

TRABALHO DE GRADUAÇÃO

Identificação de sistemas fisiológicos utilizando funções de base ortonormais de Laguerre

Autor: Vinícius Hideki Endo
Orientadora: Prof. Flavia Maria Guerra de Sousa Aranha de Oliveira

Brasília, julho de 2019

UNIVERSIDADE DE BRASÍLIA

FACULDADE DE TECNOLOGIA

UNIVERSIDADE DE BRASÍLIA
Faculdade de Tecnologia

TRABALHO DE GRADUAÇÃO

IDENTIFICAÇÃO DE SISTEMAS FISIOLÓGICOS UTILIZANDO FUNÇÕES DE BASE ORTONORMAIS DE LAGUERRE

Vinícius Hideki Endo

Relatório submetido ao curso de graduação em Engenharia Elétrica da Universidade de Brasília,
como requisito parcial para obtenção do título de Engenheiro Eletricista

Banca Examinadora

Prof. Dra. Flavia M. G. S. A. Oliveira
UnB/ ENE
Orientadora

Prof. Dr. João Luiz Azevedo de Carvalho
UnB/ ENE
Professor Convidado

Prof. Mestre Lélío Ribeiro Soares Júnior
UnB/ ENE
Professor Convidado

Dedico este trabalho a minha família, em especial aos meus pais. Obrigado pelo apoio incondicional que vocês sempre me deram.

AGRADECIMENTOS

Agradeço primeiramente à Professora Flávia, que me orientou durante este trabalho sempre de maneira muito atenciosa e compreensiva, compartilhando seu conhecimento e dando dicas e sugestões que foram fundamentais para a realização deste trabalho.

Agradeço aos meus pais Ricardo e Miriam, por todo o suporte que vocês me proporcionam, não somente no aspecto acadêmico, mas no aspecto pessoal também. Graças a vocês eu tive as oportunidades que me fizeram ser quem sou, e sou muito grato por tudo.

Agradeço a todos os amigos envolvidos nessa longa jornada. Os momentos que vivemos jamais serão esquecidos.

Agradeço à querida Marcela, por todo o seu apoio, ajuda e companheirismo. Mesmo de longe, sua presença na minha vida é importantíssima.

Por último, mas não menos importante, agradeço a todos os professores e funcionários que fizeram parte da minha formação.

Vinícius Hideki Endo

RESUMO

O presente trabalho consiste em um estudo da aplicabilidade da série de Volterra na modelagem de sistemas não-lineares. Uma comparação entre dois dos métodos de resolução da série, o algoritmo de correlação cruzada de Lee-Schetzen e a técnica de expansão de Laguerre foi feita na primeira parte, de onde concluiu-se que o método de Laguerre é mais eficiente para este tipo de sistema. A simulação de um sistema SISO, com os sinais de entrada e de saída sendo representados por sinais de respiração e de ECG foi feita na segunda parte. A base de dados utilizada era composta de 8 indivíduos, divididos em um grupo saudável e um com apneia. Os resultados e parâmetros extraídos indicaram que a série de Volterra é uma boa ferramenta para a modelagem deste tipo de sistema, visto que a análise das simulações apresentou significado fisiológico quando comparado com outros estudos.

Palavras-chave: modelamento de sistemas não-lineares, modelo de Volterra, apneia do sono

ABSTRACT

The present work consists in a study of the applicability of the Volterra series in the modelling of non-linear systems. A comparison between two of its resolution methods, the Lee-Schetzen cross-correlation method and the Laguerre expansion technique, was made in the first part, where it was concluded that the Laguerre method is more efficient for this type of system. The simulation of a SISO system, with the input and output signals being represented by respiration and ECG signals was made in the second part. The database utilized was composed by 8 individuals, divided in a healthy group and in an apneic one. The results and extracted parameters indicated that the Volterra series is a good tool for modelling this type of system, seeing that the analysis of the simulations showed physiological meaning when compared to similar studies.

Keywords: non-linear system modeling, Volterra model, sleep apnea

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Contextualização e objetivos do trabalho	1
1.2	Estruturação do trabalho	2
2	REVISÃO BIBLIOGRÁFICA	3
2.1	Conceitos fisiológicos.....	3
2.1.1	Apneia	3
2.1.2	Sistema nervoso autônomo.....	3
2.1.3	Variabilidade da frequência cardíaca.....	5
2.2	Conceitos matemáticos	5
2.2.1	Modelagem de sistemas	6
2.2.2	Série de Volterra	6
2.2.3	Série de Wiener.....	8
2.2.4	Algoritmo de Lee-Schetzen	10
2.2.5	Expansão de Laguerre.....	11
3	METODOLOGIA.....	16
3.1	Base de dados fisiológicos	16
3.2	Pré-processamento dos sinais fisiológicos	17
3.2.1	Seleção dos dados	17
3.2.2	Conversão dos dados.....	18
3.2.3	Filtragem dos dados	19
3.2.4	Extração de variáveis	20
3.2.5	Alinhamento e reamostragem	21
3.3	Simulações computacionais	22
3.4	Análise estatística	23
4	RESULTADOS E DISCUSSÕES	25
4.1	Comparação entre os métodos.....	25
4.1.1	Algoritmo de Lee-Schetzen	26
4.1.2	Expansão de Laguerre.....	27
4.1.3	Análise da comparação	28
4.2	Discussão dos resultados.....	29

5	CONCLUSÕES	36
6	REFERÊNCIAS BIBLIOGRÁFICAS.....	37

LISTA DE FIGURAS

Figura 2.1 – Efeitos dos ramos do SNA no organismo. Fonte: (ANATOMIA DO CORPO HUMANO) ...4	4
Figura 2.2 – Sinal de ECG e interpretação fisiológica das ondas. Fonte: Adaptado de (SHEA)5	5
Figura 2.3 – Esquemático da implementação do algoritmo de Lee-Schetzen para estimação dos kernels de Wiener. Fonte: (VAN DRONGELEN, 2010) 11	11
Figura 2.4 – Representação em diagrama de blocos para a saída de um sistema modelada por filtros lineares e uma não linearidade. Fonte: (MARMARELIS, 2004)..... 12	12
Figura 2.5 – Funções de Laguerre discretas no tempo de ordem 4 (linha sólida), 8 (pontilhada), 12 (tracejada) e 16 (ponto e traço) para $\alpha = 0,2$. Fonte: (MARMARELIS, 2004)..... 14	14
Figura 2.6 – Funções de Laguerre de 4ª ordem para $\alpha = 0,1$ (linha sólida), $\alpha = 0,2$ (pontilhada) e $\alpha = 0,4$ (tracejada). Fonte: (MARMARELIS, 2004)..... 15	15
Figura 3.1 – Comparação entre os sinais de respiração 18	18
Figura 3.2 – De cima para baixo: sinal de ECG antes da filtragem e após a filtragem 19	19
Figura 3.3 – De cima para baixo: exemplo de marcação dos picos R e sinal de RRI extraído a partir da marcação..... 20	20
Figura 3.4 – Detalhe do ponto inicial dos sinais de RRI e respiração antes do alinhamento 21	21
Figura 3.5 - Detalhe do ponto inicial dos sinais de RRI e respiração depois do alinhamento 22	22
Figura 3.6 – Diagrama de blocos referente ao sistema considerado na simulação..... 23	23
Figura 4.1 - De cima para baixo: sinal de entrada (respiração, em L) e sinal de saída (intervalo RR, em ms) para um indivíduo do grupo SAOS 25	25
Figura 4.2 – Saída real (em preto) e saída estimada (em vermelho) obtida através do algoritmo de Lee-Schetzen para um indivíduo do grupo SAOS..... 26	26
Figura 4.3 – De cima para baixo: kernel de primeira e kernel de segunda ordem obtidos através do algoritmo de Lee-Schetzen para um indivíduo do grupo SAOS..... 27	27
Figura 4.4 - Saída real (em preto) e saída estimada (em vermelho) obtida através da expansão de Laguerre para um indivíduo do grupo SAOS 28	28
Figura 4.5 - De cima para baixo: kernel de primeira e kernel de segunda ordem obtidos através da expansão de Laguerre para um indivíduo do grupo SAOS 28	28
Figura 4.6 - De cima para baixo: sinal de entrada (respiração, em L) e sinal de saída (intervalo RR, em ms) para um indivíduo do grupo Controle..... 30	30
Figura 4.7 - Saída real (em preto) e saída estimada (em vermelho) obtida através da expansão de Laguerre para um indivíduo do grupo Controle..... 30	30

Figura 4.8 - De cima para baixo: kernel de primeira e kernel de segunda ordem obtidos através da expansão de Laguerre para um indivíduo do grupo Controle.....	31
Figura 4.9 – De cima para baixo: sinal de RRI (em preto) e valor médio (em vermelho) para um indivíduo do grupo SAOS e do grupo Controle	33
Figura 4.10 – Da esquerda para a direita: gráfico de erro utilizando o modelo de 1ª ordem e utilizando o modelo de 2ª ordem	34
Figura 4.11 – Da esquerda para a direita: kernel k1 para um indivíduo do grupo SAOS e do grupo Controle.....	35
Figura 4.12 – Da esquerda para a direita: kernel k2 para um indivíduo do grupo SAOS e para o grupo Controle.....	35

LISTA DE TABELAS

Tabela 1 – Divisão dos indivíduos por grupo de acordo com o índice de apneia.....	23
Tabela 2 – Resumo dos parâmetros encontrados para cada grupo	32

LISTA DE ABREVIATURAS

SISO	<i>Single Input, Single Output</i>
ECG	Eletrocardiograma
SAOS	Síndrome da Apneia Obstrutiva do Sono
AHI	<i>Apnea-Hypopnea Index</i> (Índice de Apneia e Hipopneia)
SNA	Sistema Nervoso Autônomo
VFC	Variabilidade da Frequência Cardíaca
RRI	R-R Interval (Intervalo R-R)
LET	<i>Laguerre Expansion Technique</i> (Técnica de Expansão de Laguerre)
CRSIDLab	<i>Cardiorrespiratory System Identification Lab</i>
IRM	<i>Impulse Response Magnitude</i> (Magnitude da Resposta ao Impulso)
KM	<i>Kernel Magnitude</i> (Magnitude do Kernel)
NMSE	<i>Normalised Mean Square Error</i> (Erro Quadrático Médio Normalizado)

1 INTRODUÇÃO

Este capítulo trata da apresentação do escopo do trabalho, reunindo a motivação e os objetivos do estudo, assim como a estruturação do documento.

