédicos é seu melhor desempenho de tempo (262 segundos) dentre os algoritmos de aprendizagem supervisionada (Tabela 12, pág. 39).

Além disso, diferentemente do BP e o *perceptron*, no LVQ é possível visualizar a vizinhança de cada neurônio e assim permitir a extração de características do padrão de entrada por meio de um modelo de RNA de aprendizagem supervisionada, possibilitando melhor compreensão na classificação dos dados, podendo até mesmo gerar novas categorias. Isto pode ser verificado neste trabalho por meio do apontamento de classes de postura de crianças respiradoras bucais após o mapa treinado com PE3 e o diagnóstico de respiração bucal (Figura 23, pág. 53).

5.3 Software para Classificação de Padrões Posturais de Crianças Respiradoras Bucais

Na seção 4.3 (pág. 47) foram calculados a especificidade (0,90) e sensibilidade (0,95) do software para classificação de padrões posturais de crianças respiradoras bucais. Porém, como o foco desta é classificar a postura de crianças respiradoras bucais, algumas observações devem ser realizadas:

- Na Figura 19 (pág. 49) há um paciente diagnosticado como respirador bucal e classificado pelo LVQ como respirador nasal. Especificamente, este paciente não necessita realizar avaliação postural, segundo opinião do especialista (vide Figura 20, pág. 50).
- Na Figura 18 (pág. 48) há um paciente diagnosticado como respirador nasal, porém foi classificado pelo modelo de RNA como respirador bucal. A partir da classificação dos agrupamentos do LVQ, este paciente foi classificado sem necessidade de realizar avaliação postural (classe C).

A partir destas observações, pode-se entender que o software, apesar de errar o diagnóstico destes dois pacientes, acertou o perfil postural, consequentemente, sugerindo o correto encaminhamento ao profissional da saúde.

Uma limitação da versão atual deste software é sua impossibilidade de realizar auto-treinamento a partir de um paciente classificado e validado pelo profissional da área da saúde. Este fato decorre da característica do LVQ em alterar a topologia do mapa quando um novo paciente é inserido em sua base de treinamento, necessitando de uma nova análise e estabelecimento de novos agrupamentos.

6 Conclusão

Por meio do SOM foi possível apontar 4 classes de perfil postural de crianças respiradoras bucais e nasais. Assim, foi possível mostrar que estas são decorrentes de combinações etiológicas específicas.

No desenvolvimento do software classificador de perfil postural de crianças respiradoras bucais, o LVQ apresentou melhor desempenho no diagnóstico de respirador bucal utilizando a base de dados de treinamento (BD1) – 0,98 de especificidade e 0,97 de sensibilidade. Utilizando a base de dados de validação (BD2), o LVQ apresentou sensibilidade 0,95 e especificidade 0,90 no diagnóstico de crianças respiradoras bucais. Porém, como o foco do software é classificar o perfil postural de crianças, este classificou corretamente (100% de acerto) o perfil postural das crianças respiradoras bucais da base de dados utilizada, de acordo com uma escala de gravidade arbitrária.

7 Trabalhos Futuros

Diversos trabalhos encontrados na literatura determinaram alterações no algoritmo do SOM utilizado nessa pesquisa. Uma proposta para um futuro trabalho é aplicar algumas das modificações do algoritmo do SOM, como apresentado por Kohonen (2006), Sullivan & Sa (2006), Hulle (2006), Ontrup & Ritter (2006), Cottrell et al. (2006), Villmann et al. (2006), Hujun (2006) e Barreto & Souza (2006) para o problema de classificação da postura de crianças respiradoras bucais, e comparar resultados obtidos.

Outro trabalho importante a ser realizado é verificar a evolução temporal da postura de crianças respiradoras bucais a partir de intervenções executadas por fisioterapeutas. A partir deste estudo possivelmente seria mostrado se estas intervenções estão direcionando a postura de crianças respiradoras bucais para um perfil postural considerado “ideal”.

Aplicar outros modelos de RNA como a função de base radial (RBF, *radial-basis function*) (Haykin, 1999) e máquinas de vetor de suporte (MVS, *support vector machines*) (Haykin, 1999) na classificação da postura em crianças respiradoras bucais e comparar resultados com os obtidos neste trabalho também seriam estudos interessantes a serem realizados.

A utilização de outra base de dados, contendo um número maior de pacientes analisados, pode também ser aplicada em um estudo futuro.

