

DETECÇÃO DE APNÉIA DURANTE O SONO UTILIZANDO MODELOS IDENTIFICADOS

P. M. Fagundes, D. J. Oliveira e L. A. Aguirre*

Laboratório de Modelagem, Análise e Controle de Sistemas Não-Lineares (MACSIN)
Universidade Federal de Minas Gerais/*Departamento de Engenharia Eletrônica, Belo Horizonte,
Brasil

e-mail: pliniomfagundes@yahoo.com.br

Abstract: This work presents a study about the viability of sleep apnea detection by the identified model Jacobian matrix characteristics. Specifically, the Jacobian matrix eigenvalues position in the complex plane is used to classify the patient breathing pattern. For the modeling process, three typical signals are used: Heart Rate Variability (HRV), Respiration (R) and Blood Oxygen Saturation (BOS), with the R and HRV signals as the model inputs and the BOS signal as its output. The nonlinear identified model is obtained by polynomial multivariable NARMAX modeling and the behavior of the linear Jacobian matrix eigenvalues derived from each iteration is analyzed to detect the eminence of sleep apnea.

Palavras Chaves: Apnéia do sono, identificação de sistemas, monitorização.

Introdução

Nas duas últimas décadas, grande atenção vem sendo dada ao estudo das causas [1] e conseqüências [2] do distúrbio fisiológico denominado apnéia durante o sono. Em função disso, cada vez mais são realizados estudos com o intuito de detectar e/ou diagnosticar essa síndrome [3] e [4]. Vários trabalhos a respeito da modelagem de sistemas biológicos com o objetivo de representar a evolução do paciente em direção a um quadro de apnéia durante o sono [5] podem ser encontrados na literatura.

De forma simplificada, apnéia durante o sono consiste em um distúrbio fisiológico que provoca repetidas paradas respiratórias durante o sono. A duração dessas paradas pode variar tipicamente de 20 segs a 1 min. Durante esse período de tempo, o nível de Saturação de Oxigênio no Sangue (SOS) cai até que o paciente respire profundamente 4 ou 5 vezes, e depois pare de respirar novamente. Configura-se então um estado cíclico entre respiração normal e parada respiratória.

O objetivo deste trabalho consiste em analisar a viabilidade da previsão do quadro de apnéia durante o sono por meio do comportamento dos autovalores da matriz Jacobiana do modelo identificado, mais especificamente o módulo do seu maior autovalor. Além

disso, este trabalho apresenta sugestões para a construção de modelos que sejam úteis na classificação.

Materiais e Métodos

A base de dados utilizada para a elaboração deste trabalho consiste em três séries temporais de 34000 pontos. Essas séries são relativas a medições de três sinais fisiológicos amostrados a 2 Hz obtidas de um paciente do sexo masculino de 49 anos: Respiração (R), Variabilidade de Frequência Cardíaca (VFC), e Saturação de Oxigênio no Sangue (SOS). Maiores informações a respeito da sua aquisição e processamento podem ser encontradas em [6]. A Figura 1 ilustra o as três séries.




Figura 1 - Séries temporais (s). a) Variabilidade de Frequência Cardíaca; b) Respiração; c) Saturação de Oxigênio no Sangue.

Essa base de dados foi dividida em janelas de tempo correspondentes a três quadros clínicos distintos: Respiração Normal (RN), Apnéia Intermitente (AI) e Apnéia (AP) [6]. A Tabela 1 representa um mapeamento de janelas de tempo comprovadamente correspondentes a aos quadros de RN, AI ou AP.

Tabela 1: Mapeamento de quadros clínicos em função do intervalo de tempo em segs.

Quadro Clínico	Intervalo de tempo (s)	Código
Respiração Normal	6500 a 6800	RN1
	6801 a 7000	RN2
	9350 a 9550	RN3
Apnéia Intermitente	4600 a 4800	AI1
	14160 a 14560	AI2
	14560 a 14760	AI3
Apnéia	1700 a 1900	AP1
	16500 a 16800	AP2
	16801 a 17000	AP3

As Figuras 2, 3 e 4 ilustram de forma mais detalhada o comportamento de cada um dos três sinais (VFC, R e SOS) para janelas de tempo correspondentes aos quadros clínicos de interesse.




