

Aplicação de Redes Neurais Artificiais na Classificação de Padrões Posturais em Crianças Respiradoras Bucais e Nasais

Felipe Mancini 1

Liu Chiao Yi 2

Shirley Shizue Nagata Pignatari 2

Antonio Carlos Roque 3

Ivan Torres Pisa 1

Resumo: A respiração é a primeira função vital desenvolvida por ocasião do nascimento, estabelecendo-se como principal função do organismo. A respiração bucal crônica pode provocar alterações posturais, além de incitar um menor esforço do músculo diafragma. Este artigo tem por objetivo apresentar resultados sobre a aplicação de um modelo de rede neural artificial não-supervisionado, especificamente o mapa auto-organizável (self-organizing map, SOM), para auxiliar no diagnóstico e na avaliação da evolução clínica da postura de crianças respiradoras bucais e nasais. Apresentamos como padrão de entrada ao SOM as variáveis de postura e distância da excursão do músculo diafragma de 30 crianças respiradoras bucais e 22 crianças respiradoras nasais. O SOM apresentou taxa de acerto de 95% no diagnóstico de crianças respiradoras bucais e nasais. Da topologia resultante foi possível definir categorizações da postura dos pacientes.

Palavras-chave: Técnicas de apoio à decisão, redes neurais, respiração bucal, postura, suporte à decisão em medicina, mapas auto-organizáveis.

1 Departamento de Informática em Saúde (DIS), Universidade Federal de São Paulo (UNIFESP), Rua Botucatu, 862 CEP 04023-062, São Paulo/SP, Brasil

{felipe-pg@dis.epm.br, ivanpisa@dis.epm.br}

2 Departamento de Otorrinolaringologia Pediátrica e Cirurgia de Cabeça e Pescoço, Universidade Federal de São Paulo (UNIFESP), Rua Botucatu, 862 CEP 04023-062, São Paulo/SP, Brasil

{liu@netcomp.com.br, pigna@terra.com.br}

3 Departamento de Física e Matemática (DFM), Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto (FFCLRP), Universidade de São Paulo (USP), Av. Bandeirantes, 3900, CEP 14040-901, Ribeirão Preto/SP, Brasil

{antonior@neuron.ffclrp.usp.br}

Abstract: Breathing is the first vital function developed at birth, establishing itself as a major function of the organism. Chronic mouth breath can provoke postural alterations and a smaller effort of the diaphragm muscle. The objective of this work is to present results of an application of the self-organizing map (SOM), a non-supervised neural network, to assist in the diagnosis and evaluation of the postural clinical evolution of mouth and nasal breathing children. The input patterns presented to the SOM network contain the variables of posture and diaphragm muscle excursion distance of 30 mouth breathing children and 22 nasal breathing children. The SOM network had a 95% rate of correct answers in the diagnosis of mouth and nasal breath. The utilized topology made it possible to define a categorization of the patient's posture.

Keywords: Decision support techniques, neural networks, mouth breath, posture, decision support in medicine, SOM.

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 o mesmo 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 [1,2].

A respiração bucal na infância resulta em queixa freqüente no consultório do pediatra, do alergologista e do otorrinolaringologista. Sabe-se atualmente que a respiração bucal crônica, considerada com seis meses de evolução, pode provocar alterações no desenvolvimento odontológico, crânio-facial e da postura corporal [3, 4, 5, 6].

Aragão [7] estudou a postura corporal de 26 sujeitos respiradores bucais de 6 a 12 anos de idade e encontrou predominantemente as seguintes alterações: cabeça protrusa, retificação ou diminuição da lordose da coluna cervical, escápulas aladas, depressão anterior do tórax e protrusão abdominal. Liu et al. [8] e Krakauer [9] também encontraram as mesmas alterações posturais em crianças respiradores bucais de cinco a 12 anos de idade. Liu [10] constatou que a distância da excursão do diafragma é maior em crianças respiradoras nasais, se comparado com crianças bucais.

Redes neurais artificiais (RNAs) são sistemas compostos por unidades com processamento simples, interligadas entre si por conexões ponderadas por pesos, que executam operações em paralelo e de forma distribuída [11-13]. Elas podem ser consideradas como ferramentas genéricas capazes de implementar métodos estatísticos para reconhecimento de padrões [14, 15]. Devido à sua generalidade, a escolha do modelo de RNA a ser utilizado em uma dada aplicação depende do tipo de tarefa que o modelo deve executar [12, 13]. Em particular, problemas encontrados na prática médica clínica envolvem

geralmente associação e reconhecimento de padrões, fazendo com que as RNAs encontrem diversas aplicações na área médica [16].