1.1 Contextualização e objetivos do trabalho

A modelagem matemática configura uma ferramenta fundamental para auxiliar na análise do comportamento dos mais diversos tipos de sistemas. Além disso, ela configura uma maneira mais barata e segura do que os testes reais. Em caráter teórico, trabalha-se muito com os sistemas lineares, devido a sua simplicidade. Porém, em caráter prático, a maior parte dos sistemas reais é caracterizado por um comportamento não-linear. Um dos métodos mais conhecidos e utilizados para a modelagem de sistemas com essa característica é através da Série de Volterra. Serão estudados os seus dois métodos principais de resolução, o algoritmo de correlação cruzada de Lee-Schetzen e a técnica de expansão de Laguerre.

A modelagem de sistemas não-lineares pode ser empregada em diversas áreas, para os mais diferentes propósitos. Na área da engenharia biomédica por exemplo, pode ser utilizada para obter informações fisiológicas de indivíduos a partir de dados como ECG (eletrocardiograma) e respiração, auxiliando em potenciais diagnósticos e no monitoramento não-invasivo de pacientes. Para verificar a aplicabilidade desta ferramenta, o presente estudo utilizará sinais fisiológicos de indivíduos diagnosticados com Síndrome Obstrutiva da Apneia do Sono (SAOS), um distúrbio que causa a interrupção ou redução da respiração durante o sono, e de indivíduos saudáveis. A partir da construção de um modelo não-linear, serão extraídos os parâmetros relevantes para que seja feita uma comparação entre os indivíduos saudáveis e não-saudáveis, avaliando se os resultados obtidos apresentam sentido fisiológico e significância estatística.

Resumidamente, os objetivos do trabalho são:

- Comparar os métodos de Lee-Schetzen e Laguerre para verificar qual produz estimativas melhores;
- A partir da definição do melhor método, fazer sua aplicação utilizando dados reais de indivíduos saudáveis e não-saudáveis, verificando a validade dos resultados em termos fisiológicos e estatísticos.

1.2 Estruturação do trabalho

O presente trabalho está dividido da seguinte forma:

- I. O Capítulo 2 contempla a revisão bibliográfica, onde se faz um breve resumo dos conceitos importantes para a compreensão do estudo;
- II. O Capítulo 3 contempla a metodologia, onde se faz uma apresentação do que foi seguido e utilizado para a construção dos resultados e das análises;
- III. O Capítulo 4 contempla os resultados e discussões, onde se faz a apresentação dos resultados e a análise e discussão dos mesmos;
- IV. O Capítulo 5 contempla a conclusão, onde se faz as considerações finais ao que foi apresentado anteriormente.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo trata da apresentação dos conceitos mais relevantes para a compreensão do estudo, de maneira a contextualizar e justificar as decisões tomadas.

2.1 Conceitos fisiológicos

Esta seção busca apresentar os conceitos da fisiologia mais importantes para a contextualização do estudo. Os conceitos abordados aqui são particularmente importantes para o entendimento do tipo de dado que será utilizado, escolha de dados adequados e interpretação dos resultados.

2.1.1 Apneia

Durante o sono, os indivíduos com SAOS apresentam episódios recorrentes de obstrução parcial ou completa das vias aéreas superiores. A interrupção parcial do fluxo respiratório é classificada como hipopneia e a interrupção total como apneia. Esses eventos provocam a interrupção do sono por pequenos despertares, diminuição do sono REM e do sono de ondas lentas, causando episódios cíclicos de dessaturação e reoxigenação. A SAOS é um transtorno cujos efeitos afetam a qualidade de vida do paciente, além de ser considerada um fator de risco para o desenvolvimento de outras condições clínicas como hipertensão, insuficiência cardíaca, infarto do miocárdio, entre outros (SHEPARD, 1992). O seu diagnóstico é feito por meio da contagem de eventos de apneia e hipopneia ocorridos por hora de sono, gerando um índice de apneia-hipopneia (AHI, do inglês *Apnea-Hypopnea Index*). De acordo com o AHI, o paciente pode ser diagnosticado com os seguintes quadros:

- $AHI < 5$: quadro normal;
- $5 \leq AHI < 15$: quadro médio de SAOS;
- $15 \leq AHI < 30$: quadro moderado de SAOS;
- $AHI \geq 30$: quadro severo de SAOS (PENZEL, MOODY, *et al.*, 2000).

2.1.2 Sistema nervoso autônomo

O sistema nervoso autônomo (SNA) auxilia o corpo a manter a homeostase das funções fisiológicas através de comandos que levam à ações compensatórias à estímulos internos e externos, como por exemplo a constrição dos vasos sanguíneos em resposta ao frio, a regulação do tamanho da pupila em função da intensidade luminosa, o aumento da frequência cardíaca

em função de esforço físico, entre outras. Além disso, o SNA proporciona ajustes que dão suporte à execução de comportamentos motivados, como comportamento defensivo, alimentar e sexual (que são importantes para a sobrevivência do indivíduo e manutenção da espécie). Existem dois componentes importantes no SNA, o simpático e o parassimpático, que agem de maneira antagônica. O primeiro predomina em ações do tipo “*fight or flight*” (lutar ou fugir) enquanto o segundo predomina durante ações do tipo “*rest and digest*” (descansar e digerir) (MCCORRY, 2007). A Figura 2.1 ilustra algumas das funções associadas a cada tipo de sistema.

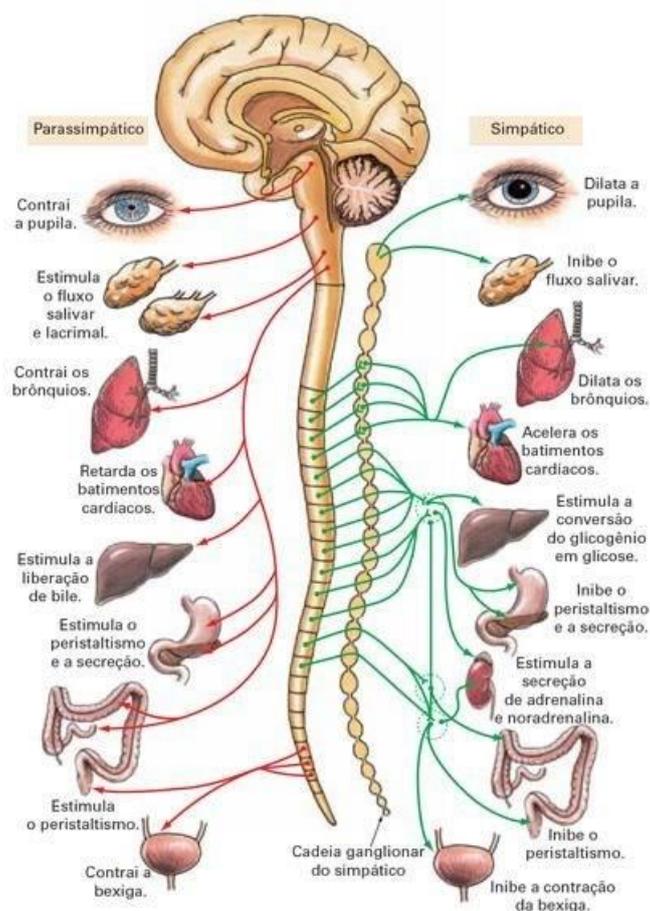


Figura 2.1 – Efeitos dos ramos do SNA no organismo. Fonte: (ANATOMIA DO CORPO HUMANO)

No contexto da SAOS, verificamos que ela tem um impacto direto na regulação do organismo pelos sistemas simpático e parassimpático. O sono é uma atividade regulada principalmente pelo ramo parassimpático, mas devido aos eventos apneicos, ocorre um aumento da atividade do ramo simpático e a consequente elevação da pressão arterial em pacientes com SAOS. Estudos indicam que tanto a pressão arterial quanto a atividade do sistema simpático tendem a ser mais elevadas em pacientes diagnosticados com SAOS do que em pacientes saudáveis (SOMERS, DYKEN, *et al.*, 1995).

2.1.3 Variabilidade da frequência cardíaca

A variabilidade da frequência cardíaca (VFC) é um dos marcadores mais utilizados para estudos não-invasivos da atividade do SNA (TASK FORCE, 1996). Ela consiste na variação entre os intervalos existentes entre batimentos cardíacos consecutivos, e é extraída através do intervalo entre os picos R do ECG, conhecido como RRI. O conceito de RRI é importante, pois é o tipo de sinal de ECG que será utilizado nas simulações. A Figura 2.2 ilustra um sinal elétrico de ECG, caracteriza suas ondas e indica a interpretação fisiológica delas.