Figura 2 - Janela correspondente ao quadro de Respiração Normal (RN1). a) VFC; b) R; c) SOS.




Figura 3 - Janela correspondente ao quadro de Apnéia Intermitente (AI1). a) VFC; b) R; c) SOS.




Figura 4 - Janela correspondente ao quadro de Apnéia (AP1). a) VFC; b) R; c) SOS.

O primeiro passo para a implementação do método de detecção de apnéia durante o sono proposto por este trabalho consiste na identificação de um modelo NARMAX (*Nonlinear Autoregressive Moving Average with Exogenous Inputs*) polinomial para o sistema representado pelos sinais FC, R e SOS. Um modelo NARMAX polinomial multivariável pode ser representado por [7]

$$\mathbf{y}(k) = f^l[\mathbf{y}(k-1), \dots, \mathbf{y}(k-n_y), \dots, \mathbf{u}(k-\tau_d), \dots, \mathbf{u}(k-n_u), \dots, \mathbf{e}(k-1), \dots, \mathbf{e}(k-n_e)] + \mathbf{e}(k) \quad (1)$$

em que

$$\mathbf{y}(k) = \begin{bmatrix} y_1(k) \\ y_2(k) \\ \vdots \\ y_n(k) \end{bmatrix} \quad \mathbf{u}(k) = \begin{bmatrix} u_1(k) \\ u_2(k) \\ \vdots \\ u_r(k) \end{bmatrix} \quad \mathbf{e}(k) = \begin{bmatrix} e_1(k) \\ e_2(k) \\ \vdots \\ e_m(k) \end{bmatrix}$$

Em (1), n_u , n_y e n_e representam o atraso máximo considerado para os sinais de entrada, saída e ruído, respectivamente e τ_d representa o atraso da resposta do sistema medido em unidades de intervalos de amostragem, $T_s = 0,5$ s. Além disso, $\mathbf{u}(k)$ e $\mathbf{y}(k)$ são vetores de tamanho r e n que representam as séries temporais dos sinais de entrada e saída do sistema, respectivamente, obtidas amostrando-se $\mathbf{u}(t)$ e $\mathbf{y}(t)$ segundo intervalos de amostragem T_s . $\mathbf{e}(k)$ representa incertezas, possíveis sinais de ruído, dinâmicas não modeladas, etc, e $f^l[\cdot]$ é alguma função não-linear de $\mathbf{u}(k)$, $\mathbf{y}(k)$ e $\mathbf{e}(k)$. Neste trabalho $f^l[\cdot]$ é considerada um polinômio de grau de não-linearidade igual a 2, mas outras representações são encontradas na literatura. O algoritmo de identificação de modelos NARMAX polinomial é descrito detalhadamente em [7].

A equação (1) representa um sistema multivariável com r sinais de entrada e n sinais de saída. O modelo identificado neste trabalho possui um sinal de saída $\mathbf{y}(k)$

(SOS), e dois sinais de entrada $u_1(k)$ e $u_2(k)$ (VFC e R respectivamente) o que implica $r = 2$ e $n = 1$.

Para a classificação dos vários modelos encontrados, utilizou-se o índice RMSE (*Root Mean Square Error*), que pode ser representado por

$$RMSE = \frac{\sqrt{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}}{\sqrt{\sum_{k=1}^N (y(k) - \bar{y})^2}} \quad (2)$$

em que

$$\begin{aligned} \hat{y}(k) &= \text{Sinal de saída estimado pelo modelo} \\ \bar{y} &= \text{Média do sinal medido } y(k) \end{aligned}$$

O RMSE qualifica o modelo quanto à sua capacidade de prever o sinal em relação ao predictor trivial de média. Quanto menor for o índice RMSE tanto melhor o modelo em questão explica o sinal medido em relação ao valor médio do sinal.