Uma das principais características das RNAs é a sua capacidade de se adaptar a problemas específicos. Isso é feito através do que se chama de treinamento da rede [12-15]. Em termos genéricos, existem dois tipos de treinamento para uma rede neural:

1 – Treinamento supervisionado: os padrões fornecidos na entrada da rede estão explicitamente associados às saídas desejadas. Durante um período de treinamento, calcula-se um erro entre cada padrão fornecido pela rede em sua saída e o padrão de saída desejado e altera os valores dos pesos das conexões da rede em função desse erro, no sentido de minimizá-lo. A repetição desse tipo de treinamento acaba levando a rede a aprender a fazer a associação desejada entre os padrões de entrada e os de saída.

2 – Treinamento não supervisionado: A rede recebe apenas os padrões de entrada, sem que haja uma imposição de classificá-los de alguma maneira pré-estabelecida. Em função apenas dos padrões de entrada e dos valores correntes dos pesos das suas conexões, a rede altera esses pesos segundo um dado algoritmo até atingir um ponto de estabilidade.

O mapa auto-organizável (self-organizing map, SOM) tem por objetivo “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” [12]. Portanto, esse método permite realizar o agrupamento de dados multi-dimensionais do repositório de dados, contendo informações de diferentes contextos. Como resposta, o SOM fornece uma representação bi-dimensional topologicamente ordenada dos dados, de maneira que dados com características intrínsecas similares tenderão a ficar em regiões vizinhas [12].

Foi realizada em 19/09/2007 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 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 [16] citam

que mais de 5000 diferentes publicações utilizaram o SOM como modelo de RNA aplicado na solução de problemas reais . Como exemplo, [17], [18] e [19] aplicaram SOM na análise e classificação de dados biomédicos, obtendo resultados significativos.

Apesar do SOM ser um modelo de RNA não-supervisionado indicado para a etapa de extração de características, e a abordagem clássica para o desenvolvimento de uma máquina reconhecadora de padrões é utilizar um modelo supervisionado [20], Haykin [12] cita que o SOM pode ser aplicado para a tarefa de classificação de padrões devido a propriedade de rotular a cada neurônio artificial atributos similares do conjunto de entrada.

O objetivo deste trabalho é investigar a aplicação do SOM na classificação de padrões posturais em crianças respiradoras bucais utilizando como padrões de entrada dados de um repositório contendo as variáveis de postura e distância da excursão do músculo diafragma de 30 crianças respiradoras bucais e 22 crianças respiradoras nasais.

2 MÉTODOS

Para este estudo utilizou-se um repositório de dados, coletados no Setor de Diagnóstico por Imagem e na Disciplina de Otorrinolaringologia Pediátrica, da Universidade Federal de São Paulo - Escola Paulista de Medicina (UNIFESP). Foram analisadas 52 crianças, sendo que 32 foram previamente diagnosticadas como respiradoras bucais e 22 foram diagnosticadas como respiradoras nasais (caso controle). Os atributos deste repositório de dados são listados na Tabela 1, e o valor médio da postura, diafragma, peso e altura para cada categoria de pacientes – respirador bucal e caso controle – é apresentado na Tabela 2.

Tabela 1. Atributos do repositório de dados.

Antropométricos	Diafragma	Postura
Sexo	Tamanho da excursão do lado direito (PD)	Lordose Cervical
Idade		Lordose Lombar
Peso		
Altura	Tamanho da excursão do lado esquerdo (PE)	Cifose Torácica
IMC		Posição da Pelve
Raça		

A captação da imagem da excursão do diafragma foi obtida utilizando-se a técnica da videofluoroscopia [21]. 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 o raio 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. 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.

Após a obtenção destas informações foram utilizadas as seguintes ferramentas para análise: software Adobe Photoshop® para analisar a distância excursionada pelo músculo diafragma. A avaliação da postura corporal foi realizada através de fotografias obtidas em norma lateral esquerda. O software para avaliação postural (SAPO) [22] para analisar o comportamento das curvaturas da coluna vertebral.

Foi utilizado o pacote SOM Toolbox 2.0 [23] para implementar o SOM. O SOM Toolbox foi desenvolvido pelo Laboratório de Informação e Ciência da Computação da Universidade Helsinki. Este pacote possibilita a implementação do SOM através do Matlab® (The MathWorks Inc., Natick, MA, EUA).

A Figura 1 lista os pontos e ângulos utilizados na avaliação postural das crianças presentes neste estudo.

