

Empregando o *Neo Fuzzy Neuron* para Modelagem de um Conjunto de Dados Fisiológicos e Avaliação do Monitoramento de Apnéia – Um Estudo de Caso

Álvaro V.P. Souza¹, Walmir M. Caminhas², e Luís A. Aguirre^{1,3}

¹Laboratório de Modelagem, Análise e Controle de Sistemas Não Lineares

²Departamento de Engenharia Elétrica

³Departamento de Engenharia Eletrônica

Av. Pres. Antônio Carlos, 6627, 31.270-901, Belo Horizonte, MG.

E-mails: caminhas@eee.ufmg.br, aguirre@cpdee.ufmg.br

Abstract

O presente artigo discute um procedimento de modelagem, que usa o neo fuzzy neuron (NFN), de um conjunto de dados fisiológicos referente a um paciente que sofre de apnéia durante o sono. Tal patologia é caracterizada por distúrbios respiratórios durante o sono e, em consequência, pela oscilação do nível de oxigênio saturado no sangue. O objetivo principal do presente estudo é verificar a possibilidade de se monitorar pacientes que sofrem de apnéia durante o sono utilizando-se a informação contida nos pesos de uma rede baseada em NFN. Resultados preliminares serão apresentados e discutidos no artigo na forma de um estudo de caso. Alguns dos resultados obtidos sugerem que o uso da variabilidade da frequência cardíaca é útil para fins de monitoramento, o que vem de encontro com recentes resultados publicados na literatura.

Abstract. This paper discusses a neo fuzzy neuron (NFN) modeling procedure of a physiological data set recorded from a subject that suffers from sleep apnea syndrome. Such a pathology is characterized by breathing disorders during sleep and consequent drop in blood oxygen saturation. The main goal of this modeling procedure is to check if it is possible to screen for sleep apnea from data using NFN weights information. Preliminary results of sleep apnea screening will be presented as a case study. Some results suggest that the use of heart rate variability for screening of sleep apnea is helpful, enforcing recent works in the literature.

Palavras Chave. Modelagem de sinais biomédicos, Neo-Fuzzy Neuron, apnéia.

1 Introdução

A análise de séries temporais fisiológicas pode ser útil para compreensão e diagnóstico de patologias. Especificamente com relação a sinais respiratórios, recentes trabalhos na literatura apresentam técnicas de monitoramento ou de diagnóstico automático de apnéia empregando diversos princípios, como análise espectral do sinal de VFC [1, 2, 3, 4, 5, 6, 7, 8], dentre outros [9, 10, 11]. No presente trabalho, um exemplo de estudo de caso envolvendo sinais respiratórios de um paciente que sofre de apnéia do sono será considerado. Tais dados foram empregados em uma competição de predição de séries temporais promovida pelo Instituto Santa Fé [12].

A apnéia do sono é uma síndrome associada a distúrbios respiratórios ocorridos durante o sono [13, 14]. A principal característica desta patologia é a presença de paradas respiratórias, cuja consequência principal é a queda da saturação de oxigênio no sangue. A apnéia do sono tem sido foco de muitos estudos nos últimos anos e, embora pareça ser um problema simples, possui causas ainda não muito claras e de difícil tratamento. O uso de modelos [15] e técnicas avançadas de processamento de sinais podem auxiliar no melhor entendimento do problema bem como ajudar na identificação do padrão respiratório do paciente, conforme evidenciam recentes trabalhos [16, 17, 18, 19].

O principal objetivo do presente trabalho é apresentar uma modelagem de séries temporais, que empregou o *neo fuzzy neuron* (NFN) [20, 21] como representação matemática; e apontar caminhos de como é possível extrair informação relevante a partir desta técnica. A ênfase do artigo, portanto, está no procedimento de modelagem e no emprego do NFN para tal. Não é a intenção do trabalho apresentar resultados conclusivos sobre o problema fi-

siológico nem mesmo sobre formas de prever paradas respiratórias usando-se modelos matemáticos, uma vez que dados de apenas um paciente foram utilizados.

Em [18], uma modelagem destes dados foi apresentada empregando-se predição local linear. Em [16, 17], os mesmos dados foram também aproximados, porém, nesse caso, empregando-se modelos polinomiais NARMAX (do inglês *nonlinear autoregressive moving average model with exogenous inputs*) [22] e em trabalho recente, redes neurais do tipo multicamadas perceptron foram usadas na análise de uma séire de dados parecida [19]. Aparentemente, o presente trabalho é o primeiro a utilizar uma rede baseada no NFN na análise de dados de paciente que sofre de apnéia durante o sono.

Os dados fisiológicos em questão são apresentados na Seção 2, os conceitos básicos associados ao NFN podem ser vistos na Seção 3. Na Seção 4, são mostrados os resultados obtidos na modelagem e predição dos dados empregando o NFN. Na Seção 5 é proposto um procedimento baseado em funções de correlação dos pesos do NFN para classificar o padrão respiratório. As principais conclusões encontram-se na Seção 6.

2 Apresentação dos Dados

O conjunto de dados usados neste trabalho consiste em três séries temporais coletadas simultaneamente durante 4 horas e 43 minutos ininterruptas, a um tempo de amostragem de 0,5 s, totalizando 34.000 pontos [12].

As três séries temporais são i) esforço respiratório (R), ii) variabilidade da frequência cardíaca (VFC) e iii) saturação de oxigênio no sangue (SOS). A série (R) foi obtida por pletismografia (movimento de tórax), a série (VFC) por processamento dos intervalos RR observados no eletrocardiograma (ECG) e a série (SOS) por oximetria na orelha. Vale ressaltar que em trabalho recente apenas o fluxo de ar foi utilizado [19], apesar de seus autores acreditarem que o uso dos sinais de SOS e cardiovascular seriam úteis para uma melhor classificação.

O paciente monitorado é do sexo masculino, tem 43 anos e sofre de apnéia do sono. A faixa de dados mostrada na Figura 1 foi registrada em um momento em que o paciente respirava normalmente.

Na Figura 2 observam-se paradas respiratórias no esforço respiratório (R), e as conseqüentes quedas drásticas na saturação de oxigênio no sangue (SOS).

3 Neo-Fuzzy Neuron (NFN)

3.1 Comentários iniciais

Proposto por Yamakawa e colegas em 1992, o NFN é uma representação matemática não-linear, e representa um sistema nebuloso de inferência [20]. Tal representação tem sido usada com sucesso em problemas que envolvem sistemas dinâmicos, pois há determinado grau de rigidez em sua estrutura, fato que lhe confere boas características de generalização. O NFN é linear nos parâmetros, ou seja, o ajuste de pesos dispensa algoritmos complexos de otimização. Devido a essas facilidades, o NFN tem sido usado com sucesso em problemas relacionados a monitoramento de sistemas dinâmicos e detecção de falhas baseados em estimação *on-line* de pesos [23].