8 Referências

- Akay M, Nonlinear Biomedical Signal Processing. Vol. I: Fuzzy Logic, Neural Networks and New Algorithms. Vol. II: Dynamic Analysis and Modeling, 2000.
- Anderson JA & Sutton JP. A Network of Networks: Computation and Neurobiology, World Congress on Neural Networks, 1995, 1, 561-568.
- Aragão W. Respirador bucal. J Ped 1988; 64(8): 349-352.
- Aragão W. Arago's function regulator, the stomatognathic system. J Clin Ped Dent 1991; 15(4):226-231.
- Barreto GA, Souza LGM. Adaptive filtering with the self-organizing map: A performance comparison. Neural Netw, 2006, 19(6-7): 785-98.
- Barton G, Lees A, Lisboa P, Attfield S. Visualization of gait data with Kohonen self-organizing neural maps. Gait Posture 2006; 24(1): 46-53.
- Benatti AT. Equilíbrio tóraco-abdominal integrado à respiração e à postura. Arq Ciênc Saúde Unipar 2001; 5(1):87-92.
- Bishop CM, Pattern Recognition and Machine Learning, New York: Springer; 2006.
- Burnham KP, Anderson D. Model Selection and Multi-Model Inference. Berlin: Springer; 2004.
- Carvalho GD. Síndrome do respirador bucal ou insuficiente respirador nasal. Rev Secret Saúde 1996; 2(18):22-24.
- Castellani B, Castellani J, Data mining: Qualitative Analysis with Health Informatics Data. Qual Health Res, 2003; 13:1005-1018.
- Cottrell M, Verleysen M, Advances in Self-Organizing Map. Neural Netw, 2006, 19(6-7): 721-22.
- Cottrell M, Hammer B, Hasenfuß A, Villmann T. Batch and median neural gas. Neural Netw, 2006, 19(6-7): 762-71.
- Cross SS, Harrison RF, Kennedy R, Introduction to Neural Networks, Lancet, 1995; 346:1075-79.
- Dieterle F, Muller-Hagedorn S, Liebich HM, Gauglitz G. Urinary nucleosides as potential tumor markers evaluated by learning vector quantization. Artif Intell Med, 2003 Jul; 28(3): 265-79.

- Duarte M. Software para Avaliação Postural (SAPO), Brasil: Universidade de São Paulo; 2006.
- Duda RO, Hart, P.E., Stork, D.G. Pattern Classification. 2nd Edition. New York, Wiley-Interscience, 2000.
- Fukunaga K, Stastical Pattern Recognition, New York: Academic Press; 1990.
- Gersho A, Gray R, M. Vector Quantization and Signal Compression, Norwell: Kluwer; 1992.
- Godfrey S, Leventhal A, Weintraub Z, Katzenelson R, Connolly NM. Distortion of chest movement by increased airways resistance. *Thorax*, 1972; 27:148-155.
- Grossi E, Massini G, Buscema M, Savare R, Maurelli G. Two Different Alzheimer Diseases in man and woman: clues from advanced neural networks and artificial intelligence. *Gend Med* 2005; 2(2): 106-117.
- Guyton AC. Tratado de fisiologia médica. 8ªed. Rio de Janeiro: Guanabara Koogan, 1992.
- Hagan MT, & Menhaj, M, Training feedforward networks with the Marquardt algorithm, *IEEE Transactions on Neural Networks*, 1994, 5(6): 989-993.
- Haykin S, *Neural Networks: a Comprehensive Foundation*. 2nd edition. New Jersey, Prentice-Hall, 1999.
- He H, Wang J, Graco W, Hawkins S. Application of Neural Networks to Detection of Medical Fraud, *Expert Systems With Applications*, 1997, 13: 329-336.
- Hilton GE. Connectionist learning procedures, *Artif Intell*, 1989, 40: 185-34.
- Hruska RJ. Influences of dysfunctional respiratory mechanics on orofacial pain. *Dent Clin North Am* 1997;41: 211-7.
- Hungria H. *Otorrinolaringologia*. São Paulo: Guanabara Koogan; 1995.
- Hudson DL, Cohen ME. *Neural Networks and Artificial Intelligence for Biomedical Engineering*, New Jersey: IEEE Press; 2000.
- Hujun Y. On the equivalence between kernel self-organizing maps and self-organizing mixture density networks. *Neural Netw*, 2006, 19(6-7): 780-84.
- Hulle MMV. Topographic map formation of factorized Edgeworth-expanded kernels. *Neural Netw*, 2006, 19(6-7): 744-50.

- Jardim JRB. Fisiologia do sistema respiratório. In: Hirschheimer MR, Matsumoto T, Carvalho W. Terapia intensiva pediátrica. São Paulo: Atheneu, 1989.
- Kohonen T. Self-Organizing Maps, Berlim: Springer-Verlag, 1997.
- Kohonen T. Self-organizing neural projections, Neural Netw, 2006, 19(6-7): 723-33.
- Kovaki R, A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. Proceedings of the International Joint Conference on Artificial Intelligence, 1995.
- Krakauer LRH, Relação entre respiração bucal e alterações posturais em crianças: uma análise descritiva. São Paulo, 1997. Tese de Mestrado. Pontifícia Universidade Católica de São Paulo.
- Lisboa PJG, Ifeachor EC, Szczepaniak OS, (Eds). Artificial Neural Networks in Biomedicine. Berlin , Springer, 2000.
- Lisboa PJG, A Review of Evidence of Health Benefit from Artificial Neural Networks in Medical Intervention, Neural Netw, 2002, 15:11-39.
- Liu CY, Estudo da relação entre a excursão do músculo diafragma e o comportamento das curvaturas da coluna vertebral em crianças respiradoras bucais e nasais. Tese de Doutorado. Universidade Federal de São Paulo, 2006.
- Liu CY, Guedes ZCF, Vieira MM. Relação da postura corporal com a disfunção da articulação temporomandibular: hiperatividade dos músculos da mastigação. Fisioter Brasil 2003; 4(5): 341-347.
- Lusvarghi L. Identificando o respirador bucal. Revista da APCD 1999; 53(4): 265-274.
- Markeya MK, Lo JY, Tourassib GD, Floyd CE, Self-organizing map for cluster analysis of a breast cancer database, Artif Intell Med, 2003, 27, 113–127.
- Martucci RC, Lopes MJ, Jardim JRB. Estudo da configuração tóraco-abdominal em indivíduos normais nas posições sentada e supina respirando livremente e através de resistência linear. J Pneumol 1992; 18(3): 93-100.
- Massad E, Menezes RX, Silveira PSP, Ortega NRS, Métodos Quantitativos em Medicina, São Paulo: Manole, 2004.
- Metz CE. Basic principles of ROC analysis. Seminars in Nucl Med 1978; 8:283-98.

