

## Comparação de algoritmos de redes neurais artificiais no diagnóstico de crianças respiradoras bucais

Comparison of algorithms for artificial neural networks in diagnosis of mouth breathing children

Felipe Mancini<sup>1</sup>  
Alex Esteves Jaccoud Falcão<sup>1</sup>  
Liu Chiao Yi<sup>2</sup>  
Shirley Shizue Nagata Pignatari<sup>2</sup>  
Domingos Alves<sup>3</sup>  
Ivan Torres Pisa<sup>4</sup>

**Descritores:** Respiração Bucal, Postura **RESUMO**

**Introdução:** A respiração bucal crônica é uma síndrome que pode promover alterações na postura corporal. 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. **Objetivo:** Comparar a acurácia de 4 algoritmos de RNA - mapa auto-organizável, aprendizagem por quantização vetorial (LVQ), perceptron e perceptron de múltiplas-camadas. **Métodos:** Utilizou-se como padrão de entrada dados de postura corporal de 52 crianças - 30 diagnosticadas previamente como respiradoras bucais e 22 como respiradoras nasais - no diagnóstico de crianças respiradoras bucais. Foi utilizado a algoritmo de validação cruzada leave-one-out, sendo calculada sensibilidade, especificidade e área sob a curva ROC para medir o desempenho dos algoritmos de RNA. **Resultados:** Dentre os algoritmos de RNA analisados, o LVQ apresentou melhores taxas de sensibilidade (0,90), especificidade (0,95) e AUC (0,92) no diagnóstico de crianças respiradoras bucais usando como padrão de entrada dados da postura corporal.

**Descriptors:** Mouth Breathing, Posture **ABSTRACT**

**Introduction:** Mouth breathing is a chronic syndrome that may bring about posture changes. Statistical methods have been proposed for nonlinear, high-dimensional biomedical data modeling, including artificial neural networks (ANN). ANN are statistical tools for dealing with nonlinear associations, which can be used to determine characteristic posture profiles of mouth-breathing children. **Objective:** To compare the accuracy of 4 ANN algorithms - self-organizing map, learning vector quantization (LVQ), perceptron, and multi-layer perceptron. **Methods:** The study was based on body posture data of 52 children, of which 30 were previously diagnosed as mouth-breathers and 22 were previously diagnosed as nasal breathers, presented as input pattern. **Results:** The leave-one-out cross-validation algorithm was applied, and sensitivity, specificity and area under ROC curve (AUC) were calculated to determine ANN accuracy. LVQ showed the highest sensitivity (0.90), specificity (0.95), and AUC (0.92) rates for the diagnosis of mouth-breathing children using body posture data as input pattern.

Autor Correspondente:  
**Felipe Mancini**  
e-mail: [fmancini@unifesp.br](mailto:fmancini@unifesp.br)

<sup>1</sup> Programa de Pós-graduação em Informática em Saúde, Universidade Federal de São Paulo -UNIFESP - São Paulo (SP), Brasil.

<sup>2</sup> Departamento de Otorrinolaringologia Pediátrica e Cirurgia de Cabeça e Pescoço, Universidade Federal de São Paulo -UNIFESP - São Paulo (SP), Brasil.

<sup>3</sup> Departamento de Física e Matemática (DFM), Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto (FFCLRP), Universidade de São Paulo - USP - São Paulo (SP), Brasil.

<sup>4</sup> Departamento de Informática em Saúde, Universidade Federal de São Paulo -UNIFESP - São Paulo (SP), Brasil.

Artigo recebido: 16/03/2009  
Aprovado: 23/06/2009

## 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<sup>(1-2)</sup>.

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. A respiração bucal crônica pode promover alterações no desenvolvimento odontológico, crânio-facial e na postura corporal<sup>(3-4)</sup>.