3.2 Topologia e formulação

O NFN é constituído por três camadas: a camada de entrada, a camada de agregação de regras e a camada de saída, ou de “desnebulização” (ver Figura 3). Cada um dos N nodos de entrada possui p partições, representadas por p funções de pertinência triangulares, fixas e regularmente distribuídas no espaço de excursão da variável associada. A Figura 4 mostra esquematicamente as funções de pertinência dos nodos de entrada do NFN. Pode-se notar que graças à forma com que essas p funções de pertinência estão distribuídas, no máximo duas delas estarão ativas para um dado valor x_i de entrada. Além disso, a soma do valor das funções ativas $f_j(x_i) + f_{j+1}(x_i)$ é sempre igual a 1.

A j -ésima partição de um dado nodo de entrada i é ponderada por um peso $w_{i,j}$, então é possível escrever que a saída do i -ésimo nodo de entrada após a agregação de regras é:

$$a_i = \sum_{j=1}^p f_{i,j}(x_i)w_{i,j}, \quad (1)$$

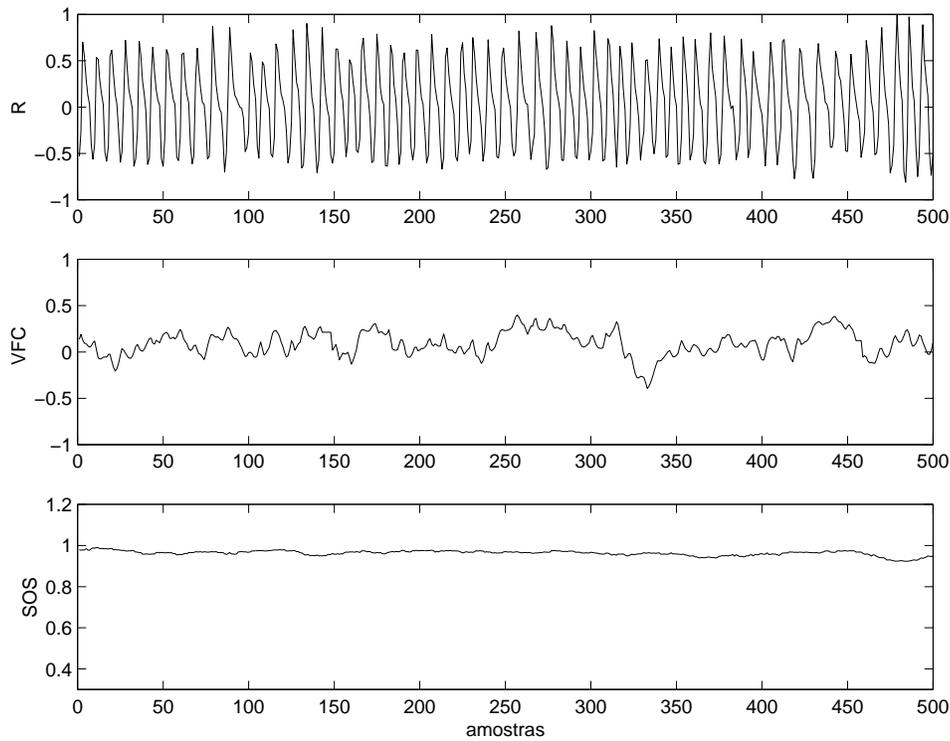


Figura 1: Faixa de dados coletada em um período em que o paciente respirava normalmente. De cima para baixo: esforço respiratório (R), variabilidade da frequência cardíaca (VFC) e saturação de oxigênio no sangue (SOS).

sendo w_{ij} pesos ajustáveis no treinamento do NFN. Deve ser lembrado que no somatório da equação (1), no máximo dois elementos são não nulos para cada valor da entrada.

Tendo em vista o tipo de função de pertinência utilizado, a última camada realiza a composição de todas as regras por meio de um somatório, ou seja,

$$y = \sum_{i=1}^N a_i. \quad (2)$$

Como apenas duas partições encontram-se ativas para um dado valor em cada nodo de entrada, a saída y pode ser obtida diretamente pela relação:

$$y = \mathbf{f}^T \boldsymbol{\zeta}, \quad (3)$$

sendo $\mathbf{f} \in \mathbf{R}^{2N \times 1}$ um vetor definido como

$$\mathbf{f} = [f_{1,j}(x_1) \ f_{1,j+1}(x_1) \ f_{2,k}(x_2) \ f_{2,k+1}(x_2) \ \dots \ f_{N,m}(x_N) \ f_{N,m+1}(x_N)]^T \quad (4)$$

e $\boldsymbol{\zeta} \in \mathbf{R}^{2N \times 1}$ um vetor definido como

$$\boldsymbol{\zeta} = [w_{1,j} \ w_{1,j+1} \ w_{2,k} \ w_{2,k+1} \ \dots \ w_{N,m} \ w_{N,m+1}]^T. \quad (5)$$

A equação (1) é linear, porém deve-se notar que, devido à existência de partições de entrada, o NFN é linear por partes, configurando uma representação globalmente não-linear.

3.3 Ajuste de pesos por mínimos quadrados

Considerando-se um conjunto de treinamento composto por N_T pares de entrada/saída (\mathbf{x}, y) , a equação (3) dá origem à seguinte equação matricial:

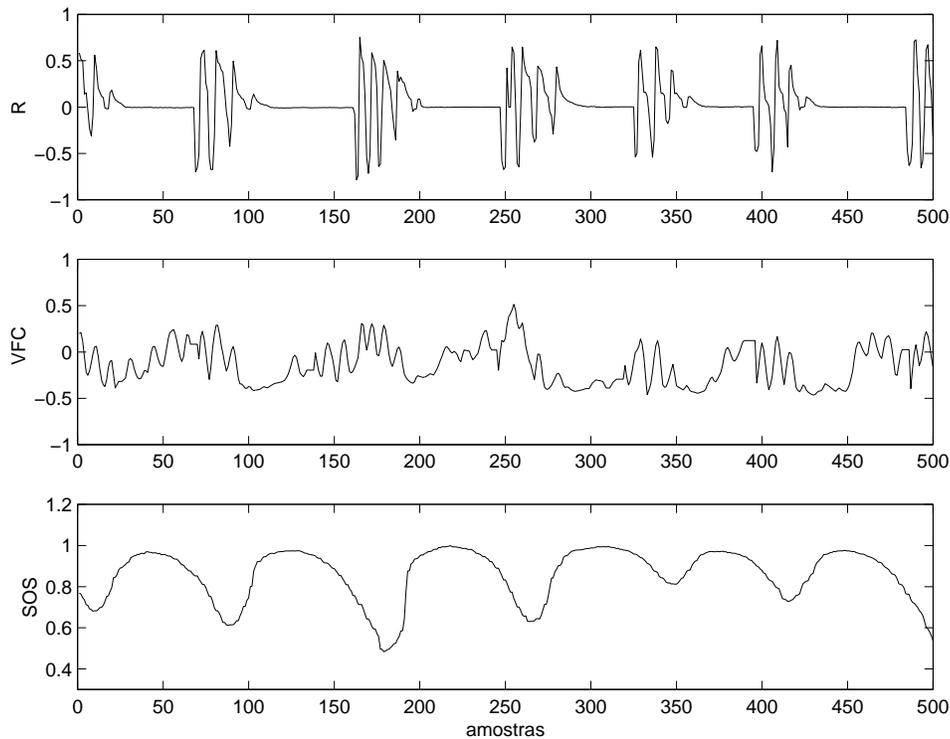


Figura 2: Faixa de dados coletada em um período em que o paciente exibiu respiração periódica (apnéia). De cima para baixo: esforço respiratório (R), variabilidade da frequência cardíaca (VFC) e saturação de oxigênio no sangue (SOS).