Tabela 2. Valor médio da postura, diafragma, peso e altura para cada categoria de pacientes, na qual CC representa pacientes da categoria caso controle e RB representa os pacientes da categoria respirador bucal.

	Peso (Kg)	Altura (m)	PD (cm)	PE (cm)	Lordose Cervical (graus)	Lordose Lombar (graus)	Cifose Torácica (graus)	Posição Pélvica (graus)
CC	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

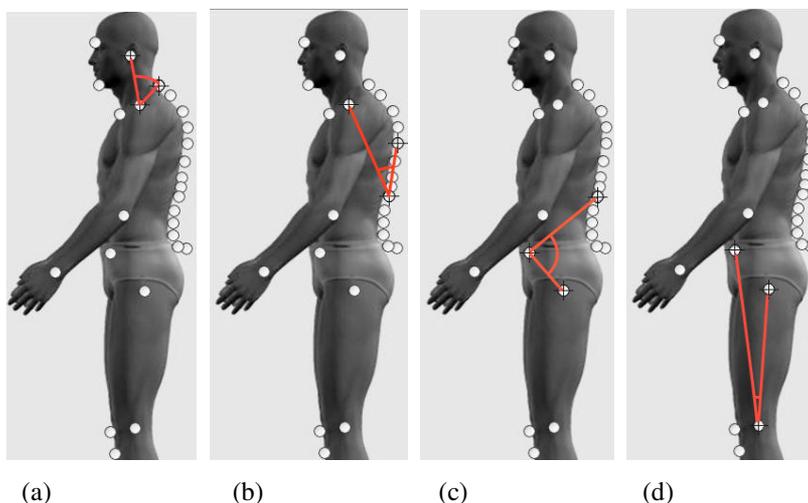


Figura 1. Representação dos pontos e ângulos utilizados na avaliação postural, indicando (a) lordose cervical; (b) cifose torácica; (c) lordose lombar; (d) posição da pelve.

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 1 itens (a), (b), (c) e (d), respectivamente, representando: (a) lordose cervical: trágus da orelha, acrômio e C7, sendo o acrômio o vértice do ângulo; (b) cifose torácica: L1, acrômio, T7, sendo L1 a vértice do ângulo; (c) lordose lombar: espinha ílica ântero superior, L1 e trocanter maior, sendo a espinha ílica ântero superior a vértice do ângulo; (d) posição da pelve: face lateral do espaço interarticular da articulação do joelho, espinha ílica ântero superior e trocanter maior, sendo a face lateral do espaço interarticular da articulação do joelho a vértice do ângulo. A Tabela 2 mostra os valores médios de cada atributo para cada categoria de crianças (respiradora bucal e caso controle).

2.1 Mapa auto-organizável

O SOM é um modelo de rede neural de aprendizagem não-supervisionada que utiliza regra de aprendizagem competitiva. Neste tipo de aprendizagem, os neurônios estão colocados em uma grade que é normalmente uni- ou bidimensional. Os neurônios tornam-se seletivamente sintonizados a vários padrões de entrada Haykin [12]. As localizações dos neurônios assim sintonizados se tornam ordenadas entre si, de forma que um sistema de coordenadas significativo para diferentes características de entrada é criado sobre a grade Kohonen [24]. Um mapa auto-organizável é, portanto, caracterizado pela formação de um mapa topográfico dos padrões de entrada. As localizações espaciais dos neurônios da grade são indicativas das características estatísticas intrínsecas contidas nos padrões de entrada.

Grade do mapa

O SOM é formado por uma grade de neurônios que é normalmente uni- ou bidimensional. Mapas com dimensionalidades mais altas são possíveis, mas não são tão comuns [12], pois sua visualização torna-se problemática [23]. Devido a este fato, abordagem teórica de modelos com outras dimensões são descartados, e este trabalho utiliza, por padrão, apenas mapas bidimensionais. Os neurônios estão conectados aos neurônios adjacentes por uma relação de vizinhança, ditando a estrutura do mapa. Os neurônios do mapa podem ser arrançados de forma retangular ou hexagonal [23].

Função de vizinhança

A função de vizinhança determina quanto fortemente os neurônios estão conectados entre si [23]. Em geral, usa-se uma função gaussiana para implementar a função de vizinhança [12, 23]:

$$h_{c(x)} = \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right), \quad (1)$$

sendo r_c o vetor posição do neurônio c , e r_i é a posição do neurônio vencedor, os dois sendo medidos no espaço discreto definido pelos nodos da rede neural. O parâmetro $\sigma^2(t)$ é o desvio padrão da função de vizinhança [12].