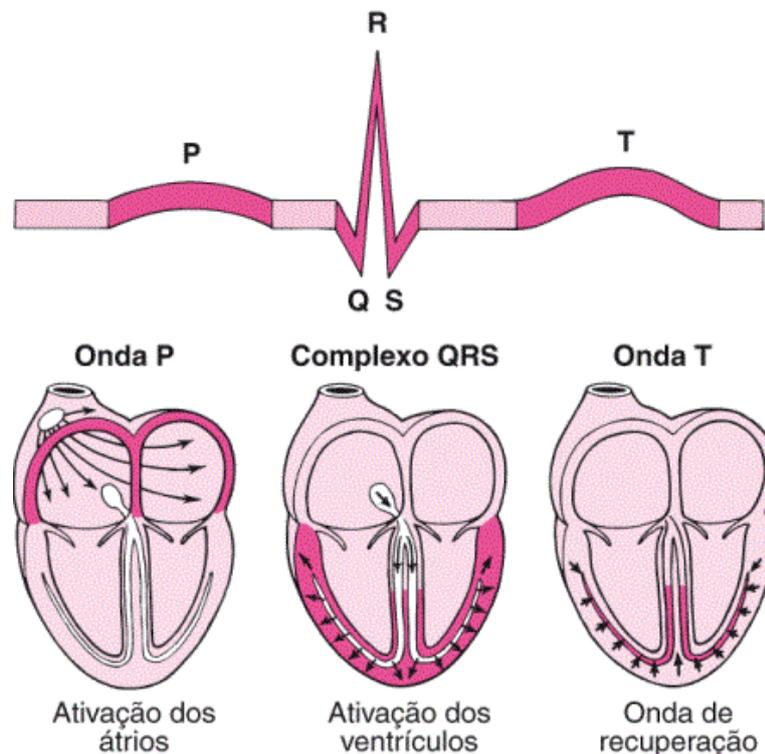


Figura 2.2 – Sinal de ECG e interpretação fisiológica das ondas. Fonte: Adaptado de (SHEA)

A VFC pode ser considerado um indicador do estado de saúde. Uma VFC alta indica um organismo bem adaptável, com o sistema autônomo funcionando apropriadamente. Uma VFC baixa por sua vez indica o oposto, o que pode ser um sinal de algum problema de saúde (PUMPRLA, HOWORKA, *et al.*, 2002).

2.2 Conceitos matemáticos

Esta seção busca apresentar os conceitos matemáticos mais importantes para a contextualização do estudo. Os conceitos abordados aqui são particularmente importantes para o entendimento do tipo de sistema que será trabalhado, do desenvolvimento matemático dos

métodos de resolução envolvidos, da escolha de parâmetros e da interpretação dos resultados obtidos a partir das simulações.

2.2.1 Modelagem de sistemas

A modelagem de sistemas tem como propósito simular um determinado sistema, permitindo assim saber como o mesmo se comporta quando submetido à uma entrada desejada. Os modelos podem ser classificados de acordo com algumas características apresentadas:

- Os sistemas são classificados como lineares quando obedecem ao princípio da superposição. Do contrário, são classificados como não-lineares;
- Os sistemas são classificados como estáticos quando a saída depende apenas da entrada atual, ou seja, são sistemas sem memória. Quando a saída depende da entrada atual e das entradas passadas, o sistema é classificado como dinâmico (ou causal);
- Os sistemas são classificados como invariantes no tempo quando sua resposta a uma mesma entrada não se altera ao longo do tempo. Do contrário, o sistema é classificado como não invariante no tempo;

Os principais métodos utilizados para a modelagem de sistemas são o método dedutivo e o método indutivo. O primeiro, também conhecido como método da caixa branca, baseia-se em hipóteses simplificadoras feitas sobre o sistema, criando um modelo hipotético que pode ser utilizado para prever e testar o comportamento do sistema. O segundo, mais conhecido como método da caixa preta, baseia-se nas medições feitas para relacionar as entradas e saídas do sistema, e a partir disso fazer o seu modelamento matemático (VAN DRONGELEN, 2010).

O foco deste estudo é trabalhar com sistemas dinâmicos e não-lineares, que representam a maior parte dos sistemas fisiológicos reais, utilizando o método da caixa preta. A modelagem do sistema será feita a partir da série de Volterra, uma das ferramentas mais utilizadas e consolidadas para fazer a representação deste tipo de sistema na área de processamento de sinais e identificação de sistemas.

2.2.2 Série de Volterra

Um sistema é definido matematicamente como uma relação entre um sinal de saída e um sinal de entrada. Essa relação pode ser definida como sendo igual a

$$y(t) = Fx(t) \quad (1)$$

onde F representa um operador. Usualmente, este operador F é considerado um operador linear H_1 , de modo que a resposta do sistema seja descrita por uma convolução

$$y(t) = H_1 x(t) = \int_{-\infty}^{\infty} h_1(\tau) x(t - \tau) d\tau \quad (2)$$

da entrada $x(t)$ com a resposta ao impulso. O trabalho de Volterra consistiu em expandir essa representação de sistemas lineares para sistemas não-lineares, através da adição de uma série de operadores integrais (VOLTERRA, 1959). A série de Volterra completa é dada pela seguinte expressão:

$$y(t) = h_0 + \int_{-\infty}^{\infty} h_1(\tau_1) x(t - \tau_1) d\tau_1 + \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} h_2(\tau_1, \tau_2) x(t - \tau_1) x(t - \tau_2) d\tau_1 d\tau_2 + \dots + \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} h_n(\tau_1, \dots, \tau_n) x(t - \tau_1) \dots x(t - \tau_n) d\tau_1 \dots d\tau_n \quad (3)$$

onde o termo h_0 representa o termo DC e os termos da forma h_n representam os kernels de Volterra de ordem n . Cabe ressaltar que o termo “kernel” representa uma definição única no contexto deste tipo de série e não deve ser confundido com o significado utilizado em outras áreas.

Utilizando o conceito de operadores, a série de Volterra pode ser escrita de maneira simplificada

$$y(t) = H_0 x(t) + H_1 x(t) + H_2 x(t) + \dots + H_n x(t) \quad (4)$$

onde os termos de forma $H_n x(t)$ representam os operadores de Volterra de ordem n .

É interessante observar que a série de Volterra é essencialmente a integral de convolução estendida para sistemas não-lineares. Como os sistemas não-lineares são compostos por uma família de funções h_n , a série de Volterra pode ser utilizada para descrever qualquer sistema desse tipo, desde que possua a quantidade de termos e ordens suficientes para tal. Em relação a isso, cabe a observação de que os kernels estão diretamente relacionados com a resposta ao impulso do sistema. Para um sistema de segunda ordem por exemplo, a resposta ao impulso será dada por $h_0 + h_1 + h_2$.

A série de Volterra se assemelha a série de Taylor, sendo que a diferença se dá em relação à “memória” do sistema. Enquanto a série de Taylor relaciona a saída do sistema com a entrada instantânea, a série de Volterra relaciona a saída do sistema com a entrada atual e com

as entradas passadas, como pode ser visto nos termos do tipo $x(t-\tau_n)$ da Equação (3) (VAN DRONGELEN, 2010).

A série de Volterra pode ser descrita da forma contínua, como representado nas equações acima ou na forma discreta, onde as integrais são substituídas por somatórios:

$$y(t) = \sum_{n=0}^N H_n[x(t)] \quad (5)$$

2.2.3 Série de Wiener

A série de Volterra representa um dos métodos mais utilizados na análise e modelagem de sistemas não-lineares. Apesar disso, o método possui algumas desvantagens: a sua região de convergência é bastante limitada e a resolução dos kernels é muito complexa devido à relação de dependência existente entre os kernels de diferentes ordens. Como uma alternativa para evitar estas desvantagens, o trabalho de Wiener consistiu no desenvolvimento de uma série similar à de Volterra, onde cada componente de sua série de Wiener é ortogonal aos componentes de ordem inferior. A ortogonalização é feita por meio do processo de ortogonalização de Gram-Schmidt. A série de Wiener é dada pela expressão

$$z(t) = \sum_{n=0}^N G_n[k_n; x(t)] \quad (6)$$

onde G_n representa os operadores de Wiener de ordem n , k_n representa os kernels de Wiener de ordem n e $x(t)$ representa a entrada do sistema.