$$\mathbf{y} = \Psi \mathbf{w} , \quad (6)$$

em que $\mathbf{w} \in \mathbf{R}^{pN \times 1}$ é definido como

$$\mathbf{w} = [w_{1,1} \ w_{1,2} \ \dots \ w_{1,p} \ w_{2,1} \ w_{2,2} \ \dots \ w_{2,p} \ w_{N,1} \ w_{N,2} \ \dots \ w_{N,p}]^T . \quad (7)$$

Cada linha da matriz Ψ tem $2N$ valores diferentes de zero (dois por nodo de entrada). Dessa forma, o vetor de pesos \mathbf{w} pode ser estimado por meio de mínimos quadrados clássico, ou seja,

$$\hat{\mathbf{w}} = [\Psi^T \Psi]^{-1} \Psi^T \mathbf{y} . \quad (8)$$

Como a matriz Ψ é esparsa determinados cuidados numéricos são importantes na obtenção dos pesos. Algoritmos ortogonais com boas propriedades numéricas para solução de (8) são discutidos em [15].

4 Modelagem e Predição

A técnica de modelagem usada baseia-se na estimação de pesos de um *neo fuzzy neuron* (NFN) empregando mínimos quadrados, conforme exposto anteriormente. O NFN possui uma saída e duas entradas exógenas. Assim sendo, tal modelo é do tipo MISO (do inglês *multi-input single-output*). Valores atrasados das variáveis entrada e saída compõem as entradas do NFN.

Os sinais de respiração (R) e variabilidade da frequência cardíaca (VFC) foram usados como entradas do modelo, e a saturação de oxigênio no sangue (SOS) como saída. Extensivos testes de correlação cruzada mostraram que é razoável usar as séries de (R) e (VFC) como entradas para explicar (SOS) [16, 17]. Séries (R) e (VFC) atrasadas de 10 a 20 amostras foram incluídas nas entradas do NFN; e a série (SOS) foi realimentada com atrasos de 1 a 5 amostras. No NFN, foram usados os mesmos atrasos nas entradas que foram empregados nos modelos encontrados em [16, 17].

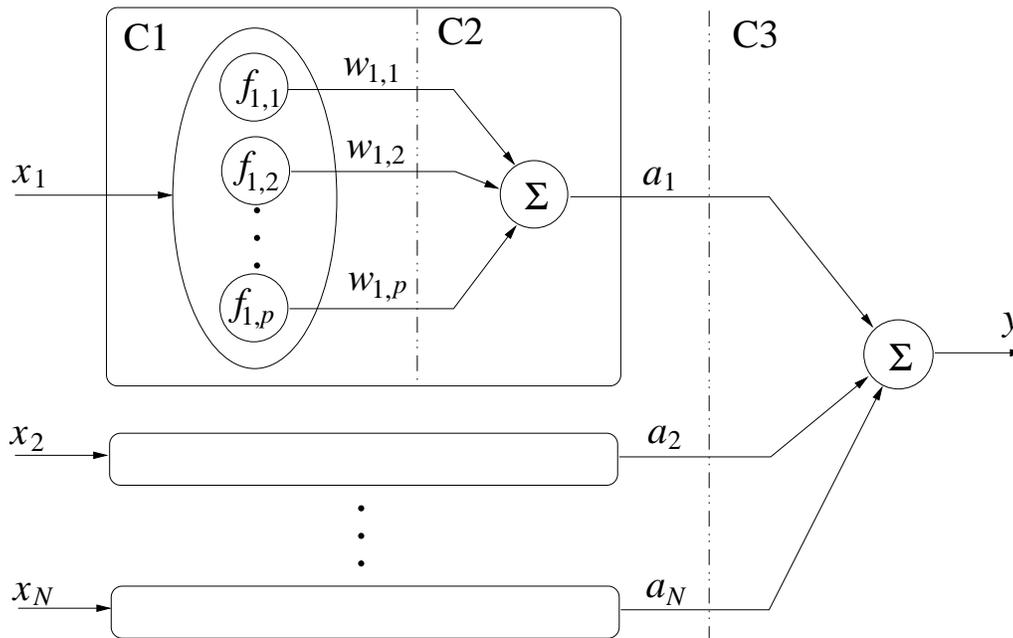


Figura 3: Topologia do NFN. Camadas: C1 é a camada de entrada, C2 é a camada de agregação de regras e C3 é a camada de saída.

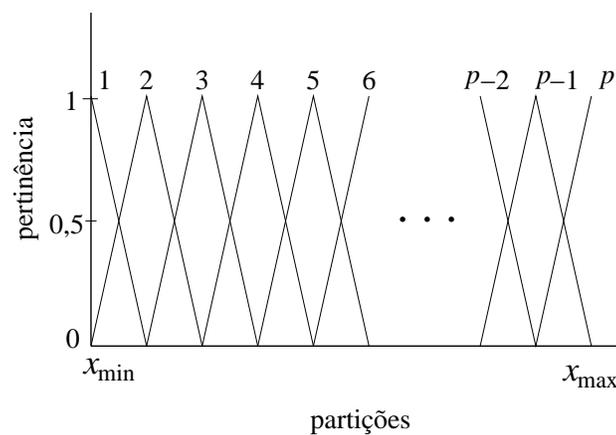


Figura 4: Funções de pertinência de cada nó de entrada do NFN.

Chegou-se a estes valores de atrasos após extensivas simulações. Apesar de se ter trabalhado com dados de um paciente apenas, acredita-se que tais atrasos constituem-se em bons pontos de partida na busca de representações matemáticas para os respectivos sinais de outros pacientes.

As séries temporais foram normalizadas da seguinte forma: A série (R) foi deslocada de maneira que o valor correspondente à parada respiratória fosse nulo, e em seguida normalizada no intervalo $[-1,1]$. A série (VFC) foi normalizada da seguinte forma: $(VFC-70)/30$. A série (SOS) foi normalizada pelo seu máximo valor.

Os modelos foram obtidos em três faixas de dados diferentes, onde respectivamente pode-se encontrar os comportamentos: i) respiração normal; ii) apnéia intermitente e iii) apnéia (respiração periódica). Todos os NFN's foram estimados para janelas de dados com 600 amostras em cada canal; e validadas com predição livre em uma janela subsequente com 150 amostras. Ou seja, cada NFN foi ajustado com um conjunto de treinamento de 600×3 amostras, e validado com 150×3 amostras. A nomenclatura apnéia e apnéia intermitente será adotada seguindo-se o trabalho [12] em que os períodos respiratórios foram também classificados. Tais autores classificaram como apnéia períodos em que o paciente alterna períodos sem respiração com períodos onde há respiração. Os períodos sem respiração têm duração maior do que 15 s, ao passo que os períodos com respiração caracterizam-se por uma rápida seqüência de em torno de quatro inspirações-expirações. A alternância entre esses períodos de respiração e não-respiração confere ao sinal de (SOS) uma característica oscilatória, como pode ser visto na Figura 2, daí a denominação de respiração periódica. A classificação de apnéia intermitente, como indicado pelos próprios autores [12] é muito mais subjetiva e é tomada simplesmente como um quadro intermediário entre respiração normal e apnéia.