O desvio padrão da função de vizinhança $\sigma^2(t)$ diminui com o número de passos t [12]. Uma escolha popular para a dependência de σ com o tempo discreto t é o decaimento exponencial dado por [12]:

$$\sigma(t) = \sigma_0 \exp\left(-\frac{t}{\tau_1}\right), \quad (2)$$

sendo τ_1 uma constante de tempo.

Além da função gaussiana, a função retangular, função gaussiana cortada e a função epanechicov também podem ser utilizadas como função de vizinhança no SOM [23].

Treinamento

Em cada passo de treinamento, uma amostra do vetor x do padrão de entrada é escolhida randomicamente e uma similaridade é calculada entre ele e todos os vetores de peso do mapa, detonado por i [23]. O BMU (*best-matching unit*) [23], também conhecido como neurônio vencedor [12], detonado como c , é a unidade na qual o peso do vetor da grade tem a maior similaridade com o amostra do vetor x do padrão de entrada. A similaridade é usualmente definida pela menor valor da distância euclidiana entre o vetor x e todos os neurônios da grade, representado pela fórmula [12, 23]:

$$\|x - m_c\| = \min_i \{\|x - m_i\|\}. \quad (3)$$

Após determinar o BMU, os vetores de protótipos do SOM são atualizados. Os vetores de protótipos do BMU e suas vizinhanças topológicas movem-se próximos para o vetor do padrão de entrada do espaço de entrada. A regra de atualização para o vetor de pesos i é [12, 23]:

$$m_i(t+1) = m_i + \eta(t) * h_{c(x)}(t)[x(t) - m_i(t)], \quad (4)$$

sendo t o tempo, $\eta(t)$ a taxa de aprendizado, $h_{c(x)}(t)$ a função de vizinhança em torno do neurônio vencedor c .

Esta regra de atualização leva a uma ordenação topológica do mapa de característica no espaço de entrada no sentido de que os neurônios que são adjacentes na grade tenderão a ter vetores de peso sináptico similares [12].

O parâmetro de aprendizagem $\eta(t)$ é uma variável no tempo, que corresponde ao caso da aproximação estocástica. Em particular ela deve começar em um valor η_0 e então decrescer gradualmente com o aumento do tempo n . Esta exigência pode ser satisfeita escolhendo-se um decaimento exponencial para $\eta(t)$, como mostrado por [12]:

$$\sigma(t) = \sigma_0 \exp\left(-\frac{t}{\tau_2}\right), \quad (5)$$

sendo τ_2 é uma constante de tempo.

Acima foi listado o treinamento clássico do SOM, conhecido como treinamento com incremento. Um importante variante do treinamento com incremento é o algoritmo de treinamento em lote. Neste tipo de treinamento em vez de utilizar um único vetor de dados do padrão de entrada de cada vez para realizar o treinamento do mapa, todo o conjunto de dados de entrada são apresentados ao mapa antes de qualquer ajuste – por isso leva o nome de lote. Em cada passo de treinamento, o conjunto de dados de entrada é particionado de acordo com as regiões de Voronoi do mapa de vetores de peso (neurônios); isto é, cada neurônio pertence a um conjunto específico dos dados de entrada, através de uma relação de proximidade [23]. Após isso, os novos pesos dos neurônios serão [23]:

$$m_i(t+1) = \frac{\sum_{j=1}^n h_{ic}(t)x_j}{\sum_{j=1}^n h_{ic}(t)}, \quad (6)$$

sendo $c = \arg \min_k \{ \|x_j - m_k\| \}$ o BMU em relação do padrão de entrada x_j e o vetor de pesos (neurônio) m_k , e h_{ic} a função de vizinhança.

2.2 Determinação do modelo do SOM e padrão de entrada

Foram executados testes práticos a fim de determinar um modelo do SOM para realizar a análise do repositório de dados presente neste estudo. Segue abaixo a configuração final dos parâmetros do SOM empregados e suas respectivas justificativas. Como informado acima, foi utilizado o pacote SOM Toolbox 2.0 [23] para implementar o SOM. Desta maneira, segue a configuração dos parâmetros do SOM para este software.

- Inicialização dos vetores protótipos: linear. Não foi adotada a inicialização aleatória, pois a resposta do SOM alterava-se consideravelmente, impossibilitando uma análise correta. Com a inicialização linear o mapa de saída discreto não apresentou alterações.
- Relação de vizinhança: hexagonal. A relação de vizinhança hexagonal facilita a visualização dos neurônios vizinhos – cada neurônio vizinho está ligado a um lado do hexágono.