À despeito das similaridades entre as expressões para as séries de Volterra e Wiener, é importante ressaltar as três diferenças mais significativas entre elas:

1. Usualmente, a série de Volterra não contém o termo de ordem zero (apesar do mesmo poder ser definido como uma constante ($H_0[x(t)] = h_0$), enquanto a série de Wiener sempre irá conter este termo. Ele é definido como o componente DC e é igual ao kernel k_0 ($G_0[k_0; x(t)] = k_0$);
2. Os operadores da série de Volterra são homogêneos ($H_n[cx(t)] = c^n H_n[x(t)]$), enquanto os operadores da série de Wiener são não-homogêneos. Observando o operador de Wiener de primeira ordem

$$\begin{aligned}
G_1[k_1; x(t)] &= g_1[k_1, k_{0(1)}; x(t)] \\
&= K_1[x(t)] + K_{0(1)}[x(t)] \\
&= \int_{-\infty}^{\infty} k_1(\tau_1)x(t - \tau_1)d\tau_1 + k_{0(1)}
\end{aligned} \tag{7}$$

e o operador de segunda ordem

$$\begin{aligned}
G_2[k_2; x(t)] &= g_2[k_2, k_{1(2)}, k_{0(2)}; x(t)] \\
&= K_2[x(t)] + K_{1(2)}[x(t)] + K_{0(2)}[x(t)] \\
&= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} k_2(\tau_1, \tau_2)x(t - \tau_1)x(t - \tau_2)d\tau_1d\tau_2 + \\
&\quad \int_{-\infty}^{\infty} k_{1(2)}(\tau_1)x(t - \tau_1)d\tau_1 + k_{0(2)}
\end{aligned} \tag{8}$$

percebemos a existência dos termos não-homogêneos $k_{0(1)}$, $k_{1(2)}$ e $k_{0(2)}$. No caso, k_1 e k_2 representam os kernels de primeira e segunda ordem respectivamente, enquanto $k_{0(1)}$ representa o kernel derivado do operador G_1 e $k_{1(2)}$ e $k_{0(2)}$ representam os kernels derivados do operador G_2 . Aplicando a resolução descrita em (VAN DRONGELEN, 2010), temos que os termos não-homogêneos são iguais a

$$\begin{aligned}
k_{0(1)} &= 0 \\
k_{1(2)} &= 0 \\
k_{0(2)} &= -\sigma^2 \int_{-\infty}^{\infty} k_2(\tau_1, \tau_1)d\tau_1
\end{aligned} \tag{9}$$

de forma que os operadores de Wiener possam ser reescritos como

$$G_1[k_1; x(t)] = g_1[k_1; x(t)] = \int_{-\infty}^{\infty} k_1(\tau_1)x(t - \tau_1)d\tau_1 \tag{10}$$

e

$$\begin{aligned}
G_2[k_2; x(t)] &= g_2[k_2, k_{1(2)}, k_{0(2)}; x(t)] \\
&= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} k_2(\tau_1, \tau_2)x(t - \tau_1)x(t - \tau_2)d\tau_1d\tau_2 - \sigma^2 \int_{-\infty}^{\infty} k_2(\tau_1, \tau_1)d\tau_1
\end{aligned} \tag{11}$$

onde σ^2 representa a variância da entrada, no caso, ruído branco gaussiano.

3. A série de Volterra pode ser utilizada para qualquer tipo de sinal de entrada, enquanto a série de Wiener utiliza somente entradas do tipo ruído branco gaussiano, pois a característica deste tipo de sinal garante que os operadores de Wiener sejam ortogonais aos operadores de ordem inferior (VAN DRONGELEN, 2010).

É possível fazer a determinação dos kernels de Wiener a partir da resposta do sistema. Aplicando a resolução descrita em (VAN DRONGELEN, 2010) para um sistema cuja entrada é um ruído branco gaussiano, estes kernels podem ser definidos como:

$$\langle z(t) \rangle = \sum_{n=0}^{\infty} \langle G_n[k_n; x(t)] \rangle = G_0[k_0; x(t)] = k_0 \quad (12)$$

indicando que o kernel de Wiener de ordem zero é determinado pela média da saída;

$$k_1(v_1) = \frac{1}{\sigma^2} \langle z(t)x(t - v_1) \rangle \quad (13)$$

indicando que o kernel de Wiener de primeira ordem é determinado pela correlação cruzada entre a entrada x e a saída z ponderada pela variância da entrada;

$$k_2(v_1, v_2) = \frac{1}{2\sigma^4} \langle z(t)x(t - v_1)z(t - v_2) \rangle \quad (14)$$

indicando que o kernel de Wiener de segunda ordem, é determinado pela correlação cruzada de segunda ordem entre a entrada e a saída ponderada pelo termo $2\sigma^4$. O símbolo $\langle \dots \rangle$ representa a média no tempo.

Devido à relação existente entre as séries, os kernels de Wiener podem ser utilizados para determinar os kernels de Volterra (KHAN e VYAS, 1999).

2.2.4 Algoritmo de Lee-Schetzen

O método mais conhecido para estimação dos kernels de Wiener em modelamento de sistemas não-lineares é o método de correlação cruzada proposto por (LEE e SCHETZEN, 1965). O algoritmo proposto opera da seguinte forma:

- Estimação do kernel de ordem 0: obtido com a média do sinal de saída para uma entrada do tipo ruído branco gaussiano;
- Estimação do kernel de primeira ordem: obtido com a correlação cruzada entre o sinal de entrada e o resíduo de ordem zero (diferença entre o sinal de entrada e a sua média);
- Estimação do kernel de segunda ordem: obtido com a correlação cruzada 2-D entre o sinal de entrada e o resíduo de primeira ordem (diferença entre o resíduo de ordem zero e a correlação cruzada entre o sinal de entrada e o kernel de primeira ordem).

A Figura 2.3 ilustra as operações realizadas para a estimação dos kernels de Wiener por meio do algoritmo de Lee-Schetzen.

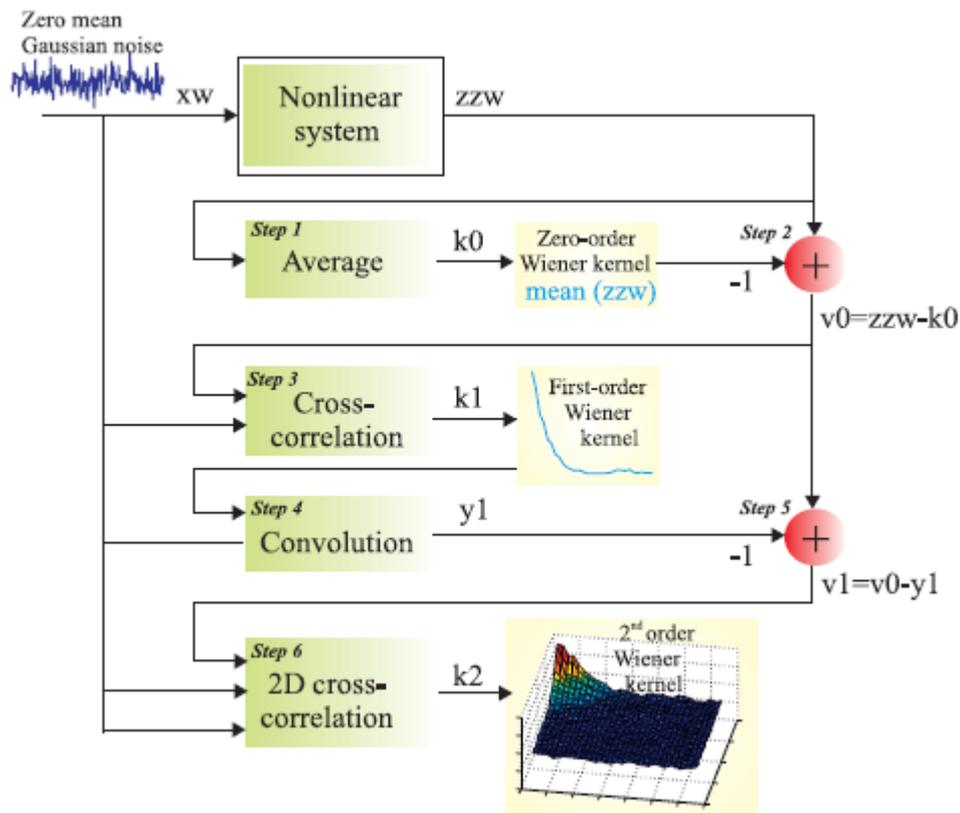


Figura 2.3 – Esquemático da implementação do algoritmo de Lee-Schetzen para estimação dos kernels de Wiener. Fonte: (VAN DRONGELEN, 2010)

2.2.5 Expansão de Laguerre

O método da expansão de Laguerre trata de um algoritmo proposto por (MARMARELIS, 1993) para estimação dos kernels, buscando reduzir os efeitos negativos impostos pelo método da correlação cruzada. Entre suas principais vantagens em relação ao algoritmo de Lee-Schetzen está a não-dependência de entradas do tipo ruído gaussiano branco. A LET (técnica de expansão de Laguerre, do inglês *Laguerre Expansion Technique*) não utiliza a ortogonalização para a resolução da série, e sim o método dos mínimos quadrados, proporcionando estimações mais precisas na presença de ruídos, reduzindo a necessidade de grandes quantidades de dados e permitindo a determinação de kernels mais precisos para entradas diversas (JO, BLASI, *et al.*, 2007).

Para fazer a expansão dos kernels de Volterra, o método de Laguerre utiliza L funções causais $b_j(\tau)$, definidas a partir da memória dos kernels. Estas funções causais representam a resposta ao impulso de filtros lineares para uma entrada $x(t)$, conforme demonstrado na Figura 2.4. A saída desses filtros, que compõem a função $\{v_j(t)\}$, é dada por:

$$v_j(t) = \int_0^{\mu} b_j(\tau)x(t - \tau)d\tau \quad (15)$$

de forma que a saída do sistema seja dada por

$$y(t) = h_0 + \sum_{n=1}^Q \sum_{j_1=1}^L \cdots \sum_{j_n=1}^L c_n(j_1, \dots, j_n)v_{j_1}(t) \cdots v_{j_n}(t) \quad (16)$$

onde L representa o número de funções de base e $\{c_n\}$ representa os coeficientes de expansão desconhecidos, que podem ser determinados através dos dados de entrada e saída.