- Ng EY & Chong C. ANN-based mapping of febrile subjects in mass thermogram screening: facts and myths. *J Med Eng Technol*. 2006; 30(5):330-7.
- Ontrup J & Ritter H. Large-scale data exploration with the hierarchically growing hyperbolic SOM. *Neural Netw*, 2006, 19(6-7): 751-61.
- Pardey J, Roberts S, Tarassenko L, Stradling L. A new approach to the analysis of the human sleep/wakefulness continuum, *J Sleep Res*; 1996, 5: 201-210.
- Pesonen E, Matti E, Juhola M, Comparasion of Different Neural Network Algorithms in the Diagnosis of Acute Appendicitis. *Int J Biomed Comput*. 1996; 40:227-233.
- Pizarro GU. Análise videofluoroscópica das fases oral e faríngea da deglutição em crianças respiradoras bucais com apnéia do sono. Tese de Mestrado. Universidade Federal de São Paulo, 2003.
- Principe JC, Euliano NR, Lefebvre WC, *Neural and Adaptive Systems*. New York, Wiley, 2000.
- Reggia JA, *Neural Computation in Medicine*. *Artif Intell Med*, 1993, 5, 143-157.
- Ribeiro EC, Soares LM, Avaliação espirométrica de crianças portadoras de respiração bucal antes e após intervenção fisioterapêutica. *Fisioter Bras* 2003; 4:163-167.
- Ribeiro EC, Marchiori SC, Silva AMT. Electromyographic analysis of trapezius and sternocleidomastoideus muscles during nasal and oral inspiration in nasal and mouth breathing children. *J Electromyogr Kinesiol* 2002;12: 305-16.
- Rocabado M, *Cabeza Y cuello – tratamiento articular*. Buenos Aires: Intermédica; 1979.
- Rodrigues EC, Bérzin F. Temporomandibular disorder and dysfunctional breathing. *Braz J Oral Sci* 2004;3(10):498-502.
- Roque AC. Notas de Aula da Disciplina de Redes Neurais Artificiais, Disponível em <http://neuron.ffclrp.usp.br/2004-I-RN-roteiro.php>. Acesso em 12 de maio 2007.
- Schinestsck PA. A relação entre a má oclusão dentária, respiração bucal e as deformidades esqueléticas. *J Bras Ortod Ortop Max* 1986; 3(4): 45.
- Schonweiler R, Kaese S, Moller S, Rinscheid A, Ptok M. Neuronal networks and self-organizing maps: new computer techniques in the acoustic evaluation of the infant cry, *Int J Pediatr Otorhinolaryngol*, 1996, 38: 1-11.

Shortliffe EH, Barnett GO, Medical Data: Their Acquisition, Storage, and Use. In: Shortliffe, E.H., Perreault, L.E. (Eds.), Medical Informatics: Computer Applications in Health Care and Biomedicine, 2nd edition, pp. 41-75, New York , USA, Springer-Verlag, 2001, pp. 41-75.

Sullivan TJ & Sa VR. Homeostatic synaptic scaling in self-organizing maps. Neural Netw, 2006, Neural Netw, 2006, 19(6-7): 734-43.

Vesanto J, Himberg J, Alhoniemi E, Parhankangas J. SOM 2.0 Toolbox para Matlab 5. Espoo: Universidade de Tecnologia de Helsink; 2000.

Villmann Th, Neural maps for faithful data modelling in medicine - state-of-the-art and exemplary applications, Neurocomputing 2002; 48: 229-250.

Villmann Th, Hammer B, Schleif F, Geweniger T, Herrmann W. Fuzzy classification by fuzzy labeled neural gas. Neural Netw, 2006, 19(6-7): 772-79.

Anexo 1 – Parecer do Comitê de Ética em Pesquisa

	<p>Universidade Federal de São Paulo Escola Paulista de Medicina</p>	<p>Comitê de Ética em Pesquisa Hospital São Paulo</p>
-----------------------------------------------------------------------------------	--------------------------------------------------------------------------	-----------------------------------------------------------

São Paulo, 16 de setembro de 2005.
CEP 0997/05

Ilmo(a). Sr(a).
Pesquisador(a) FELIPE MANCINI
Co-Investigadores: Antonio Carlos Roque da Silva Filho, Ivan Torres Pisa
Disciplina/Departamento: Informática em Saúde - DIS da Universidade Federal de São Paulo/Hospital São Paulo
Patrocinador: Recursos Próprios.