Na Figura 5 pode-se ver a predição livre para a faixa de respiração normal. No gráfico mostrado, a linha contínua corresponde aos dados experimentais extraídos da série (SOS). Os valores realimentados correspondentes a série (SOS), evidenciados no gráfico pela linha pontilhada, são apenas estimativas, obtidas pelo próprio modelo.

A Figura 6 mostra a uma predição efetuada na faixa de apnéia intermitente, enquanto que a Figura 7 foi estimada com amostras da faixa de apnéia. Na Figura 6, predições de um passo à frente também estão mostradas.

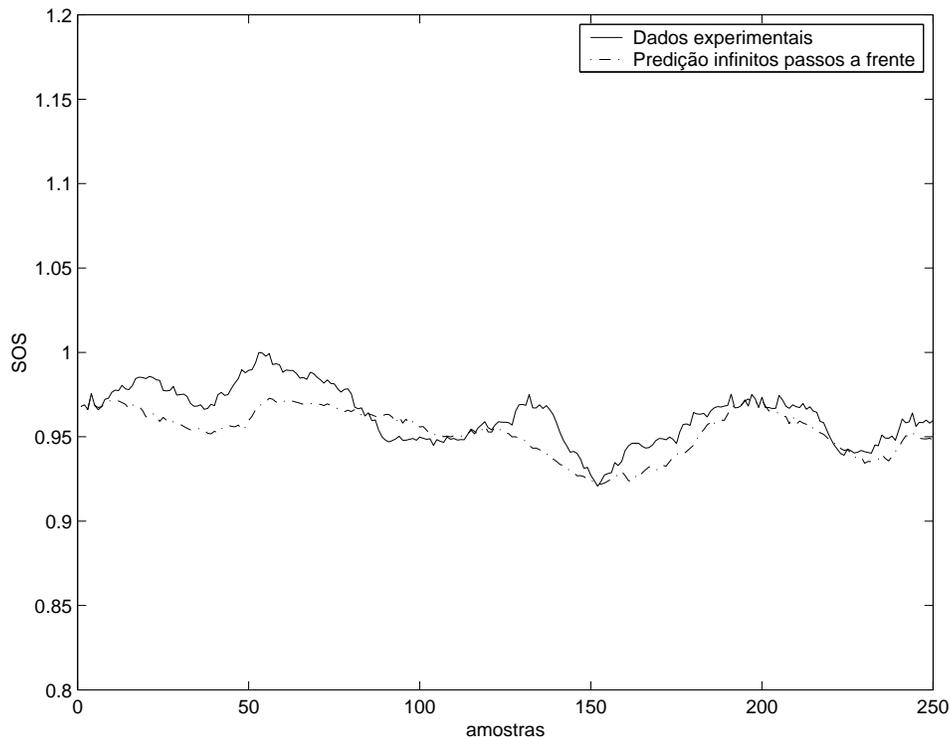


Figura 5: Predição livre MISO, na série SOS em uma faixa de respiração normal.

Existem várias aplicações possíveis em que tal modelagem pode ser útil, como i) possibilidade de extrair informações sobre o sistema através do processo de modelagem, ii) auxílio na implementação de dispositivos automáticos, como

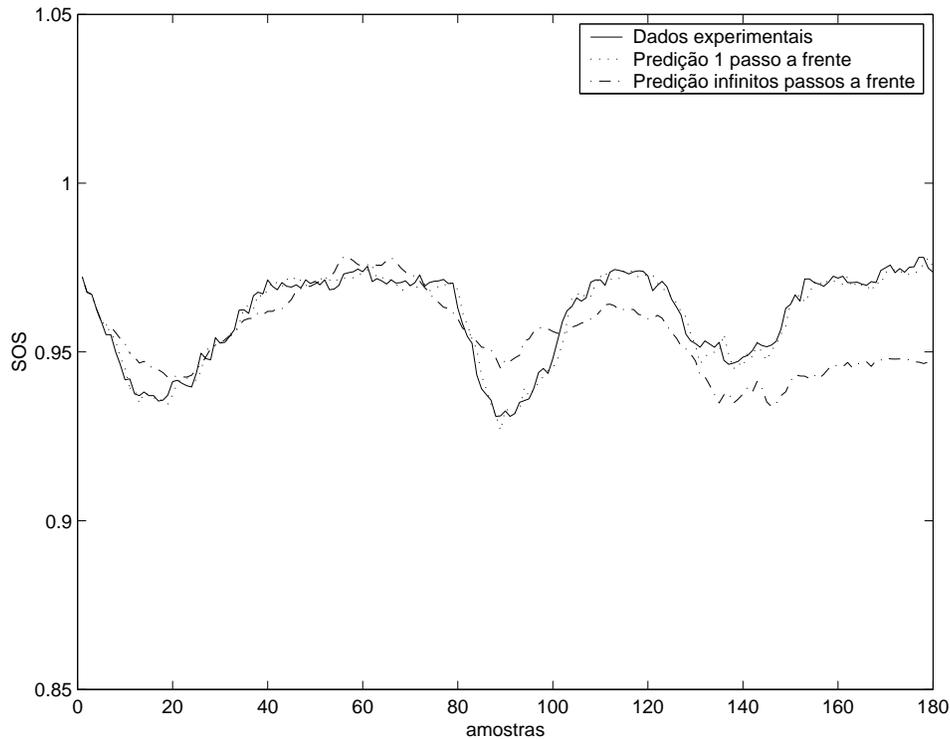


Figura 6: Predição livre MISO (linha traço-ponto), na série SOS, em uma faixa de apnéia intermitente. A linha pontilhada representa a predição um passo à frente.

por exemplo, monitoramento de pacientes, iii) auxílio no entendimento da fisiologia envolvida sob um ponto de vista mais pragmático, iv) avaliação do estado clínico do paciente e dos diferentes regimes dinâmicos envolvidos, entre outros.

Com a finalidade de avaliar as predições e compará-las a resultados anteriores, foi empregado o índice RMSE (do inglês *root mean square error*). Dada uma série de observações seqüenciais y_ℓ , $\ell = 1, 2, \dots$ e os respectivos valores estimados \hat{y}_ℓ , o índice RMSE é definido como:

$$RMSE = \frac{\sum_\ell (y_\ell - \hat{y}_\ell)}{\sum_\ell (y_\ell - \bar{y})}, \quad (9)$$

sendo que os somatórios são tomados ao longo da janela de dados considerada. Nota-se que o índice RMSE é normalizado com respeito à saída do “preditor trivial” que é a média dos dados de treinamento. Assim, valores de RMSE menores do que a unidade indicam que o modelo considerado faz predições melhores do que as do “preditor trivial” e vice-versa. Evidentemente, esse índice pode ser normalizado utilizando-se outro critério. A seguir além de utilizar a média da janela de treinamento \bar{y} , o valor medido no instante anterior também será utilizado como fator de normalização. Evidentemente, o uso de $y_{\ell-1}$ em (9) ao invés de \bar{y} resulta em um índice tipicamente maior do que o RMSE, uma vez que, de forma geral, $y_\ell - y_{\ell-1} < y_\ell - \bar{y}$. Nesse caso, o índice será indicado por RMSE(1).