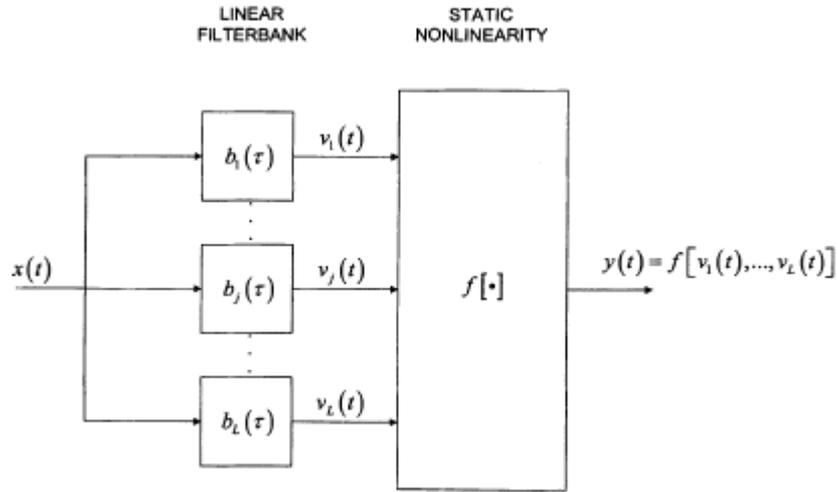


Figura 2.4 – Representação em diagrama de blocos para a saída de um sistema modelado por filtros lineares e uma não linearidade. Fonte: (MARMARELIS, 2004)

Os kernels expandidos de Volterra são representados como uma combinação linear de funções ortonormais de Laguerre:

$$h_n(\tau_1, \dots, \tau_n) = \sum_{j_1=1}^L \cdots \sum_{j_n=1}^L c_n(j_1, \dots, j_n)b_{j_1}(\tau_1) \cdots b_{j_n}(\tau_n) \quad (17)$$

onde b_j representa as funções de Laguerre de ordem j . Para que os kernels possam ser expandidos e fornecer estimativas adequadas, é necessário que a base de funções b_j seja completa. Assim, o problema de estimação dos kernels se resume à determinação dos coeficientes de expansão c_n .

Para que a Equação (16) possa ser utilizada no domínio do tempo discreto, ela é alterada para

$$y(n) = c_0 + \sum_{r=1}^Q \sum_{j_1=1}^L \cdots \sum_{j_r=1}^{j_r-1} c_r(j_1, \dots, j_r) v_{j_1}(n) \cdots v_{j_r}(n) + \epsilon(n) \quad (18)$$

onde c_r leva em conta as simetrias dos kernels de Volterra. Observe que foi incorporado à Equação (18) o termo ϵ que representa o erro associado ao truncamento do modelo e a possíveis ruídos e interferências nos dados.

Também na forma discreta, a Equação (15) é dada por:

$$v_j(n) = T \sum_{m=0}^{M-1} b_j(m) x(n-m) \quad (19)$$

onde M representa a largura de banda da memória do sistema e T representa o intervalo de amostragem.

Para fazer a estimação dos coeficientes de expansão c_r , pode ser utilizada a forma matricial da Equação (18).

$$y = Vc + \epsilon \quad (20)$$

onde a matriz V representa as saídas dos filtros lineares. A matriz c pode ser resolvida por meio da utilização dos mínimos quadrados.

Por fim, temos a definição das funções de Laguerre:

$$b_j(m) = \alpha^{(m-j)/2} (1-\alpha)^{1/2} \sum_{k=0}^m (-1)^k \binom{m}{k} \binom{j}{k} \alpha^{j-k} (1-\alpha)^k \quad (21)$$

onde m representa a largura de banda da memória do sistema e α representa um parâmetro que determina a taxa de decaimento exponencial das funções de Laguerre.

Para obter os melhores resultados possíveis com a LET, é importante fazer a escolha correta dos parâmetros de Laguerre. Os parâmetros a serem estudados serão a ordem das funções de Laguerre e o parâmetro α .

Em relação à influência da ordem das funções, observa-se na Figura 2.5 que a quantidade de vezes que cada função intercepta o eixo x corresponde à ordem do sistema. Também se nota que, conforme a ordem aumenta, os valores significativos da função persistem por mais tempo, indicando uma atenuação menor. Depreende-se assim que kernels que apresentem atraso relativamente grande podem necessitar de funções de Laguerre com ordem maior para serem representados apropriadamente.

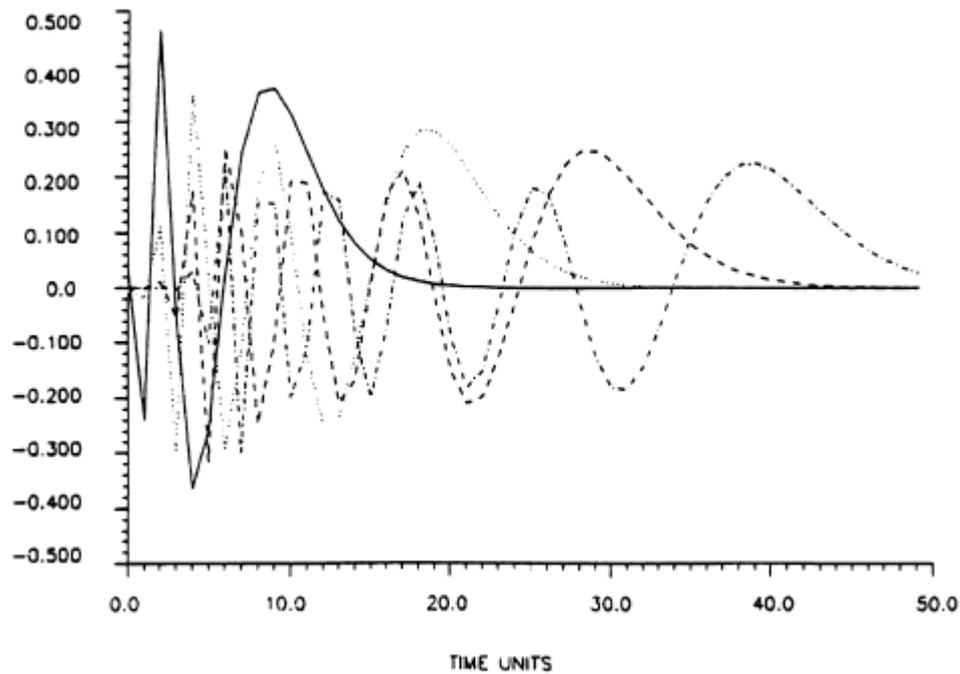


Figura 2.5 – Funções de Laguerre discretas no tempo de ordem 4 (linha sólida), 8 (pontilhada), 12 (tracejada) e 16 (ponto e traço) para $\alpha = 0,2$. Fonte: (MARMARELIS, 2004)

Em relação à influência do parâmetro α , faz-se primeiramente a observação que seu valor deve estar entre 0 e 1. Observa-se na Figura 2.6 que, de maneira similar ao constatado na influência da ordem das funções, um aumento do parâmetro implica em um aumento na quantidade de cruzamentos com o eixo x e na persistência dos valores significativos ao longo do tempo. Assim, a escolha do parâmetro deve ser feita de acordo com a extensão da memória do kernel e no número de funções de Laguerre utilizadas na expansão, garantindo que todas as funções declinem suficientemente perto do zero ao final do kernel (JO, BLASI, *et al.*, 2007) (MARMARELIS, 2004). Também é importante ressaltar o efeito de α na magnitude das funções, visto que para valores maiores de α as funções apresentaram valores menores.

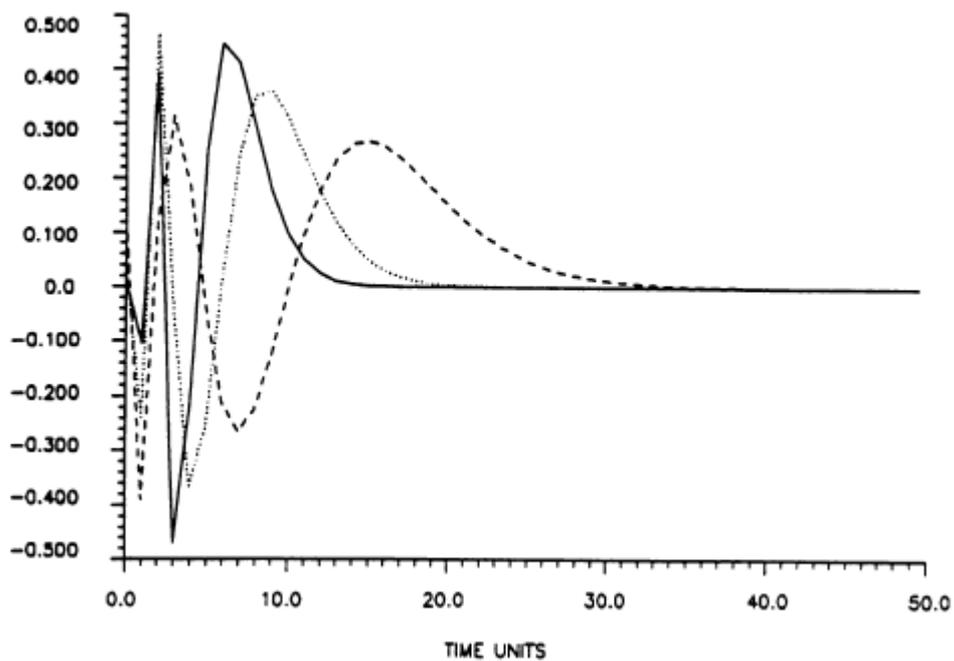


Figura 2.6 – Funções de Laguerre de 4ª ordem para $\alpha = 0,1$ (linha sólida), $\alpha = 0,2$ (pontilhada) e $\alpha = 0,4$ (tracejada). Fonte: (MARMARELIS, 2004)

3 METODOLOGIA

Este capítulo trata da metodologia aplicada para a construção dos resultados e das análises presentes neste estudo, com base nos conceitos discutidos anteriormente.