PARECER DO COMITÊ DE ÉTICA INSTITUCIONAL

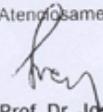
Ref: Projeto de pesquisa intitulado: **"Classificação de padrões do repositório de dados sobre avaliação postural utilizando redes neurais artificiais"**.

CARACTERÍSTICA PRINCIPAL DO ESTUDO: Estudo observacional de levantamento de dados numéricos.
RISCOS ADICIONAIS PARA O PACIENTE: sem contato com pacientes.
OBJETIVOS: Classificar padrões referentes à avaliação postural, utilizando redes neurais artificiais, para realizar um mapeamento inicial do padrão de referência postural brasileiro, e apoiar diretamente o diagnóstico de alinhamento dos segmentos corporais de um indivíduo.
RESUMO: Realizar um ambiente de testes (protótipo), utilizando um mapa auto-organizável (SOM), para verificar se esse tipo de rede neural artificial realiza o agrupamento dos dados de um pequeno grupo da população do repositório de dados de forma coerente, validando estes resultados com especialistas. Serão realizados testes com outros modelos de redes neurais artificiais visando encontrar uma melhor classificação das características do repositório de dados sobre avaliação postural. Este projeto utilizará resultados do projeto de pesquisa de doutorado avaliado e aprovado pelo CEP-USP cujo título Alinhamento Postural e variação do centro de pressão em adultos jovens para classificar padrões de referência postural brasileiro.
FUNDAMENTOS E RACIONAL: Fundamentado nas características contidas no repositório de dados sobre avaliação postural visando contribuir para uma determinação do padrão de referência postural brasileiro.
MATERIAL E MÉTODO: descritos o instrumento que será utilizado para coleta de dados.
TCLE: não se aplica.
DETALHAMENTO FINANCEIRO: sem financiamento específico R\$ 300,00.
CRONOGRAMA: 24 meses.
OBJETIVO ACADÊMICO: mestrado.
ENTREGA DE RELATÓRIOS PARCIAIS AO CEP PREVISTOS PARA: 11/09/2006 e 06/09/2007.

O Comitê de Ética em Pesquisa da Universidade Federal de São Paulo/Hospital São Paulo **ANALISOU e APROVOU** o projeto de pesquisa referenciado.

1. Comunicar toda e qualquer alteração do projeto e termo de consentimento livre e esclarecido. Nestas circunstâncias a inclusão de pacientes deve ser temporariamente interrompida até a resposta do Comitê, após análise das mudanças propostas.
2. Comunicar imediatamente ao Comitê qualquer evento adverso ocorrido durante o desenvolvimento do estudo.
3. Os dados individuais de todas as etapas da pesquisa devem ser mantidos em local seguro por 5 anos para possível auditoria dos órgãos competentes.

Atenciosamente,



Prof. Dr. José Osmar Medina Pestana
Coordenador do Comitê de Ética em Pesquisa da
Universidade Federal de São Paulo/ Hospital São Paulo

Rua Botucatu, 572 - 1º andar - conj. 14 - CEP 04023-062 - São Paulo / Brasil
Tel.: (011) 5571-1062 - 5539.7162

Anexo 2 – Parecer do Comitê de Ética em Pesquisa da Dra. Liu (2006)


Universidade Federal de São Paulo
Escola Paulista de Medicina

Comitê de Ética em Pesquisa
Hospital São Paulo

São Paulo, 16 de janeiro de 2004.
CEP 1611/03

Ilmo(a). Sr(a).
Pesquisador(a) LIU CHIAO YI
Disciplina/Departamento: Otorrinopediátrica/Otorrinolaringologia da
Universidade Federal de São Paulo/Hospital São Paulo

Ref. Projeto de pesquisa intitulado: "Avaliação da excursão do músculo diafragma em crianças respiradoras bucais e nasais de 5 a 12 anos de idade através de videofluoroscopia".

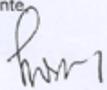
Prezado(a) Pesquisador(a),

O Comitê de Ética em Pesquisa da Universidade Federal de São Paulo/Hospital São Paulo ANALISOU e APROVOU o projeto de pesquisa acima referenciado.

Conforme resolução 196/96 do Conselho Nacional de Saúde são deveres do pesquisador:

1. Comunicar toda e qualquer alteração do projeto e do termo de consentimento. Nestas circunstâncias a inclusão de pacientes deve ser temporariamente interrompida até a resposta do Comitê, após análise das mudanças propostas.
2. Comunicar imediatamente ao Comitê qualquer evento adverso ocorrido durante o desenvolvimento do estudo.
3. Os dados individuais de todas as etapas da pesquisa devem ser mantidos em local seguro por 5 anos para possível auditoria dos órgãos competentes.
4. Apresentar primeiro relatório parcial em 14/julho/2004.
5. Apresentar segundo relatório parcial em 10/janeiro/2005.