Na Tabela 1, podem ser vistos os índices RMSE obtidos para predições com o NFN sobre 150 pontos de validação.

Com a finalidade de comparar estes resultados com os de predição com modelos NARMAX [22] obtidos em [16, 17]; a Tabela 2 apresenta os índices RMSE obtidos para este tipo de representação.

Comparando-se os índices, pode-se notar que existe uma semelhança na qualidade das predições. É importante ressaltar que, no caso NARMAX, uma janela maior de validação foi usada, mostrando mais consistência em um prazo maior de predição; porém a obtenção do NFN é mais simples.

Algumas séries simuladas do NFN exibiram uma piora considerável após 200 amostras de predição livre o que indica que o horizonte de previsão com o NFN dessas séries é em torno de 100 segundos. A piora do desempenho dos

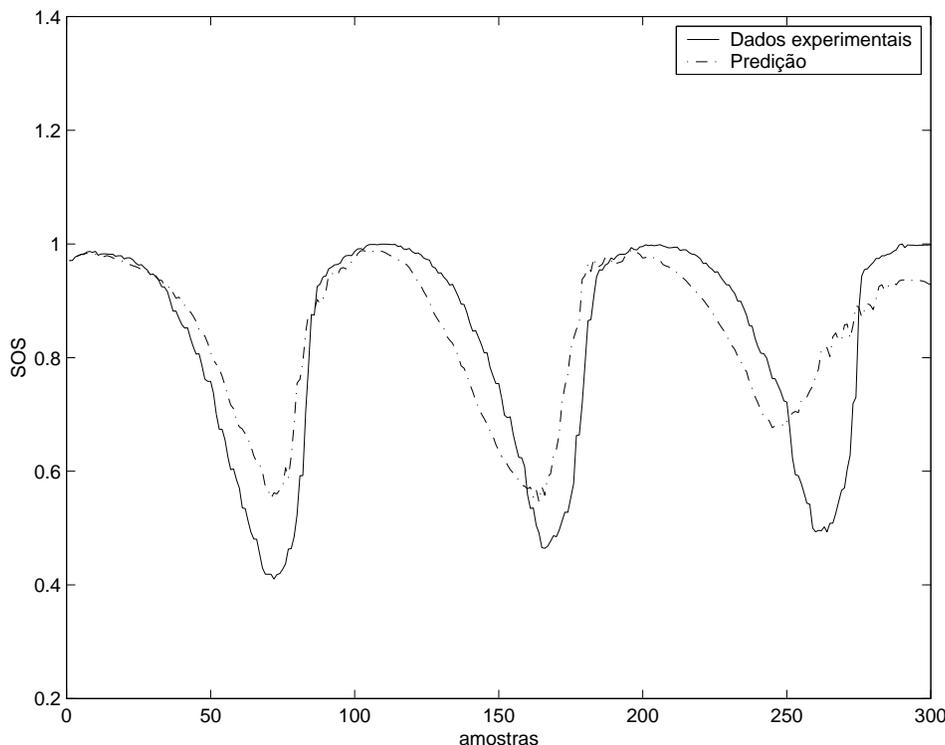


Figura 7: Predição livre MISO, na série SOS, durante apnéia.

Tabela 1: Índices RMSE para predições livres e de um-passo-à-frente, empregando-se o NFN, obtidos através dos dados mencionados.

Padrão resp.	RMSE	RMSE(1)
Ap. inter.	0,68	0,97
Apnéia	0,45	2,03

modelos à medida que a previsão se afasta da janela de treinamento é esperada no caso de sinais não-estacionários, como na presente situação [17].

Na próxima seção será mostrado como empregar o processo de modelagem visto aqui, na tentativa de previsão antecipada de apnéia.

5 Análise de Sinais Respiratórios Usando o NFN

Nesta seção, alguns testes preliminares de diagnóstico automático de apnéia serão efetuados, empregando-se a análise de pesos do *Neo-Fuzzy Neuron* (NFN). O uso do NFN foi motivado pela sua habilidade de supervisionar sistemas dinâmicos por meio do acompanhamento dos pesos do NFN treinados *on-line* [23].

5.1 Metodologia investigada

A idéia a ser investigada nesta seção baseia-se em acompanhar a evolução de um vetor de pesos \mathbf{P} estimados do NFN em janela deslizante sobre os dados por meio da comparação com pesos de redes NFN obtidas usando-se dados de respiração normal, \mathbf{P}_{RN} , e de apnéia, \mathbf{P}_{AP} . Tais pesos “padrões” foram obtidos na modelagem apresentada na seção anterior (mesma topologia da rede e atrasos nas variáveis) e para faixas de dados com comportamento conhecido e diagnosticado.

Dessa forma, sugere-se o seguinte procedimento como metodologia de monitoramento:

Tabela 2: Índices RMSE para predições livres e de um-passo-à-frente, empregando-se modelos NARMAX estimados para as faixas de dados mencionadas. Tais resultados foram detalhadamente discutidos em [16, 17].

Padrão resp.	RMSE	RMSE(1)
Ap. inter.	0,68	0,85
Apnéia	0,51	0,75

Tabela 3: Faixas de dados usadas nesta seção, aplicadas a metodologia proposta para monitoramento de apnéia. Durante a modelagem os primeiros 600 valores das faixas foram usados no treinamento e os 150 seguintes, na validação. No caso da classificação, a faixa de treinamento foi a mesma, mas a validação foi efetuada em outras janelas, conforme indicado.

Código	Faixa	Utilização
rn1	13.000 a 14.000	Obtenção de pesos-padrões de respiração normal
ap1	33.000 a 34.000	Obtenção de pesos-padrões de apnéia
nb2	18.200 a 19.200	Validação normal
ap2	3.000 a 4.000	Validação apnéia

1. Identificar e validar redes a partir de janelas de dados com diagnóstico claro. Os pesos da rede treinada e validada com dados de respiração normal são colocados no vetor \mathbf{P}_{RN} . Para a rede otida para dados de apnéia o vetor é \mathbf{P}_{AP} .
2. Fazer $n = 1$.
3. Tomar uma janela de dados de largura L compreendida entre as amostras $k_0 = 1$ a $k_f = L$, nas três séries temporais y_R , y_{VFC} e y_{SOS} .
4. Obter um conjunto de pesos $\mathbf{P}(n)$ por mínimos quadrados empregando-se a janela de dados em questão.
5. Calcular o coeficiente de correlação $\rho_{RN}(n)$ e $\rho_{AP}(n)$ entre os pesos $\mathbf{P}(n)$ e os pesos padrões \mathbf{P}_{RN} de respiração normal e \mathbf{P}_{AP} de apnéia. Neste passo, pode-se considerar somente parte dos pesos (ver explicação no texto);
6. Fazer $n \leftarrow n + 1$.
7. Selecionar uma nova janela de dados compreendida entre as amostras $k_0 = \Delta \cdot n + 1$ e $k_f = \Delta \cdot n + L$, em que Δ é o incremento do deslocamento da janela móvel.
8. Retornar ao passo 4 enquanto o monitoramento for necessário.