- Função de vizinhança: gaussiana. Essa função de vizinhança foi adotada como padrão para este trabalho, tendo respondido de maneira satisfatória para o problema em questão.
- Número de neurônios: grade de 3x3 neurônios. Foram realizados testes com grades de 4x4 neurônios e 3x3 neurônios. A grade de 4x4 neurônios representou sujeitos similares por neurônios diferentes, podendo gerar problemas na análise dos dados. Já a grade de 3x3 neurônios representou sujeitos similares por neurônios diferentes, realizando o agrupamento de maneira mais satisfatória.
- Algoritmo de treinamento adotado: algoritmo em lote. Além de apresentar melhor desempenho, comparado ao algoritmo seqüencial, o algoritmo em lote não apresenta nenhuma alteração quanto à rotação dos dados apresentados ao SOM.

Além disso, foram apresentadas diferentes combinações de dados, variando o conjunto de entrada com as variáveis da Tabela 2, ao SOM a fim de definir as características presentes nos padrões de entrada com maior taxa de acerto para o problema da classificação de crianças respiradoras bucais e nasais. O conjunto de características que se mostrou mais adequado para este tipo de problema foi o que incluiu dados sobre a postura – lordose cervical, cifose torácica, lordose lombar e posição da pelve – e o diafragma – PD e PE.

2.3 Leave-one-out

Para este estudo foi utilizado o algoritmo de validação cruzada leave-one-out (LOO) para calcular os acertos dos modelos de redes neurais artificiais [25]. No algoritmo LOO, $N - 1$ 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 [25].

3 RESULTADOS

Os resultados deste trabalho são divididos em 2 partes. Primeiramente o SOM foi aplicado como um classificador de crianças respiradoras bucais e nasais utilizando dados da postura. Posteriormente, foi aplicado o SOM para a determinação de padrões posturais em crianças respiradoras bucais.

3.1 Diagnóstico de crianças respiradoras bucais e nasais

A Figura 2 ilustra a rede SOM após o seu treinamento conforme o procedimento indicado na metodologia deste trabalho. Pode-se ver que a rede divide os dados em duas categorias bem definidas. Os neurônios 1, 2, 3, 4 e 7 representam crianças respiradoras bucais e os os neurônios 5, 6, 8 e 9 representam crianças caso controle. O único erro cometido nessa representação ocorre para o neurônio 8, que é um neurônio de rótulo “caso

controle” e que corretamente representa 4 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. Foi aplicado o LOO para calcular acerto do SOM na classificação de crianças respiradoras bucais, obtendo taxa de 95% de acerto.

A fim de justificar essa taxa de acerto, além de auxiliar na abordagem de outras características do repositório de dados, é necessário realizar algumas observações quanto ao comportamento das variáveis de postura e o tamanho da excursão do diafragma, conforme Tabela 3:

- O valor angular médio da lordose cervical no grupo das crianças respiradores bucais foi cerca de 15% maior, se comparado com o valor médio no grupo das crianças caso controle;
- O valor angular médio da lordose lombar no grupo das crianças respiradores bucais foi cerca de 25% menor, se comparado com o valor médio no grupo das crianças caso controle;
- O valor angular médio da cifose torácica no grupo das crianças respiradores bucais foi cerca de 11% maior, se comparado com o valor médio no grupo das crianças caso controle;
- O valor angular médio da posição da pelve no grupo das crianças respiradores bucais foi cerca de 45% maior, se comparado com o valor médio no grupo das crianças caso controle;
- O valor angular médio do PD e PE foi cerca de 34% menor, se comparado com o valor médio no grupo das crianças caso controle.

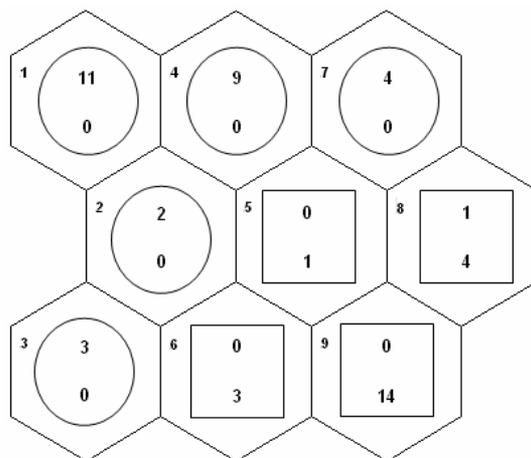


Figura 2. Mapa gerado após o treinamento do SOM. Cada hexágono representa um neurônio, com sua identificação do lado superior esquerdo. No interior de cada hexágono está desenhado um círculo ou um quadrado. O quadrado indica que o neurônio representa crianças respiradoras nasais e o círculo indica que ele representa crianças respiradoras bucais. Dentro de cada círculo e quadrado estão mostradas as quantidades de crianças respiradoras bucais (número acima) e de crianças respiradoras nasais (número abaixo) agrupadas sob o neurônio correspondente.