O próximo passo na implementação do método descrito neste trabalho consiste em determinar-se a matriz Jacobiana do modelo identificado (1). A matriz Jacobiana de um modelo (1) pode ser definida como [7]:

$$J = \begin{bmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \\ \frac{\partial f}{\partial y(k-n_y)} & \frac{\partial f}{\partial y(k-n_y+1)} & \frac{\partial f}{\partial y(k-n_y+2)} & \dots & \frac{\partial f}{\partial y(k-1)} \end{bmatrix} \quad (3)$$

O método de detecção de apnéia durante o sono descrito neste trabalho consiste na análise do comportamento dos autovalores da matriz Jacobiana do modelo identificado, mais especificamente no módulo do seu maior autovalor.

Resultados

Dentre os melhores modelos encontrados, destaca-se o seguinte:

$$\begin{aligned} y_1(k) = & +1.4455 y_1(k-1) - 0.72028 y_1(k-5) \\ & - 0.18762 y_1(k-3) + 0.16886 \times 10^{-4} \\ & - 0.20098 \times 10^{-1} u_1(k-9) u_1(k-1) \\ & + 0.14217 \times 10^{-6} u_2(k-10) u_2(k-3) \\ & + 0.79815 \times 10^{-4} y_1(k-5) y_1(k-2) \\ & + 0.29836 \times 10^{-3} u_2(k-8) u_1(k-6) \\ & - 0.78266 \times 10^{-8} u_2(k-9) u_2(k-3) \\ & + 0.29558 \times 10^{-1} u_1(k-8) u_1(k-1) \\ & - 0.48452 \times 10^{-4} y_1(k-2) y_1(k-1) \\ & - 0.28306 \times 10^{-3} u_2(k-8) u_1(k-7) \\ & - 0.11191 \times 10^{-1} u_1(k-5) u_1(k-1) \\ & - 0.46632 \times 10^{-7} u_2(k-3) u_2(k-3) \\ & + 0.72532 \times 10^{-7} u_2(k-5) u_2(k-1) \\ & + \sum_{i=1}^{20} \hat{\Theta}_i E(k-i) \end{aligned} \quad (4)$$

utilizando-se AI2 como janela de identificação e toda a base de dados (34000 pontos) como janela de validação.

Uma vez que o modelo identificado (4) trata-se de um modelo de 5ª ordem ($n_y = 5$), sua matriz Jacobiana é 5×5 e portanto, possui 5 autovalores. Com isso, a última linha da matriz Jacobiana (3) do modelo identificado é representada por

$$\begin{aligned} \frac{\partial y_1(k)}{\partial y_1(k-5)} &= -0.72028 + 0.79815 \times 10^{-4} y_1(k-2); \\ \frac{\partial y_1(k)}{\partial y_1(k-4)} &= 0; \\ \frac{\partial y_1(k)}{\partial y_1(k-3)} &= -0.18762; \\ \frac{\partial y_1(k)}{\partial y_1(k-2)} &= +0.79815 \times 10^{-4} y_1(k-5) - 0.48452 \times 10^{-4} y_1(k-1); \\ \frac{\partial y_1(k)}{\partial y_1(k-1)} &= +1.44550 - 0.48452 \times 10^{-4} y_1(k-2); \end{aligned} \quad (5)$$

De posse da matriz Jacobiana do modelo identificado, resta analisar o comportamento do seu maior autovalor (em módulo) à medida em que a matriz J é avaliada ao longo de todos os pontos pertencentes à base de dados. A Figura 5 ilustra tal comportamento.




Figura 5: Módulo do maior autovalor de J em função do tempo (s) para toda a base de dados.

A Figura 6 apresenta de forma mais detalhada o comportamento do maior autovalor em módulo de J para três das janelas de tempo discriminadas na Tabela 1 - mais especificamente, as mesmas ilustradas nas Figuras 2 (RN1), 3 (AI1) e 4 (AP1) respectivamente.




Figura 2: Comportamento do maior autovalor em módulo de J para janelas de tempo correspondentes a quadros clínicos de interesse. a) Respiração Normal; b) Apnéia Intermitente; c) Apnéia.