Atenciosamente



Prof. Dr. José Osmar Medina Pestana
Coordenador do Comitê de Ética em Pesquisa da
Universidade Federal de São Paulo/ Hospital São Paulo

"Resaltamos que é de essencial importância que seja verificado, antes da divulgação dos processos e/ou resultados obtidos nesta pesquisa, se os mesmos são potencialmente patenteáveis ou passíveis de outras formas de proteção intelectual/industrial. A proteção por meio do depósito de patente, ou de outras formas de proteção da propriedade intelectual, evita a ação indevida de terceiros e confere maior segurança quando da publicação dos resultados da pesquisa."

Rua Botucatu, 572 - 1º andar – conj. 14 - CEP 04023-062 - São Paulo / Brasil
Tel.: (011) 5571-1062 - 5539.7162

Anexo 3 – Termo de Consentimento Livre e Esclarecido da Dra. Liu (2006)

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO INFLUÊNCIA DO MÚSCULO DIAFRAGMA NA COLUNA VERTEBRAL DE CRIANÇAS RESPIRADORAS BUCAIS

O objetivo desta pesquisa é verificar a relação entre a excursão do músculo diafragma e as curvaturas da coluna vertebral em crianças respiradoras bucais.

O método consiste inicialmente pela avaliação do ouvido, nariz e garganta para verificar a possível presença de secreções, hipertrofias adenoamigdalianas, alterações anatômicas, pólipos e tumores.

Posteriormente será realizado um exame de RX em que a criança permanecerá na posição em pé, na qual o aparelho estará direcionado para a região próximo à barriga, durante um tempo de quatro respirações no lado direito e quatro respirações no lado esquerdo.

Em seguida, todos os participantes irão tirar uma fotografia na posição em pé, em perfil à esquerda. Os procedimentos realizados promovem risco e desconforto mínimo ao paciente. Em caso de dano pessoal, diretamente causado pelos procedimentos propostos neste estudo, o participante terá direito a tratamento médico na instituição, bem como às indenizações legalmente estabelecidas.

Todas as informações e dados dos participantes serão mantidos em sigilo. Poderão ser utilizados unicamente para fins científicos, podendo assim, ser publicados em revistas médicas, apresentados em congressos ou ainda em reuniões científicas.

Não há benefício direto para o paciente. Trata-se de um estudo para avaliar o movimento do diafragma em crianças respiradoras bucais e nasais. É permitida a liberdade de retirada de consentimento a qualquer momento e deixar de participar do estudo, sem qualquer prejuízo à continuidade de seu tratamento na instituição. Não há despesas pessoais para o paciente, incluindo exames e consultas. Também não há compensação financeira relacionada à sua participação. Se existir qualquer despesa adicional, ela será absorvida pelo orçamento da pesquisa.

Acredito ter sido suficientemente informado a respeito das informações que li ou que foram lidas para mim. Discuti com a Dra. Liu Chiao Yi sobre minha decisão em incluir meu filho(a) na participação deste estudo. Ficaram claros para mim quais foram os propósitos do estudo, os procedimentos a serem realizados, as garantias de confidencialidade e de esclarecimentos permanentes. Ficou claro também que a participação é isenta de despesas. Concordo voluntariamente em participar deste estudo e poderei retirar o meu consentimento a qualquer momento, sem penalidades, prejuízo ou perda de qualquer benefício que meu filho(a) possa ter adquirido, no seu atendimento neste serviço.

.....
Assinatura do paciente/representante legal

.....
Assinatura da testemunha

Declaro que obtive de forma apropriada e voluntária o Consentimento Livre e Esclarecido deste paciente para a participação deste estudo.

.....
Assinatura do responsável pelo estudo

Anexo 4 – Aprovação para Utilização da Base de Dados

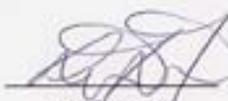
São Paulo, 30 de junho de 2005.

Ao Comitê de Ética em Pesquisa da Universidade Federal de São Paulo.

Eu, Liu Chiao Yi, RG 21.768.301-0, autorizo Felipe Mancini, RG 29593718X, a utilizar em seu projeto de pesquisa de mestrado intitulado "Aplicação de Redes Neurais Artificiais na Classificação de Padrões Posturais de Crianças Respiradoras Bucais", apenas dados numéricos do repositório de dados obtido em meu projeto de doutorado intitulado "Influência do músculo diafragma na coluna vertebral de crianças respiradoras bucais".

Sem mais, coloco-me a disposição para eventuais esclarecimentos.