3.1 Base de dados fisiológicos

A base de dados escolhida para a realização dos estudos foi a The Apnea-ECG Database, disponível no site do PhysioNet (GOLDBERGER, AMARAL, *et al.*, 2000). Ela consiste em um conjunto de gravações de indivíduos saudáveis e indivíduos com SAOS e contém os sinais de ECG digitalizados e anotações referentes à presença ou não de eventos apneicos, feitas por um especialista da área. Os sinais possuem uma duração entre 401 e 578 minutos (PENZEL, MOODY, *et al.*, 2000).

Para a utilização neste estudo, foram selecionadas as 8 gravações que contém além dos dados citados acima, dados adicionais de respiração, sendo eles denominados de RespC (obtenção dos dados através de uma cinta torácica), RespA (obtenção dos dados através de uma cinta abdominal), RespN (obtenção dos dados através de um termistor nasal) e SpO2 (saturação de oxigênio). A base completa consiste em uma amostra de dados de 70 gravações, divididas em 2 conjuntos, um de aprendizado e um de teste.

Os sinais capturados foram amostrados a uma frequência de 100 Hz e possuíam ganho de 200 unidades por mV para os sinais de ECG e de 20.000 unidades por mV para os sinais de respiração.

Os indivíduos contidos na base de dados estão divididos em 3 grupos distintos, de acordo com a quantidade de minutos registrados com a respiração desordenada:

- O grupo dos que continham menos de 5 minutos de respiração desordenada foi alocado no chamado grupo normal (de controle, ou grupo C);
- O grupo dos que continham 100 minutos ou mais de respiração desordenada foi alocado no chamado grupo de apneia (grupo A);
- O grupo dos que continham alguns eventos apneicos considerados de menor importância foram alocados no chamado grupo “apneia limítrofe” (grupo B).

Para fazer a extração completa dos dados, foi utilizada uma *toolbox* disponível no próprio site do PhysioNet, chamada WFDB (SILVA e MOODY, 2014). Isso foi necessário pois a quantidade de dados era muito extensa, sendo limitada às primeiras 1.000.000 de amostras pelo PhysioBank ATM.

3.2 Pré-processamento dos sinais fisiológicos

Esta seção aborda os procedimentos envolvidos no tratamento dos dados, para garantir que eles possam ser utilizados de maneira adequada na simulação e análise dos resultados, com o intervalo de dados ideal e sem a presença de ruídos, por exemplo.

3.2.1 Seleção dos dados

Para fazer o tratamento adequados dos sinais, foram seguidas as indicações contidas em (TASK FORCE, 1996), um trabalho realizado por um grupo de especialistas das áreas da matemática, engenharia, fisiologia e clínica médica. Os objetivos principais deste trabalho era tratar dos padrões a serem estabelecidos em relação à padronização de nomenclaturas e definição de termos técnicos, especificação dos métodos de medição, definição de correlações fisiológicas e fisiopatológicas, descrição de aplicações médicas e identificação de áreas para pesquisas futuras. Para o estudo presente, observou-se a recomendação de se utilizar um período de 5 minutos, necessário para assegurar a estabilidade do sinal sem comprometer a medição das componentes de alta e baixa frequência. Além disto, observou-se também a recomendação de se utilizar um intervalo que não contenha batimentos ectópicos, pois os mesmos podem alterar a estimação do espectro de potência da variabilidade da frequência cardíaca, e eventos apneicos, pois durante a sua ocorrência há o aumento da probabilidade de arritmias e batimentos ectópicos (CINTRA, LEITE, *et al.*, 2014).

Para evitar os intervalos inadequados citados acima, foram utilizadas as anotações referentes aos eventos apneicos contidas na base de dados para determinar os períodos de ao menos 5 minutos que poderiam ser utilizados. A determinação destes intervalos é bastante importante para garantir a análise adequada dos sinais.

Além da determinação dos intervalos apropriados, foi feita a escolha do sinal de respiração mais adequado para a análise. Com o auxílio do MATLAB (The MathWorks, Inc., Natick, Massachusetts, United States), os 3 sinais de respiração foram plotados em um mesmo gráfico, que pode ser visto na Figura 3.1. É importante ressaltar que o sinal RespN foi integrado antes, uma vez que este era inicialmente um sinal de fluxo de ar enquanto os outros eram um sinal de volume instantâneo. Essa integração foi feita através da ferramenta CRSIDLab,

elaborada por (SILVA e OLIVEIRA, 2019). Uma descrição mais detalhada da mesma será feita posteriormente.

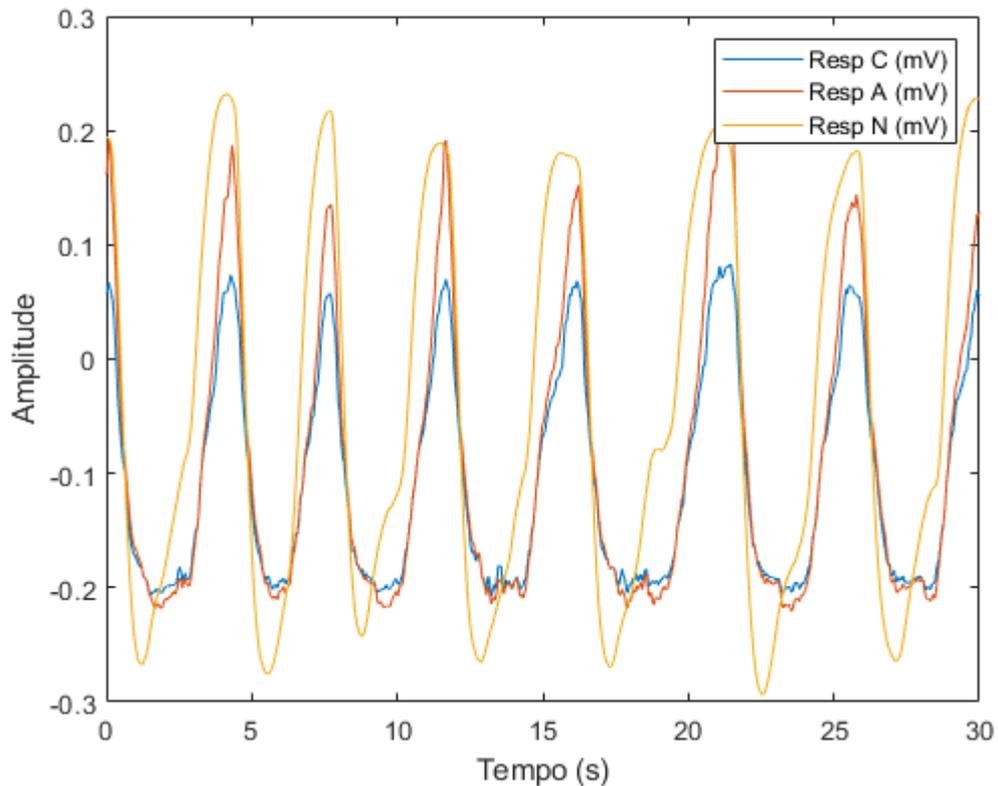


Figura 3.1 – Comparação entre os sinais de respiração

Pode-se notar na comparação que os sinais RespA (em laranja) e RespC (em azul) estão em fase e que a amplitude de RespA é maior devido à expansão maior provocada pela cinta abdominal. Observa-se também que o sinal RespN (em amarelo) apresenta uma pequena diferença de fase em relação aos outros sinais, possivelmente resultante do processo de conversão para volume instantâneo que foi feito (SILVA, 2017). A partir da comparação entre os sinais de respiração disponíveis, foi feita a escolha pelo sinal RespA, por conta de sua maior amplitude em relação à RespC e ausência da diferença de fase existente em RespN.

Dessa forma, os sinais escolhidos para o desenvolvimento do trabalho foram o sinal de ECG e o sinal de respiração RespA, obtido através de uma cinta abdominal.

3.2.2 Conversão dos dados

Para fazer a conversão dos sinais escolhidos para as unidades reais, utilizou-se o MATLAB. Esta conversão foi feita por meio de uma função auxiliar, disponível no site do PhysioNet. Esta etapa é importante para garantir que os sinais utilizados estejam nas unidades corretas.