Conforme pode ser visto acima, a comparação entre pesos estimados e aqueles considerados padrões será efetuada por meio da análise do coeficiente de correlação entre eles. Os pesos-padrões serão calculados nas faixas **rn1** e **ap1** (ver tabela 3). A validação do procedimento será efetuada nas faixas **nb2**, **ap2** (ver tabela 3). Nos exemplos mostrados aqui, $L=300$ e $\Delta=10$.

A Figura 8 apresenta curvas de índices de correlação com pesos-padrões normal (linha contínua) e apnéia (linha pontilhada), ao longo de janelas deslizantes. O intervalo de confiança $[-2\sigma/\sqrt{N} \quad +2\sigma/\sqrt{N}]$ aparece evidenciado. Pode-se notar que a correlação entre pesos no caso da faixa normal avaliada (**nb2**) e os pesos padrões normal e apnéia evidenciam que há maior correlação com pesos de respiração normal, ou seja, para maioria de n , $\rho_{RN}(n) > \rho_{AP}(n)$. O caso contrário pode ser visto na segunda figura, onde a correlação com pesos da faixa padrão de apnéia parece maior (**ap1** e **ap2**). Infelizmente, neste caso, a diferenciação entre as curvas não é possível em geral, mas somente em alguns curtos trechos em que tais curvas não estão na faixa estatisticamente nula do intervalo de confiança (ver

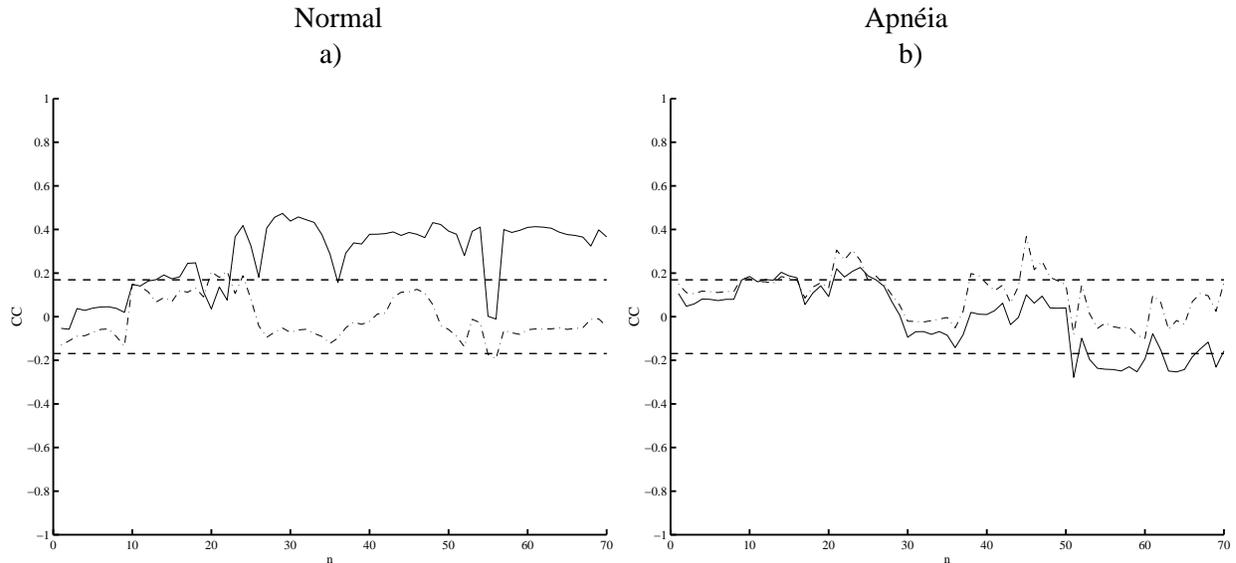


Figura 8: Coeficientes de correlação entre pesos-padrões obtidos em janela normal $n1$ (linhas contínuas) e em janela de respiração periódica, $ap1$ (linhas pontilhadas). a) $n \times \rho_{NB}(n)$ calculado na faixa $nb2$, e b) $n \times \rho_{AP}(n)$, calculado na faixa $ap2$.

intervalos $\approx [20 \ 25]$ e $\approx [43 \ 48]$). A largura desses trechos é de aproximadamente 6 atrasos. Como o incremento é de $\Delta = 10$, tais trechos correspondem a 60 observações de cada série ou, em outras palavras, 30 segundos.

Para analisar melhor o quadro apresentado, a mesma análise pode ser feita considerando isoladamente cada variável y_R , y_{SOS} e y_{VFC} . Os pesos do NFN estão associados a cada nodo de entrada. Como há 11 nodos para a variável y_R (atrasos de 10 a 20), 11 para a variável y_{VFC} (atrasos de 10 a 20) e 5 para variável y_{SOS} (atrasos de 1 a 5), pode-se subdividir os pesos em três subconjuntos, $\mathbf{P}^{(R)}$, $\mathbf{P}^{(VFC)}$ ou $\mathbf{P}^{(SOS)}$, isto é, os associados a cada variável y_R , y_{VFC} e y_{SOS} , respectivamente. Da mesma forma, coeficientes de correlação para cada segmento y_R , y_{VFC} ou y_{SOS} podem ser calculados.

As Figura 9 mostra a correlação entre os pesos de cada segmento mencionado, sendo os gráficos a) e b) a correlação de pesos do segmento associado a y_R , c) e d), a y_{SOS} e e) e f), a y_{VFC} . À esquerda são mostrados os coeficientes para o caso da faixa normal ($nb2$) e à direita, o caso da faixa apnéia ($ap2$). As figuras mostram que no caso normal, os pesos associados à variável y_{VFC} são suficientes para o diagnóstico de respiração normal (gráfico e). No caso apnéia, o diagnóstico pode ser feito de forma mais clara a partir dos pesos associados a y_{SOS} (gráfico d).

Percebe-se que mais estudos a respeito são necessários para desenvolver uma ferramenta de monitoramento ou de diagnóstico automático, porém, acredita-se, a partir destes resultados, que uma análise baseada no procedimento descrito pode ser útil para atingir tal objetivo. Faixas de apnéia intermitente também foram testadas com a metodologia apresentada aqui, e os resultados indicam mais correlação com pesos da faixa normal padrão.

É importante notar que os resultados mostrados aqui são preliminares e referentes a um estudo de caso. Um estudo mais elaborado e com maior número de pacientes envolvidos é fundamental para analisar a generalidade do procedimento.

6 Conclusão

Este trabalho, apresentou dois aspectos relacionados à modelagem e análise de um conjunto de dados fisiológicos, a saber: i) modelagem multivariável usando a representação *neo fuzzy neuron* (NFN) e ii) definição preliminar de uma metodologia para monitoramento do paciente usando essa representação matemática.

Os dados utilizados são de domínio público e são compostos de três séries temporais de 34000 valores cada. Os dados medidos foram: respiração (movimento torácico), saturação de oxigênio no sangue e variabilidade da frequência cardíaca.