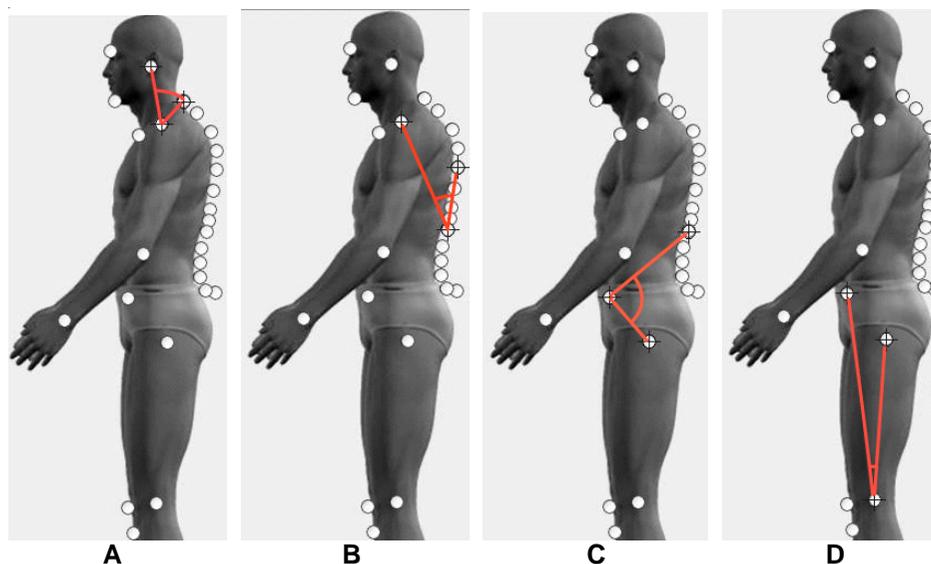
Devido ao aumento da resistência nasal no respirador bucal, o trabalho ventilatório apresenta-se aumentado<sup>(5)</sup>. Segundo<sup>(6)</sup>, os músculos acessórios da inspiração passam a ser solicitados, o que leva a um movimento inspiratório proeminente do tórax superior. O movimento inspiratório proeminente do tórax superior, segundo<sup>(7)</sup>, 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. Sendo assim, e devido ao fato dos músculos atuarem de forma sinérgica e serem organizados em cadeias<sup>(8)</sup>, a estrutura corporal pode ser interpretada como um sistema não-linear. Como exemplo, Liu et al.<sup>(9)</sup> 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<sup>(10)</sup>. 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<sup>(11)</sup>. 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*<sup>(12)</sup>. Um dos métodos mais populares que tem se mostrado eficiente para a análise de dados biomédicos é o de redes neurais artificiais (RNA)<sup>(11)</sup>. RNA são sistemas compostos por unidades de processamento simples, interligadas entre si por conexões ponderadas que executam operações



**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.

em paralelo e de forma distribuída<sup>(13)</sup>. As redes neurais artificiais podem ser aplicadas como ferramentas de análise estatística semi paramétrica de dados<sup>(14)</sup>. 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<sup>(15)</sup>.

Um modelo de RNA de aprendizagem não-supervisionada conhecido como mapa auto-organizável (SOM) foi aplicado para detectar diferentes categorias de postura de crianças respiradoras bucais<sup>(16-17)</sup>. Nestes estudos foi possível mostrar categorias de perfis posturais de crianças respiradoras bucais.

A partir do escopo apresentado, o presente estudo tem como objetivo comparar a acurácia de diferentes algoritmos de RNA<sup>(13)</sup> – SOM, aprendizagem por quantização vetorial (LVQ), perceptron (PT) e perceptron de múltiplas-camadas (MLP) – no diagnóstico de crianças respiradoras bucais utilizando dados da postura.

## MATERIAIS E MÉTODOS

Para este estudo utilizou-se um repositório de dados coletado no Setor de Diagnóstico por Imagem e na Disciplina de Otorrinolaringologia Pediátrica, da Universidade Federal de São Paulo. Foram realizadas avaliações posturais de 52 crianças, sendo que 30 foram previamente diagnosticadas como respiradoras bucais e 22 como respiradoras nasais. Os atributos do repositório de dados considerados para este estudo foram a lordose cervical, cifose torácica, lordose lombar e posição da pelve.