3.2.3 Filtragem dos dados

A partir dos dados convertidos e com o intervalo adequado, pôde-se fazer a filtragem dos sinais. Para eliminar possíveis ruídos que poderiam deturpar os sinais e prejudicar na sua posterior análise, foram aplicados (quando necessário) os filtros digitais presentes no CRSIDLab. O CRSIDLab é uma ferramenta desenvolvida para MATLAB para auxiliar na análise multivariável do sistema cardiorrespiratório, capaz de fazer o processamento de sinais de ECG, pressão arterial e de respiração. O programa é baseado na ferramenta ECGLab, desenvolvida por (CARVALHO, ROCHA, *et al.*, 2002). O CRSIDLab possui módulos dedicados à filtragem dos sinais, extração de variáveis, pré-processamento de sinais respiratórios, alinhamento e reamostragem dos dados e ferramentas de análise de densidade espectral de potência e de identificação de sistemas, que não serão utilizadas neste trabalho.

Em relação à filtragem dos sinais de ECG, o programa possui filtros para tratar as 3 causas mais comuns de ruídos: um filtro notch de 60 Hz para atenuar a interferência da rede elétrica, um filtro passa-baixas com frequência de corte entre 20 Hz e 60 Hz para atenuar o ruído muscular e um filtro passa-altas com frequência de corte entre 0,001 Hz e 1 Hz para atenuar a variação da linha de base (SILVA, 2017). Os filtros foram aplicados quando foi observado que os ruídos presentes no sinal poderiam atrapalhar na análise dos dados; no caso dos dados utilizados, foi utilizado somente o filtro passa-baixas de 35 Hz, como sugerido em (CARVALHO, 2001). Um exemplo ilustrativo do efeito da filtragem do sinal pode ser visto na Figura 3.2.

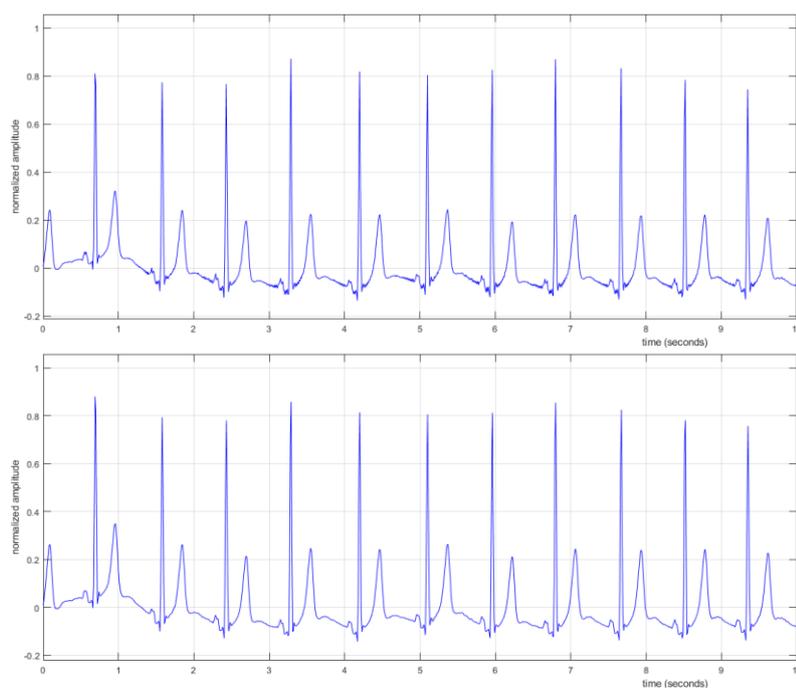


Figura 3.2 – De cima para baixo: sinal de ECG antes da filtragem e após a filtragem

Em relação à filtragem dos sinais respiratórios, o programa possui um filtro passa-baixas com uma frequência de corte entre 1 Hz e 4 Hz, que foi aplicado quando os sinais eram ruidosos.

3.2.4 Extração de variáveis

Após a filtragem dos sinais, pôde-se fazer a extração de variáveis. No contexto do estudo, o interesse para a análise era na detecção dos picos R, e conseqüentemente, no intervalo RR do ECG. O CRSIDLab possui dois algoritmos de detecção, um denominado rápido e um lento. Para termos uma marcação mais precisa, foi utilizado o algoritmo lento. Com a marcação dos picos R feita, é possível visualizar o intervalo entre os picos, facilitando a verificação de possíveis batimentos ectópicos. Caso seja detectada a sua ocorrência, o programa permite sua marcação, para que ele seja então removido de forma que a quantidade de amostras do sinal seja mantida (PELTOLA, 2012). A Figura 3.3 ilustra a marcação dos picos R feita para um sinal de ECG e o sinal de RRI resultante desta marcação.

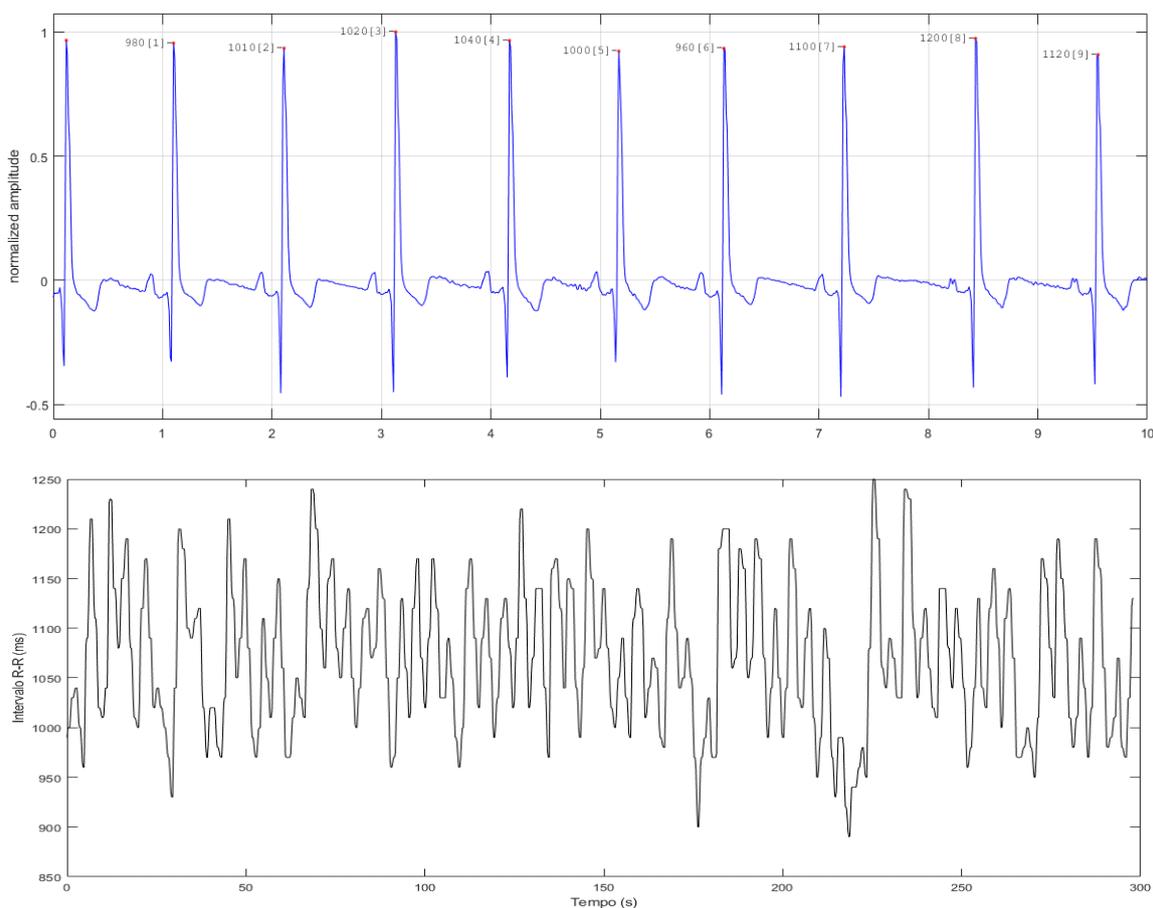


Figura 3.3 – De cima para baixo: exemplo de marcação dos picos R e sinal de RRI extraído a partir da marcação

3.2.5 Alinhamento e reamostragem

Devido à sua natureza, o sinal de RRI é amostrado de maneira irregular enquanto o sinal de respiração é amostrado de maneira regular com uma alta frequência. Por conta disto, os dados de RRI e de respiração não apresentam os mesmos pontos de início e fim (o sinal de respiração começa antes e acaba depois). Um exemplo da diferença existente no começo dos sinais pode ser visto na Figura 3.4. Para a aplicação de métodos de identificação de sistemas, é necessário que estes pontos inicial e final sejam os mesmos para ambos os sinais (JO, BLASI, *et al.*, 2003). Para corrigir isso, faz-se o alinhamento dos sinais. O processo de alinhamento consiste no ajuste dos sinais, para garantir que os dados de entrada e de saída existam nos mesmos instantes de tempo.