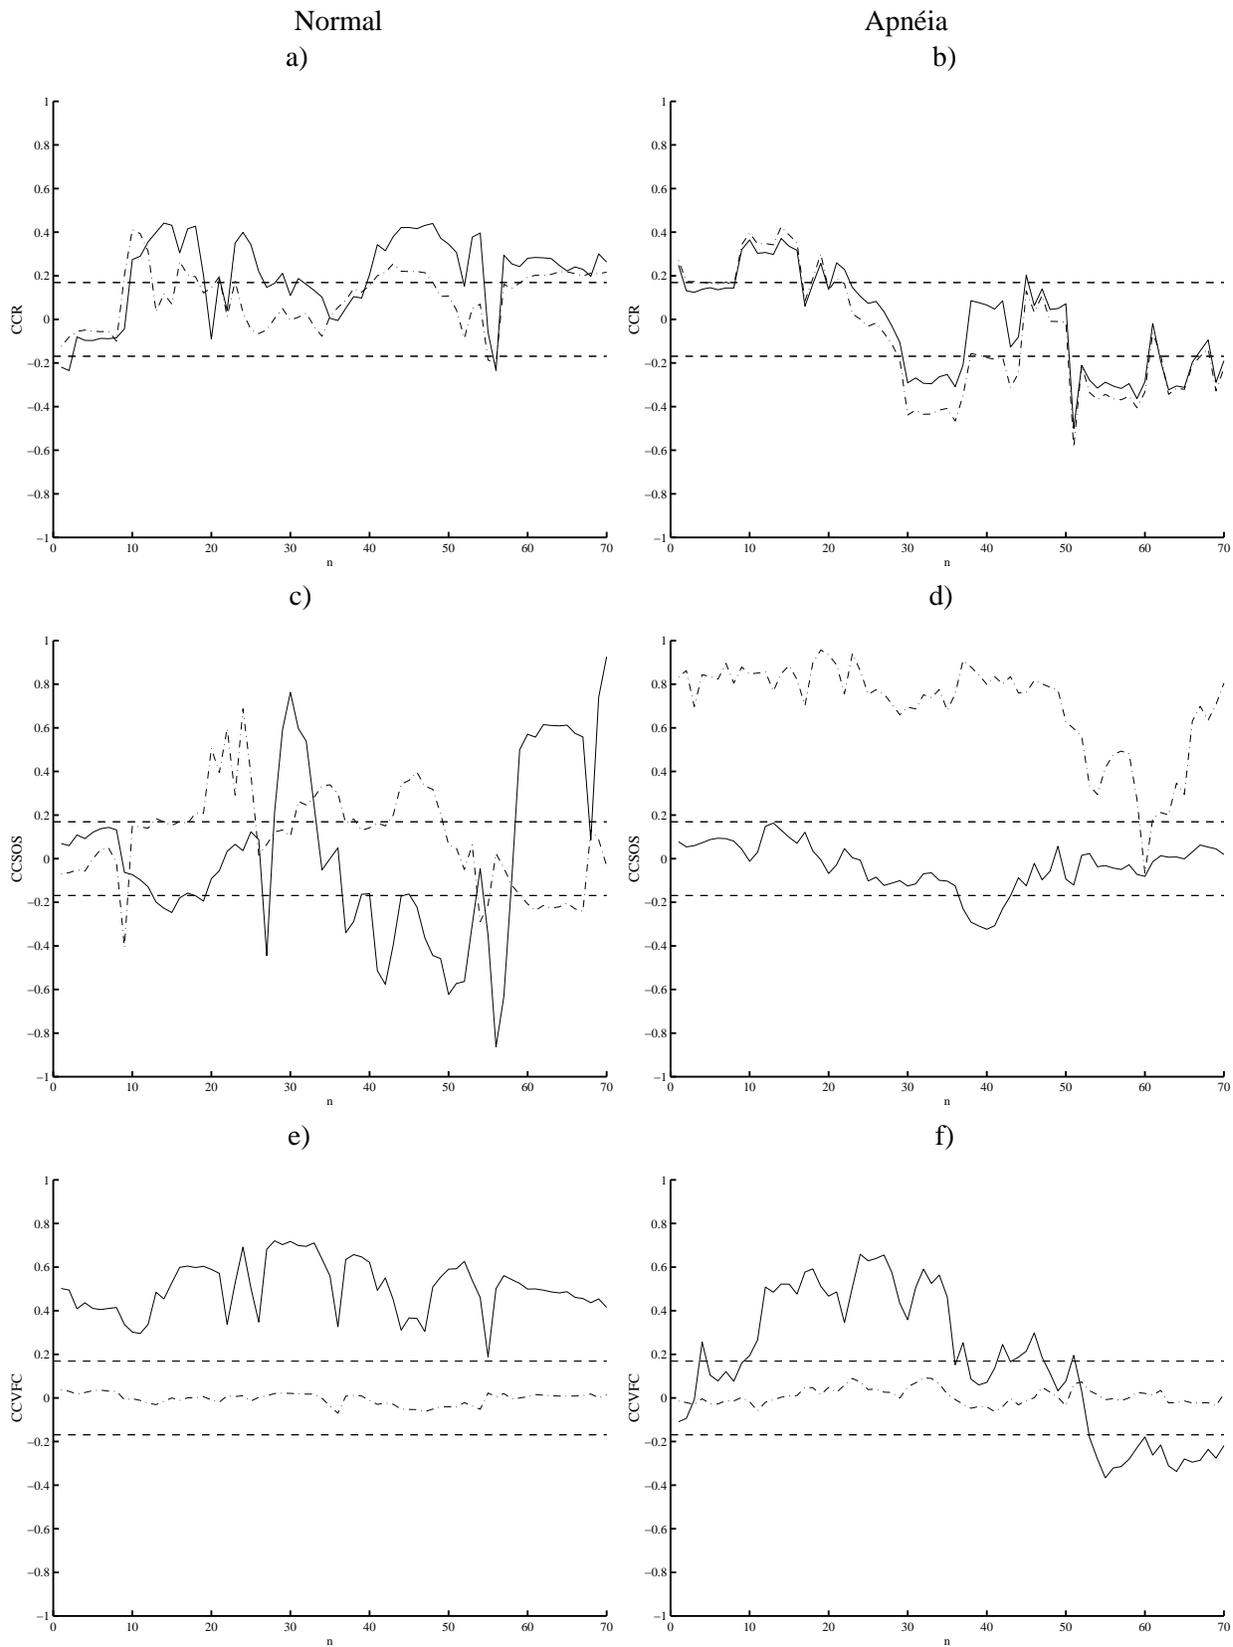


Figura 9: Esta figura foi obtida de forma análoga à Figura 8, porém neste caso, estão sendo empregados apenas segmentos do conjunto total de pesos, obtidos segundo a variável que estão associados: a) e b) y_R , c) e d) y_{SOS} e e) e f) y_{VFC} . Nos gráficos à esquerda, os coeficientes são relativos à faixa normal nb2, e à direita, à faixa ap2.