Tabela 3. Média de cada atributo para o conjunto de pacientes agrupados em cada neurônio, conforme representados pela Figura 2.

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

Uma variante de treinamento supervisionado da rede SOM, conhecida como quantização aprendida de vetores (learning vector quantization, LVQ) [12, 24], foi testada a

partir da aplicação do LOO. No entanto, ela não alteração na taxa de acerto, mantendo valor 95%.

3.2 Modelo para evolução clínica de crianças respiradoras bucais.

Por meio da Erro! Fonte de referência não encontrada. e da Figura 2 foi possível classificar os sujeitos em 4 classes de respiradores. Estas classes são apresentadas na Figura 3 e possuem as seguintes características:

- **Classe 1** – Esta classe representa o paciente respirador típico, dividido essencialmente em 2 subgrupos:
 - Subgrupo 1 - sujeitos representados pelo neurônio 1. Estes apresentam uma excursão de diafragma muito pequena – comparando com os pacientes do neurônio 9 (classe 4), o valor chega a ser 50% menor –, além de apresentar o menor valor médio do ângulo da lordose lombar e o maior valor médio da posição da pelve. O ângulo da lordose cervical é próximo do valor médio do grupo caso controle;
 - Subgrupo 2 - sujeitos representados pelo neurônio 4. Estes apresentam excursão do diafragma um pouco maior, se comparada com o subgrupo 1 desta mesma classe. O ângulo da lordose cervical apresenta o maior valor médio medido. Os valores médios dos outros atributos deste subgrupo não se alteram, se comparados com o subgrupo 1.

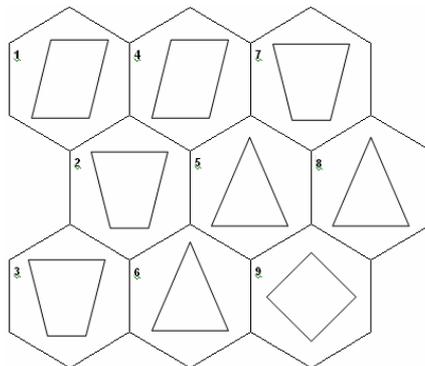


Figura 3. Representação dos 4 agrupamentos obtidos a partir da análise das médias dos atributos de cada neurônio, conforme listadas pela Erro! Fonte de referência não encontrada., seguindo os agrupamentos gerados pela Figura 2. A classe 1 é representada pelo paralelogramo, a classe 2 é representada pelo trapézio, a classe 3 é representada pelo triângulo e a classe 4 é representada pelo losango.

- **Classe 2** – Esta classe é constituída pelos pacientes agrupados sob os neurônios 2, 3 e 7. Apesar de o neurônio 7 não ser vizinho dos neurônios 2 e 3, os sujeitos agrupados nestas áreas podem ser considerados casos intermediários, e apresentam-se como fronteira para o grupo caso controle. A classe 2 possui as seguintes características:
 - Maior número de vizinhanças para a classe 3 – 5 vizinhanças – do que para a classe 1 – 2 vizinhanças;
 - Os valores médios dos atributos da classe 2 encontram-se entre os valores médios das classes 3 e 4 e os valores médios da classe 1;
- **Classe 3** – Esta classe compreende sujeitos agrupados sob os neurônios 5, 6 e 8. Tais sujeitos não podem ser rotulados como caso controle típico, por apresentarem principalmente grande variação do valor médio do ângulo lordose cervical;
- **Classe 4** – Esta classe contém os sujeitos típicos do caso controle. Especificamente, todos foram agrupados sob o neurônio 9, apresentando valores médios próximos à média dos sujeitos caso controle. Apenas o valor de PD e PE é superior à média dos sujeitos casos controle, sendo este o maior valor listado em todos as classes abordadas neste trabalho.