A Figura mostra a estratégia utilizada para determinação dos atributos utilizados neste trabalho, sendo: (a) lordose cervical: trágus da orelha, acrômio e C7, sendo o acrômio a 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 antero superior e trocanter maior, sendo a face lateral do espaço interarticular da articulação do joelho a vértice do ângulo.

O desempenho dos algoritmos de RNA escolhidos neste trabalho para a tarefa do diagnóstico de crianças respiradoras bucais usando dados da postura foi medido a partir da aplicação do algoritmo de validação cruzada leave-one-out (LOO)<sup>(18)</sup>, sendo calculadas taxas de sensibilidade e especificidade<sup>(19)</sup> e área sob a curva ROC (AUC)<sup>(20)</sup>.

### Composição da Base de Dados

O presente trabalho utilizou dois modelos de RNA de aprendizagem por correção de erro como processo de aprendizagem (MLP e PT) e dois modelos de RNA que utilizam a aprendizagem competitiva como

processo de aprendizagem (SOM e LVQ)<sup>(13)</sup>.

O SOM é utilizado para definir agrupamentos a partir da similaridade de determinadas características medidas do conjunto de dados, respeitando relações topológicas. Apesar de ser um modelo de RNA não-supervisionado, e a construção de um classificador de padrões pedir a utilização de aprendizagem supervisionada<sup>(13)</sup>, o SOM pode ser aplicado para a tarefa de reconhecimento de padrões<sup>(13)</sup>. Especificamente, diferentes estudos apontam que o SOM não deve ser utilizado para a tarefa de reconhecimento de padrões<sup>(13)</sup>. Porém, como este estudo tem caráter exploratório, entendemos como válido testar este modelo de RNA para a tarefa de diagnóstico de crianças respiradoras bucais.

O LVQ, apesar de utilizar o mesmo processo de aprendizagem do SOM, utiliza a técnica de aprendizagem supervisionada. O LVQ usa a informação sobre as classes para mover ligeiramente os pesos dos neurônios da grade, a fim de melhorar a qualidade das regiões de decisão de um classificador<sup>(13)</sup>. O LVQ apresenta resultados satisfatórios para a tarefa de classificação de padrões na área médica<sup>(11)</sup>.

O PT é a forma mais simples de uma RNA usada para a classificação de padrões ditos linearmente separáveis de maneira supervisionada – padrões que se encontram em lados opostos de um hiperplano<sup>(13)</sup>. O foco da utilização do PT para a tarefa de diagnóstico de crianças respiradoras bucais foi identificar se as classes analisadas são linearmente separáveis

O algoritmo de backpropagation é aplicado às redes conhecidas como perceptrons de múltiplas camadas (MLP)<sup>(13)</sup>, 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. 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<sup>(13)</sup>. Desta maneira, algoritmo backpropagation aplicado ao MLP (BP) realiza uma classificação de padrões de maneira não-linear e de natureza estocástica. O BP é um dos modelos mais populares para a tarefa de classificação de padrões de dados biomédicos<sup>(11)</sup>.

### Leave-one-out

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<sup>(18)</sup>. 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.

### Curva ROC

A curva Receiver Operating Characteristic (ROC)

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<sup>(19-20)</sup>.

Um das tarefas críticas para o cálculo da curva ROC é determinação de seu corte. Neste estudo, cada iteração do LOO foi proposta como variação do corte da curva ROC.

### Softwares Utilizados

O SOM Toolbox 2.0<sup>(21)</sup> foi utilizado na construção do SOM e LVQ e o Neural Networks Toolbox<sup>®</sup> (The MathWorks Inc., Natick, MA, USA) foi utilizado para construir o PT e o MLP. Estes pacotes permitem a implementação dos algoritmos de RNA por meio do Matlab<sup>®</sup> (The MathWorks Inc., Natick, MA, USA). A configuração final dos parâmetros SOM Toolbox e Neural Networks Toolbox para os algoritmos de RNA construídos foram:

- Perceptron – Estrutura da rede: 1 neurônio na camada oculta e 1 um neurônio na camada de saída. Número máximo de épocas utilizadas para treinamento: 100.