Atenciosamente



Liu Chiao Yi

Anexo 5 – Valores Numéricos Apresentados pela Figura 16

Desvio-padrão especificidade

0,15811	0,21082	0,15811	0	0,21082	0,33747	0	0,15811
0	0,20226	0,15076	0,15076	0,15076	0,32333	0,20226	0,15076
0	0	0	0	0,14434	0,31079	0,14434	0
0	0,13868	0	0	0	0,29957	0,29957	0
0	0	0,36314	0,13363	0,13363	0,28947	0,26726	0
0	0,1291	0,35187	0,17593	0,1291	0,28031	0,1291	0
0,125	0,125	0,27195	0,125	0,125	0,25	0	0
0,12127	0,19648	0,16605	0	0,12127	0,24254	0,12127	0
0,11785	0,11785	0,16169	0	0,11785	0,2357	0,25725	0
0,11471	0,11471	0,15765	0,11471	0,11471	0,22942	0,25073	0
0,1539	0,1118	0,18317	0	0,1118	0,22361	0,30779	0
0,10911	0,25588	0	0	0,23905	0,21822	0,23905	0
0,1066	0,1066	0,1066	0,1066	0,2132	0,2132	0,23378	0,1066
0,10426	0,14405	0,10426	0,10426	0,20851	0,20851	0,29987	0
0	0,29411	0,10206	0,10206	0,20412	0,20412	0,20412	0,14116
0	0,23629	0	0,2	0,2	0,2	0,28868	0,23629
0,19612	0,23205	0	0,098058	0,19612	0,19612	0,28352	0,23205
0,19245	0,22802	0	0,096225	0,19245	0,19245	0,27863	0,22802
0,18898	0,27398	0	0	0,18898	0,26227	0,32275	0,2242
0,1857	0,12894	0	0,1857	0,1857	0,20463	0,30993	0,22056
0,18257	0,25371	0	0,18257	0,18257	0,18257	0,25371	0,21709
0,17961	0,2613	0,17961	0,17961	0,17961	0,17961	0,24973	0,21377
0	0,25745	0,24593	0,17678	0,17678	0,12297	0,24593	0,21061
0,087039	0,29994	0,24231	0,17408	0,17408	0,12115	0,29194	0,17408
0,085749	0,29592	0,23883	0,1715	0,1715	0,11942	0,2879	0,1715
0,18675	0,21498	0,16903	0,16903	0,16903	0,11775	0,2355	0,16903
0,24357	0,1992	0,1992	0,16667	0,16667	0,11616	0,23231	0,16667
0,27672	0,19663	0,11462	0,1644	0,1644	0,22924	0,1644	0,1644
0,27328	0,19415	0,27328	0,16222	0,16222	0,22629	0,1794	0,16222
0,26995	0,19177	0,26995	0,16013	0,16013	0,22346	0,17713	0,16013
0,18947	0,2317	0,26675	0,15811	0,15811	0,22072	0,15811	0,15811
0,21808	0,18725	0,21808	0,15617	0,15617	0,15617	0,15617	0,15617
0,1543	0,22638	0,21554	0,1543	0,1543	0,1543	0,1543	0,1543
0,21308	0,21308	0,21308	0,1525	0,1525	0,1525	0,1525	0,1525
0,21071	0,15076	0,21071	0,15076	0,15076	0,15076	0,15076	0,15076
0,14907	0,14907	0,20841	0,20841	0,14907	0,14907	0,14907	0,14907
0,14744	0,20618	0,14744	0,20618	0,14744	0,14744	0,14744	0,14744
0,14586	0,20403	0,20403	0,20403	0,14586	0,20403	0,14586	0,14586
0,14434	0,20194	0,20194	0,14434	0,14434	0,14434	0,14434	0,14434
0,14286	0,19991	0,19991	0,14286	0,14286	0,14286	0,14286	0,14286
0,14142	0,14142	0,19795	0,14142	0,14142	0,14142	0,14142	0,19795
0,14003	0,14003	0,14003	0,14003	0,14003	0,14003	0,14003	0,14003
0,13868	0,13868	0,13868	0,13868	0,13868	0,13868	0,13868	0,13868