4 Discussão

Determinar as características dos padrões de entrada a serem usados na construção de um reconhecedor de padrões é uma tarefa crítica. No experimento computacional apresentado neste trabalho verificou-se que, por meio da comparação dos diferentes mapas gerados pelo SOM para diferentes conjuntos de dados apresentados, os dados da postura e o tamanho da excursão do diafragma geraram agrupamentos característicos. Foi realizado o teste t de Student, controlado pelo teste de Levene [26] para igualdades de variâncias, a fim de comprovar, a partir de um modelo estatístico convencional, se as diferenças médias entre a categoria dos respiradores bucais e a dos casos controle são significantes. Os dados são apresentados na Tabela 4.

Por meio da Tabela 4 é possível comprovar que somente os atributos referentes ao comportamento das curvaturas da coluna vertebral e distância da excursão do diafragma apresentaram diferenças médias significativas. Isto é, a partir do teste t de Student, mostra-se que apenas o conjunto de dados aplicado como padrão de entrada expressou diferenças médias significativas. Desta maneira, pode-se afirmar que os agrupamentos gerados pelo SOM são concordantes.

Tabela 4. Aplicação do teste t de Student controlado pelo teste de Levene para igualdade de variâncias. Se o valor de $p \leq 0,05$ pode-se concluir que as diferenças médias entre os grupos respirador bucal e caso controle são significativas.

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

Foram realizados testes com o objetivo de verificar a taxa de acerto do SOM no reconhecimento de um respirador bucal ou caso controle, caso os padrões de entrada contêm características diferentes das mostradas neste trabalho. Foi aplicado o LOO para este contexto e os resultados são mostrados na Tabela 5.

Tabela 5. Diferentes padrões de entrada apresentados ao SOM e a representação da quantidade de variáveis adotadas para cada conjunto de dados. Na coluna da direita é mostrada a porcentagem de acertos. * conjunto de dados adotados como padrão de entrada para este trabalho.

Padrão de entrada	Acertos (%)
Comportamento das curvaturas da coluna vertebral (4) e excursão do músculo diafragma (2)*	95
Comportamento das curvaturas da coluna vertebral (4), excursão do músculo diafragma (2), peso (1) e altura (1)	93
Comportamento das curvaturas da coluna vertebral (4)	92
Excursão do músculo diafragma (2)	54
Peso (1) e altura (1)	54

A partir da Tabela 5 é possível verificar que as características usadas para se montar os padrões de entrada deste trabalho levaram à maior taxa de acertos, evidenciando novamente que dados que possuem diferenças médias significativas tendem a apresentar maior taxa de acerto na classificação de padrões. Apesar de os atributos antropométricos não apresentarem diferenças médias significativas entre classes de pacientes, se apresentados em conjunto com os dados que possuem diferenças médias significativas estes não alteraram de maneira representativa a porcentagem de acertos do SOM. Este tipo de comportamento demonstra uma propriedade das redes SOM [12], que é a de conseguir realizar a tarefa de agrupamento de dados mesmo na presença de possíveis ruídos.

De maneira geral, o SOM foi eficiente para o diagnóstico de crianças respiradoras bucais e nasais. Foi aplicado o LVQ ao mesmo problema, porém não houve alteração na taxa de acerto (95%). Com o objetivo de avaliar o efeito de outras grades da rede e de

combinações de SOM com LVQ, foi aplicado o LOO para este propósito e o acerto na classificação de crianças respiradoras bucais, para cada configuração de rede são mostrados na Tabela 6.

Tabela 6. Resultados de testes executados com os dois modelos de RNA abordados neste trabalho, alterando-se o tamanho da grade (quantidade de neurônios). * modelo de RNA adotado como padrão para este trabalho.

Modelos de RNA	Configuração da grade	Acertos (%)
SOM*	3x3	95
SOM + LVQ	3x3	95
SOM	5x5	90
LVQ	3x3	87
LVQ	5x5	83
LVQ	10x10	83
SOM + LVQ	10x10	83
SOM	10x10	60

Com a grade 3x3 o SOM manteve-se com a melhor taxa de acertos se comparado com outras configurações e modelos de RNA. Porém, quando foi usada uma grade de 10x10 neurônios o SOM apresentou uma baixa taxa de acertos. Aplicando LVQ ao SOM com esta mesma estrutura de grade foi possível estabelecer uma taxa de acertos maior, porém não tão alta como no caso da rede 3x3.

Neste trabalho uma rede SOM foi utilizada para agrupar em diferentes classes sujeitos respiradores bucais e nasais. O principal foco da análise feita foi a determinação do conjunto de características comportamentais de postura e distância da excursão do diafragma de crianças respiradores bucais e nasais mais adequadas para fornecer um bom desempenho de classificação. Os resultados encontrados podem ser utilizados no desenvolvimento de outros estudos. Em particular, poderá ser desenvolvida uma ferramenta a fim de determinar o progresso da postura clínica em crianças respiradoras bucais.