Dentre os aspectos apresentados, os principais resultados obtidos foram: i) o desempenho dos modelos NFN foi bom, com índice RMSE abaixo de 0,7 e em algumas janelas abaixo de 0,5. Isso foi obtido para predição livre em janelas com 150 amostras, o que sugere uma boa capacidade de generalização. Esses índices, apesar de serem um pouco piores do que para outras representações testadas, são encorajadores tendo em vista a facilidade de se implementar este tipo de rede. Na linha de classificação de padrão respiratório, foi proposto um procedimento baseado no índice de correlação entre os pesos de três NFN's. Com respeito a esse procedimento concluiu-se que: i) correlacionando-se todos os pesos dos NFN's dificulta a classificação. Melhoras foram observadas quando apenas os pesos relativos a uma entrada são analisados por vez. Especificamente com respeito a isso observou-se que ii) os pesos relativos à entrada de saturação de oxigênio no sangue são os que permitem uma melhor classificação no caso de apnéia e os de frequência cardíaca no caso de respiração normal. Isso parece sugerir que um procedimento de monitoramento se beneficiaria do uso de ambas as variáveis. Os resultados devem ser considerados preliminares, devido à complexidade do problema em questão, e devido ao fato de que foram obtidos somente para uma massa de dados de um único indivíduo.

Trabalhos futuros deverão investigar a capacidade de detecção precoce de apnéia utilizando NFN e outras representações matemáticas.

Agradecimentos

Este projeto foi parcialmente financiado pelo CNPq e FAPEMIG. Os autores agradecem ao Sr. Ubiratan Freitas por valiosa assistência computacional.

Referências

- [1] C. Keyl, P. Lemberger, M Pfeifer, K. Hochmuth, and P. Geisler. Heart rate variability in patients with daytime sleepiness suspected of having sleep apnoea syndrome: a receiver-operating characteristic analysis. *Clinical Science*, 92:335–343, 1997.
- [2] M. Hilton, R. Bates, K. Godfrey, and R. Cayton. A new application for heart rate variability: diagnosing the sleep apnoea syndrome. *Computers in Cardiology*, 25:1–4, 1998.
- [3] M. Glos, D. Romberg, I. Fietze, J. Rötting, M. Knobe, and C. Witt. Analysis of heart rate and blood pressure variability during nasal continuous positive airway pressure therapy in patients with obstructive sleep apnea. *Computers in Cardiology*, 26:603–605, 1999.
- [4] M.F. Hilton, R.A. Bates, K.R. Godfrey, M.J. Chappell, and R.M. Cayton. Evaluation of frequency and time-frequency spectral analysis of heart rate variability as a diagnostic marker of the sleep apnoea syndrome. *Medical & Biological Engineering & Computing*, 37(6):760–769, 1999.
- [5] F. Roche, J. Gaspoz, I. Court-Fortune, P. Minini, V. Pichot, D. Duverney, F. Costes, J. Lacour, and J. Barthelemy. Screening of obstructive sleep apnea syndrome by heart rate variability analysis. *Circulation*, 100(13):1411–1415, 1999.
- [6] M. Schrader, C. Zywietz, V. Einem, B. Widiger, and G. Joseph. Detecting of sleep apnea in single channel ecgs from the PhysioNet database. *Computers in Cardiology*, 27:263–266, 2000.
- [7] U. Wiklund, B.O. Olofsson, K. Franklin, H. Blom, P. Bjerle, and U. Niklasson. Autonomic cardiovascular regulation in patients with obstructive sleep apnoea: a study based on spectral analysis of heart rate variability. *Clinical Physiology*, 20(3):234–241, 2000.
- [8] G.B. Moody, R.G. Mark, A.L. Goldberger, and T. Penzel. Stimulating rapid research advances via focused competition: The computers in cardiology challenge 2000. In *Computers in Cardiology*. IEEE Press, 2000.
- [9] S. Reisch, H. Steltner, J. Timmer, C. Renotte, and J. Guttmann. Early detection of upper airway obstructions by analysis of acoustical respiratory input impedance. *Biological Cybernetics*, 81(1):25–37, 1999.

- [10] S. Reisch, J. Timmer, H. Steltner, K. H. Ruhle, J. H. Ficker, and J. Guttmann. Detection of obstructive sleep apnea by analysis of phase angle using the forced oscillation signal. *Resp. Physiol.*, 123(1–2):87–99, 2000.
- [11] S. Reisch, J. Daniuk, H. Steltner, K. H. Ruhle, J. Timmer, and J. Guttmann. Detection of sleep apnea with the forced oscillation technique compared to three standard polysomnographic signals. *Respiration*, 67(5):518–525, 2000.
- [12] D. R. Rigney, A. L. Goldberger, W. C. Ocasio, Y. Ichimaru, G. B. Moody, and R. G. Mark. Multi-channel physiological data: Description and analysis. In A. A. Weigend and N. A. Gershenfeld, editors, *Time Series Prediction*, pages 105–129. Addison-Wesley, New York, 1994.
- [13] P.C. Deegan and W.T. McNicholas. Pathophysiology of obstructive sleep apnea. *European Respiration Journal*, 8:1161–1178, 1995.
- [14] K.P. Strohl and S. Redline. Recognition of obstructive sleep apnea. *Am. J. Respir. Crit. Care Medicine*, 154:279–289, 1996.
- [15] L. A. Aguirre. *Introdução à Identificação de Sistemas: Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. Editora UFMG, Belo Horizonte, 2000.
- [16] V. C. Barros. *Processamento de sinais biomédicos usando modelos polinomiais NARMAX multivariáveis*. Dissertação de Mestrado, PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil, 1997.
- [17] L. A. Aguirre, V. C. Barros, and A. V. P. Souza. Nonlinear multivariable modeling and analysis of sleep apnea time series. *Computers in Biology and Medicine*, 29(3):207–228, 1999.
- [18] L. Cao and A. Mees. Deterministic structure in multichannel physiological data. *Int. J. Bifurcation and Chaos*, 10(12):2767–2780, 2000.
- [19] P. Varady, T. Micsik, S. Benedek, and Z. Benyó. A novel method for the detection of apnea and hypopnea events in respiration signals. *IEEE Trans. Biomedical Engineering*, 49(9):936–942, 2002.
- [20] T. Yamakawa, E. Uchino, T. Miki, and T. Kusanagi. A neo fuzzy neuron and its applications to system identification and predictions to system behavior. In *Proceedings of the 2nd IIZUKA*, pages 477–483, Japan, 1992.
- [21] W. M. Caminhas and F.A.C. Gomide. A fast learning algorithm for neofuzzy networks. In *8th IPMU-2000*, number 1 in 1, pages 1784 – 1790, 2000. Madrid, Spain.
- [22] S. A. Billings, S. Chen, and M. J. Korenberg. Identification of MIMO nonlinear systems using a forward-regression orthogonal estimator. *Int. J. Control*, 49(6):2157–2189, 1989.
- [23] W.M. Caminhass, F.A.C. Gomide, and H.M.F. Tavares. Detecção de falhas em sistemas dinâmicos: Abordagem baseada em redes neurofuzzy com aprendizado *on-line*. In *V Congresso Brasileiro de Redes Neurais*, pages 613–618, Rio de Janeiro, 2001. Anais do V Congresso Brasileiro de Redes Neurais.