- Backpropagation - Estrutura da rede: 20 neurônios na primeira camada oculta, 5 neurônios na segunda camada oculta 1 neurônio na camada de saída. Função de treinamento: Levenberg-Marquardt. Número máximo de épocas utilizadas para treinamento: 100.

- LVQ - Estrutura da rede: 3 x 3 neurônios. Inicialização dos vetores protótipos: linear. Relação de vizinhança: hexagonal. Taxa de aprendizagem: 0,01.

- SOM - Estrutura da rede: 3 x 3 neurônios. Inicialização dos vetores protótipos: linear. Relação de vizinhança: hexagonal. Função de vizinhança: gaussiana.

## RESULTADOS

A Tabela 1 mostra a sensibilidade, especificidade e AUC no diagnóstico de crianças respiradoras bucais calculados a partir da aplicação do LOO aos 4 modelos de RNA, usando como padrão de entrada dados postura corporal.

**Tabela 1** - Especificidade (ESP), sensibilidade (SEN) e AUC calculados para o diagnóstico de crianças respiradoras bucais usando algoritmo de validação cruzada leave-one-out, e os modelos de RNA - LVQ, SOM, MLP e PT.

	ESP	SEN	AUC
LVQ	0,95	0,90	0,92
SOM	0,95	0,88	0,91
MLP	0,91	0,90	0,90
PT	0,36	0,96	0,70

A partir da Tabela 1, é possível verificar que o LVQ apresenta melhores taxas de sensibilidade, especificidade e AUC para a tarefa de diagnóstico de

crianças respiradoras bucais, utilizando como padrão de entrada dados de postura corporal.

## DISCUSSÃO

No presente estudo, foi utilizado o algoritmo LOO para auxiliar na determinação do melhor modelo de RNA para a classificação automática da postura de crianças respiradoras bucais. A adoção deste algoritmo de validação cruzada ocorreu por ser melhor aplicado quando o repositório de dados a ser analisado apresenta poucos atributos<sup>(13,22)</sup>.

Foram realizados testes utilizando outros algoritmos de validação cruzada (5-fold e 3-fold<sup>(18)</sup>), porém estes algoritmos apresentaram diferentes valores de sensibilidade e especificidade para mesmos conjuntos de testes realizados, além dos valores de sensibilidade e especificidade alcançados serem menores, se comparado aos valores alcançados pelo LOO. Isto ocorreu pela propriedade do LOO em aproximar os valores finais dos vetores de pesos dos neurônios durante o processo de validação.

Por meio da Tabela pode-se verificar que o PT apresentou menor AUC, 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.

Além disso, diferentemente do MLP e o PT, no LVQ é possível visualizar a vizinhança topológica 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.

Os autores<sup>(23-25)</sup> comparam a desempenho do SOM e MLP para diferentes problemas de classificação de padrões de dados biomédicos. Diferentemente aos resultados apresentados no presente estudo, MLP apresentou melhores taxas de sensibilidade e especificidade para todos os outros trabalhos. Isto ocorreu pela característica do MLP em apresentar maior número de funções em seu algoritmo de treinamento, o que pode ser um complicador quando é apresentado um pequeno conjunto de dados como padrão de entrada.

Apesar do SOM apresentar valor próximo da AUC (0,91), se comparado ao LVQ (0,92), este modelo de RNA possui paradigma de treinamento não supervisionado e sua aplicação é indicada para a tarefa de extração de características<sup>(26)</sup>. Este trabalho também verificou que o SOM apresenta limitações na classificação de padrões para o estudo apresentado, principalmente por apresentar menor de sensibilidade dentre os algoritmos de RNA analisados. Este fato também é constatado por Pesonen<sup>(23)</sup>.