Especificidade

0,15811	0,21082	0,15811	0	0,21082	0,33747	0	0,15811
0	0,20226	0,15076	0,15076	0,15076	0,32333	0,20226	0,15076
0	0	0	0	0,14434	0,31079	0,14434	0
0	0,13868	0	0	0	0,29957	0,29957	0
0	0	0,36314	0,13363	0,13363	0,28947	0,26726	0
0	0,1291	0,35187	0,17593	0,1291	0,28031	0,1291	0
0,125	0,125	0,27195	0,125	0,125	0,25	0	0
0,12127	0,19648	0,16605	0	0,12127	0,24254	0,12127	0
0,11785	0,11785	0,16169	0	0,11785	0,2357	0,25725	0
0,11471	0,11471	0,15765	0,11471	0,11471	0,22942	0,25073	0
0,1539	0,1118	0,18317	0	0,1118	0,22361	0,30779	0
0,10911	0,25588	0	0	0,23905	0,21822	0,23905	0
0,1066	0,1066	0,1066	0,1066	0,2132	0,2132	0,23378	0,1066
0,10426	0,14405	0,10426	0,10426	0,20851	0,20851	0,29987	0
0	0,29411	0,10206	0,10206	0,20412	0,20412	0,20412	0,14116
0	0,23629	0	0,2	0,2	0,2	0,28868	0,23629
0,19612	0,23205	0	0,098058	0,19612	0,19612	0,28352	0,23205
0,19245	0,22802	0	0,096225	0,19245	0,19245	0,27863	0,22802
0,18898	0,27398	0	0	0,18898	0,26227	0,32275	0,2242
0,1857	0,12894	0	0,1857	0,1857	0,20463	0,30993	0,22056
0,18257	0,25371	0	0,18257	0,18257	0,18257	0,25371	0,21709
0,17961	0,2613	0,17961	0,17961	0,17961	0,17961	0,24973	0,21377
0	0,25745	0,24593	0,17678	0,17678	0,12297	0,24593	0,21061
0,087039	0,29994	0,24231	0,17408	0,17408	0,12115	0,29194	0,17408
0,085749	0,29592	0,23883	0,1715	0,1715	0,11942	0,2879	0,1715
0,18675	0,21498	0,16903	0,16903	0,16903	0,11775	0,2355	0,16903
0,24357	0,1992	0,1992	0,16667	0,16667	0,11616	0,23231	0,16667
0,27672	0,19663	0,11462	0,1644	0,1644	0,22924	0,1644	0,1644
0,27328	0,19415	0,27328	0,16222	0,16222	0,22629	0,1794	0,16222
0,26995	0,19177	0,26995	0,16013	0,16013	0,22346	0,17713	0,16013
0,18947	0,2317	0,26675	0,15811	0,15811	0,22072	0,15811	0,15811
0,21808	0,18725	0,21808	0,15617	0,15617	0,15617	0,15617	0,15617
0,1543	0,22638	0,21554	0,1543	0,1543	0,1543	0,1543	0,1543
0,21308	0,21308	0,21308	0,1525	0,1525	0,1525	0,1525	0,1525
0,21071	0,15076	0,21071	0,15076	0,15076	0,15076	0,15076	0,15076
0,14907	0,14907	0,20841	0,20841	0,14907	0,14907	0,14907	0,14907
0,14744	0,20618	0,14744	0,20618	0,14744	0,14744	0,14744	0,14744
0,14586	0,20403	0,20403	0,20403	0,14586	0,20403	0,14586	0,14586
0,14434	0,20194	0,20194	0,14434	0,14434	0,14434	0,14434	0,14434
0,14286	0,19991	0,19991	0,14286	0,14286	0,14286	0,14286	0,14286
0,14142	0,14142	0,19795	0,14142	0,14142	0,14142	0,14142	0,19795
0,14003	0,14003	0,14003	0,14003	0,14003	0,14003	0,14003	0,14003
0,13868	0,13868	0,13868	0,13868	0,13868	0,13868	0,13868	0,13868

Desvio-padrão sensibilidade

0,15811	0,15811	0,21082	0,24152	0,15811	0,26352	0,15811	0,15811
0,15076	0	0,20226	0,15076	0,15076	0,32333	0,20226	0,20226
0,19462	0	0,14434	0,19462	0,14434	0,25746	0,24618	0,22613
0,18777	0	0,32522	0,13868	0,13868	0,32522	0,13868	0,18777
0,28947	0	0,37978	0,13363	0,13363	0,30562	0,13363	0,18157
0,2582	0,1291	0,37161	0,1291	0,1291	0,20702	0,28031	0,1291
0,25	0	0,3594	0,125	0,125	0,25	0,125	0,125
0,16605	0,24254	0,28115	0,12127	0,12127	0,2643	0	0,12127
0,11785	0,2357	0,27416	0,16169	0,16169	0,27416	0	0,11785
0,11471	0,11471	0,25073	0,11471	0,15765	0,25073	0	0,11471
0,1118	0,1118	0,26157	0,1118	0,1539	0,26157	0,24468	0,1539
0	0,21822	0,25588	0,10911	0,1504	0,25588	0,23905	0,10911
0,2132	0,2132	0,23378	0,1066	0,25054	0,14712	0,23378	0,1066
0,10426	0,2881	0,24551	0	0,24551	0,10426	0,22885	0,10426
0,10206	0,22421	0,22421	0	0,16892	0,16892	0,2658	0,24077
0	0,27689	0,21985	0,13844	0,13844	0,13844	0,21985	0,21985
0,098058	0,27175	0,21573	0	0,13587	0,16291	0,23205	0,21573
0	0,26688	0,21183	0	0,24167	0,13344	0,13344	0,22802
0	0,26227	0,20813	0,13113	0,20813	0,13113	0,13113	0,2378
0	0,25788	0,20463	0,092848	0,20463	0,26956	0,12894	0,2341
0,20129	0,26533	0,23057	0,12685	0,25371	0,18257	0,091287	0,20129
0,089803	0,2613	0,2714	0,12487	0,2613	0,17961	0,089803	0,17961
0,088388	0,14807	0,30412	0,21061	0,17678	0,17678	0,088388	0,21061
0	0,25376	0,26382	0,20757	0,17408	0,17408	0,14597	0,17408
0,1715	0,32703	0,29592	0,20467	0,1715	0,1715	0,20467	0,1715
0,16903	0,29205	0,25684	0,21498	0,16903	0,2355	0,20188	0,16903
0,23231	0,28833	0,29547	0,25355	0,16667	0,24357	0,22361	0,16667
0,3148	0,28475	0,29191	0,18175	0,1644	0,27672	0,20957	0,1644
0,20701	0,27328	0,32224	0,19415	0,16222	0,27328	0,1794	0,16222
0,31333	0,23451	0,31333	0,17713	0,16013	0,26995	0,16013	0,19177
0,2317	0,2317	0,20215	0,18947	0,15811	0,26675	0,17495	0,15811
0,24755	0,21808	0,23877	0,18725	0,15617	0,229	0,15617	0,15617
0,1851	0,26066	0,2087	0,26862	0,1543	0,1851	0,17083	0,1543
0,18303	0,19546	0,20648	0,18303	0,1525	0,18303	0,1525	0,1525
0,18102	0,19338	0,21413	0,18102	0,16697	0,22141	0,15076	0,19338
0,17908	0,16514	0,22863	0,17908	0,14907	0,17908	0,14907	0,2373
0,16337	0,1772	0,2575	0,29097	0,14744	0,14744	0,14744	0,18939
0,14586	0,19828	0,25492	0,22402	0,14586	0,19828	0,14586	0,14586
0,16	0,23039	0,25243	0,20194	0,14434	0,21237	0,16	0,18564
0,15838	0,21967	0,19453	0,21028	0,15838	0,1719	0,14286	0,15838
0,15682	0,15682	0,17023	0,15682	0,15682	0,15682	0,14142	0,18211
0,14003	0,14003	0,1553	0,16862	0,14003	0,14003	0,14003	0,16862
0,15382	0,15382	0,15382	0,15382	0,15382	0,15382	0,15382	0,15382