Um outro estudo importante a ser realizado é comparar os resultados obtidos pelo SOM e LVQ na tarefa de classificação da postura de crianças respiradoras bucais com outros algoritmos de RNA (multi-layer perceptron, máquinas de vetor de suporte e função de base radial) Haykin [12].

5 Conclusões

Para a tarefa de classificação de crianças respiradoras bucais, a partir do repositório de dados analisado neste estudo, o SOM apresentou melhor desempenho, obtendo 95% de acerto utilizando como padrão de dados PD, PE e dados da postura.

Além disto, por meio do SOM foi possível apontar 4 classes de postura de crianças respiradoras bucais e nasais. Assim, foi possível mostrar que estas são decorrentes de diferentes perfis posturais.

Referências

- [1] Hungria H. Otorrinolaringologia. 7º ed. São Paulo: Guanabara Koogan, 1995.
- [2] Carvalho GD., 1996, Síndrome do respirador bucal ou insuficiente respirador nasal. *Rev Secret Saúde*, 2(18):22-24.
- [3] Schinestsck PA., 1986, A relação entre a má oclusão dentária, respiração bucal e a deformidade esqueléticas. *J Bras Ortod Ortop Max*, 3(4):45.
- [4] Aragão W., 1988, Respirador bucal. *J Ped*, 64(8):349-352.
- [5] Lusvarghi L., 1999, "Identificando o respirador bucal". Revista da APCD, 53(4):265-274.
- [6] Pizarro, GU., 2003, 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 / Escola Paulista de Medicina.
- [7] Aragão W., 1991, "Aragão's function regulator, the stomatognathic system". *J Clin Ped Dent*, 15(4):226-231.
- [8] Liu CY, Guedes ZCF, Vieira MM., 2003, "Relação da postura corporal com a disfunção da articulação temporomandibular: hiperatividade dos músculos da mastigação". *Fisioter Brasil*;4(5): 341-347.
- [9] Krakauer LRH. Relação entre respiração bucal e alterações posturais em crianças: uma análise descritiva. São Paulo, 1997. [Teses Mestrado]. Pontifícia Universidade Católica de São Paulo.
- [10] 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 / Escola Paulista de Medicina, 2006.
- [11] Roque, A C., 2004, 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 2006.
- [12] Haykin, S. Neural Networks: a Comprehensive Foundation. 2nd edition. New Jersey, Prentice-Hall, 1999.
- [13] Cross, S. S., Harrison, R. F., Lee Kennedy, R., 1995, "Introducion to Neural Networks". *Lancet*, 346: 1075-79.
- [14] Duda, R.O., Hart, P.E., Stork, D.G. Pattern Classification. 2nd edition. New York, Wiley-Interscience, 2000.
- [15] Fukunaga, K. Statical Pattern Recognition. 2nd edition, New York, Academic Press, 1990.
- [16] Cottrell M, Verleysen M, Advances in Self-Organizing Map. Neural Netw, 2006, 19(6-7): 721-22.

- [17] 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.
- [18] Barton, G., Lees, A., Lisboa, P., Attfield, S., 2005, “Visualisation of gait data with Kohonen self-organising neural maps”. *Gait & Posture*, In Press, Corrected Proof.
- [19] 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.
- [20] Duda RO, Hart, P.E., Stork, D.G. *Pattern Classification*. 2nd Edition. New York, Wiley-Interscience, 2000.
- [21] Hungria H. *Otorrinolaringologia*. São Paulo: Guanabara Koogan; 1995.
- [22] Duarte, Marcos. Portal do Projeto Software para Avaliação Postural., <http://sapo.incubadora.fapesp.br/portal>. Acessado em 19 maio de 2006.
- [23] Vesanto J, Himberg J, Alhoniemi E, Parhankangas J., 2000, "SOM toolbox 2.0 for Matlab." Espoo: Helsinki University of Technology.
- [24] Kohonen, T. *Self-Organizing Maps*. 2nd edition. Berlim, Springer-Verlag, 1997.
- [25] Burnham KP, Anderson D. *Model Selection and Multi-Model Inference*. Berlim: Springer; 2004.
- [26] Massad E, Menezes RX, Silveira PSP, Ortega NRS, *Métodos Quantitativos em Medicina*, São Paulo: Manole, 2004.