Os autores<sup>(23,27)</sup> 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 melhores taxas de acertos se comparado ao BP. Este fato também pode estar ligado ao pequeno conjunto de dados utilizados para treinamento, utilizou 991 pacientes para treinamento<sup>(23)</sup> e utilizou 206 pacientes para treinamento<sup>(27)</sup>.

É necessário enfatizar que este é um estudo inicial na tentativa de desenvolver uma ferramenta que diagnostique automaticamente crianças respiradoras

bucais. É importante também a realização de outros estudos, a fim de aplicar outras bases de dados, outros modelos de RNA como função de base radial (RBF, radial-basis function)<sup>(13)</sup>, por exemplo.

## CONCLUSÃO

O LVQ apresentou melhores taxas de sensibilidade (0,90), especificidade (0,95) e AUC (0,92) no diagnóstico de crianças respiradoras bucais usando como padrão de entrada dados da postura corporal.

## REFERÊNCIAS

- Hungria H. Otorrinolaringologia. São Paulo: Guanabara Koogan; 1995.
- Carvalho GD. Síndrome do respirador bucal ou insuficiente respirador nasal. *Rev Secret Saúde*. 1996;2(18):22-4.
- Lusvarghi L. Identificando o respirador bucal. *Revista da APCD*. 1999;53(4):265-74.
- Pizarro GU. Análise videofluoroscópica das fases oral e faríngea da deglutição em crianças respiradoras bucais com apnéia do sono. [Dissertação] São Paulo (SP): Universidade Federal de São Paulo; 2003.
- Rodrigues EC, Bérzin F. Temporomandibular disorder and dysfunctional breathing. *Braz J Oral Sci*. 2004;3(10):498-502.
- Benatti AT. Equilíbrio tóraco-abdominal integrado à respiração e à postura. *Arq. Ciênc. Saúde Unipar*. 2001;5(1):87-92.
- Hruska RJ. Influences of dysfunctional respiratory mechanics on orofacial pain. *Dent Clin North Am*. 1997;41:211-7.
- Ribeiro EC, Soares LM. Avaliação espirométrica de crianças portadoras de respiração bucal antes e após intervenção fisioterapêutica. *Fisioter. Bras*. 2003;4(3):163-7.
- 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] São Paulo (SP). Universidade Federal de São Paulo; 2006.
- Villmann TH. Neural maps for faithful data modelling in medicine - state-of-the-art and exemplary applications. *Neurocomputing*. 2002;48(1-4):229-50.
- Lisboa PJG. A review of evidence of health benefit from artificial neural net-works in medical intervention. *Neural Netw*. 2002;15(1):11-39.
- Duda RO, Hart PE, Stork, DG. *Pattern classification*. 2nd ed. New York: Wiley-Interscience; 2000.
- Haykin S. *Neural networks: a comprehensive foundation*. 2nd ed. New Jersey: Prentice-Hall; 1999.
- Principe JC, Euliano NR, Lefebvre WC. *Neural and adaptive systems*. New York: Wiley; 2000.
- Bishop CM. *Pattern recognition and machine learning*. New York: Springer; 1995.
- Mancini F, Liu CY, Pignatari SSN, Alves D, Pisa IT. Postural qualitative analysis in mouth breath children. *Fisioterapia em Movimento*. 2007;20(2):119-26.
- 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. *Rev Inf Teo Apli*. 2007;14(2):91-107.
- Burnham KP, Anderson D. *Model selection and multi-model inference*. Berlin: Springer; 2004.
- Massad E, Menezes RX, Silveira PSP, Ortega NRS. *Métodos quantitativos em medicina*. São Paulo: Manole; 2004.
- Metz CE. Basic principles of ROC analysis. *Semin Nucl Med*. 1978; 8(4):283-98.
- Vesanto J, Himberg J, Alhoniemi E, Parhankangas J. *SOM 2.0 Toolbox para Matlab 5*. Espoo: Universidade de Tecnologia de Helsink; 2000.
- 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.
- Pesonen E, Matti E, Juhola M. Comparasion of different neural network algorithms in the diagnosis of acute appendicitis. *Int J Biomed Comput*. 1996;40(3):227-33.