Sensibilidad

0,95	0,95	0,9	0,85	0,95	0,75	0,95	0,95
0,95455	1	0,90909	0,95455	0,95455	0,86364	0,90909	0,90909
0,91667	1	0,95833	0,91667	0,95833	0,79167	0,83333	0,875
0,92308	1	0,80769	0,96154	0,96154	0,80769	0,96154	0,92308
0,89286	1	0,75	0,96429	0,96429	0,85714	0,96429	0,92857
0,93333	0,96667	0,73333	0,96667	0,96667	0,9	0,9	0,96667
0,9375	1	0,8125	0,96875	0,96875	0,9375	0,96875	0,96875
0,94118	0,94118	0,88235	0,97059	0,97059	0,91176	1	0,97059
0,97222	0,94444	0,88889	0,94444	0,94444	0,88889	1	0,97222
0,97368	0,97368	0,92105	0,97368	0,94737	0,92105	1	0,97368
0,975	0,975	0,9	0,975	0,95	0,9	0,925	0,95
1	0,95238	0,90476	0,97619	0,95238	0,90476	0,92857	0,97619
0,95455	0,95455	0,93182	0,97727	0,90909	0,95455	0,93182	0,97727
0,97826	0,91304	0,91304	1	0,91304	0,97826	0,93478	0,97826
0,97917	0,9375	0,9375	1	0,9375	0,9375	0,875	0,91667
1	0,92	0,94	0,96	0,96	0,96	0,94	0,94
0,98077	0,92308	0,94231	1	0,96154	0,94231	0,92308	0,94231
1	0,92593	0,94444	1	0,90741	0,96296	0,96296	0,92593
1	0,92857	0,94643	0,96429	0,94643	0,96429	0,96429	0,91071
1	0,93103	0,94828	0,98276	0,94828	0,91379	0,96552	0,91379
0,95	0,91667	0,91667	0,96667	0,93333	0,96667	0,98333	0,95
0,98387	0,91935	0,90323	0,96774	0,91935	0,96774	0,98387	0,96774
0,98438	0,95313	0,89063	0,9375	0,96875	0,96875	0,98438	0,9375
1	0,92424	0,90909	0,93939	0,9697	0,9697	0,95455	0,9697
0,97059	0,88235	0,89706	0,94118	0,97059	0,97059	0,94118	0,97059
0,97143	0,9	0,91429	0,92857	0,97143	0,94286	0,94286	0,97143
0,94444	0,90278	0,88889	0,91667	0,97222	0,93056	0,91667	0,97222
0,89189	0,90541	0,89189	0,95946	0,97297	0,91892	0,93243	0,97297
0,93421	0,92105	0,86842	0,94737	0,97368	0,92105	0,96053	0,97368
0,88462	0,9359	0,88462	0,96154	0,97436	0,92308	0,97436	0,94872
0,9375	0,9375	0,9375	0,95	0,975	0,925	0,9625	0,975
0,91463	0,95122	0,92683	0,95122	0,97561	0,93902	0,97561	0,97561
0,95238	0,92857	0,92857	0,91667	0,97619	0,95238	0,96429	0,97619
0,95349	0,94186	0,93023	0,95349	0,97674	0,95349	0,97674	0,97674
0,95455	0,94318	0,92045	0,95455	0,96591	0,94318	0,97727	0,94318
0,95556	0,96667	0,93333	0,95556	0,97778	0,95556	0,97778	0,92222
0,96739	0,95652	0,92391	0,90217	0,97826	0,97826	0,97826	0,94565
0,97872	0,93617	0,92553	0,93617	0,97872	0,93617	0,97872	0,97872
0,96875	0,92708	0,92708	0,95833	0,97917	0,94792	0,96875	0,94792
0,96939	0,93878	0,93878	0,94898	0,96939	0,95918	0,97959	0,96939
0,97	0,97	0,96	0,97	0,97	0,97	0,98	0,95
0,98039	0,98039	0,97059	0,96078	0,98039	0,98039	0,98039	0,96078
0,97115	0,97115	0,97115	0,97115	0,97115	0,97115	0,97115	0,97115