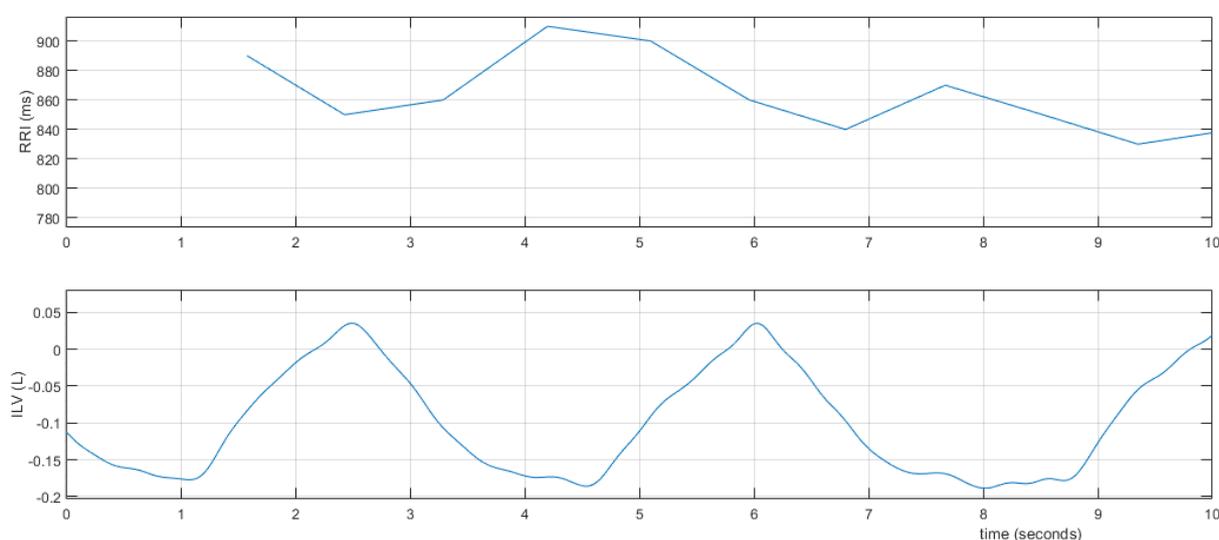


Figura 3.4 – Detalhe do ponto inicial dos sinais de RRI e respiração antes do alinhamento

Para fazer o alinhamento dos sinais, o CRSIDLab permite fazer a escolha dos limites do sinal. Como ponto inicial, foi escolhido o início do sinal de RRI, e como ponto final, a quantidade de amostras existentes a partir do ponto de início. A Figura 3.5 ilustra o efeito do alinhamento no ponto inicial dos sinais.

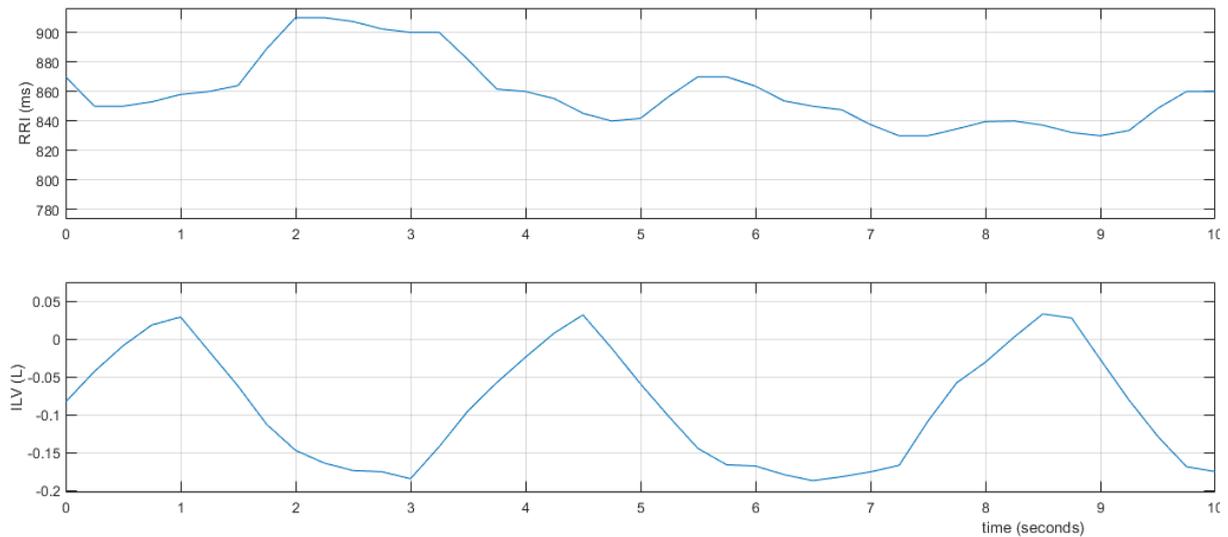


Figura 3.5 - Detalhe do ponto inicial dos sinais de RRI e respiração depois do alinhamento

Para fazer a reamostragem dos sinais, o programa apresenta três métodos distintos: a interpolação linear, a interpolação cúbica e o algoritmo de Berger. Como as técnicas de interpolação tendem a causar uma sobrestimação da razão entre as componentes espectrais de baixa e alta frequência, foi escolhido o método de Berger (SILVA, 2017). O algoritmo de Berger utiliza um modelo IPFM (*Integral Pulse Frequency Modulation*) para reconstruir o sinal de ECG (BERGER, AKSELROD, *et al.*, 1986). Além do método, é necessário também determinar a frequência de reamostragem. Esta é uma escolha importante, devido ao critério de Nyquist, Levando isso em consideração, a maior parte dos estudos sugere uma frequência entre 2 Hz e 4 Hz, assumindo que a maior frequência cardíaca esteja entre 60 e 120 bpm (batimentos por minuto) (CLIFFORD, 2002). Com base nos sinais de RRI, optou-se por utilizar uma frequência de reamostragem de 4 Hz.

Obteve-se assim, para cada um dos 8 indivíduos escolhidos, um conjunto composto pelo sinal de RRI e pelo sinal de respiração proveniente da cinta abdominal, alinhados e reamostrados a uma taxa de 4 Hz.

3.3 Simulações computacionais

Para fazer as análises relevantes para o estudo, que envolvem a comparação entre os dois métodos de resolução da série de Volterra, foram feitas simulações computacionais com o auxílio do MATLAB. Para a resolução através do algoritmo de Lee-Schetzen, foi utilizado o programa disponível em (VAN DRONGELEN, 2010) com algumas alterações para que ele se tornasse compatível com o tipo de sistema que pretendemos estudar. Para a resolução através

da expansão de Laguerre foi utilizado o Lysis, uma *toolbox* para MATLAB para modelamento de sistemas não-lineares desenvolvida por (MARMARELIS).

Para as simulações, foi considerado um sistema do tipo SISO (Single Input Single Output), onde o sinal de entrada é o sinal de respiração do paciente e o sinal de saída é o sinal de RRI do ECG. A Figura 3.6 mostra o diagrama de blocos que representa o sistema descrito.

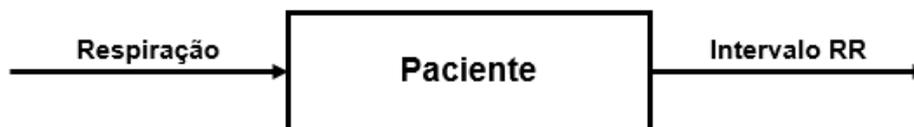


Figura 3.6 – Diagrama de blocos referente ao sistema considerado na simulação

3.4 Análise estatística

Para verificar se os dados obtidos através das simulações computacionais produziram respostas estatisticamente confiáveis, utilizou-se o MATLAB para conduzir um teste t de Student, um teste de hipóteses capaz de verificar se existe diferença significativa entre as médias de duas amostras. Essa avaliação é feita através do p-valor, uma medida indicativa da probabilidade de significância. Usualmente, considera-se que para um p-valor menor que 0,05 temos um resultado estatisticamente significativo.

Considerando o escopo das análises, os indivíduos foram agrupados de acordo com o índice de apneia medido, de forma a existirem dois grupos, ambos compostos por quatro pacientes. A Tabela 1 ilustra a divisão dos indivíduos por grupo.

Tabela 1 – Divisão dos indivíduos por grupo de acordo com o índice de apneia

Indivíduo	AHI	Grupo
A01	69,6	SAOS
A02	69,5	SAOS
A03	39,1	SAOS
A04	77,4	SAOS
B01	0,24	Controle
C01	0	Controle
C02	0	Controle
C03	0	Controle

O método do teste t exige algumas condições para que possa ser aplicado corretamente, sendo a mais relevante delas a necessidade de as amostras seguirem uma distribuição normal. Nos casos onde a distribuição dos dados não era normalizada, foi utilizado outro teste estatístico, o teste U de Mann-Whitney. Este teste é considerado o equivalente do teste t para dados não-paramétricos, no caso, dados que não possuem distribuição normal. A avaliação da significância estatística também é feita através da medida do p-valor.

A saber, os dados de RRI médio e de erro foram testados por meio do teste t enquanto os dados de ganho linear IRM (magnitude da resposta ao impulso, do inglês *Impulse Response Magnitude*) e não-linear KM (magnitude do kernel, do inglês *Kernel Magnitude*) foram testados por meio do teste U de Mann-Whitney.

4 RESULTADOS E DISCUSSÕES

Este capítulo trata da apresentação dos resultados obtidos e da discussão do que foi observado a partir deles.

4.1 Comparação entre os métodos

Para fazer o estudo comparativo entre os dois métodos de resolução da Série de Volterra, foi feita a simulação utilizando os dados de um dos indivíduos do grupo A (grupo com apneia), considerando um sistema do tipo SISO conforme ilustrado na Figura 3.6. Desta forma, pretendia-se comparar os resultados obtidos por cada um dos métodos para analisar a eficácia de cada um deles. É importante ressaltar que as análises foram feitas considerando a variação dos dados em torno da média. A Figura 4.1 mostra os sinais originais de entrada e de saída do sistema, onde o sinal de cima é a entrada (sinal de respiração) e o sinal de baixo é a saída (intervalo RR do ECG).

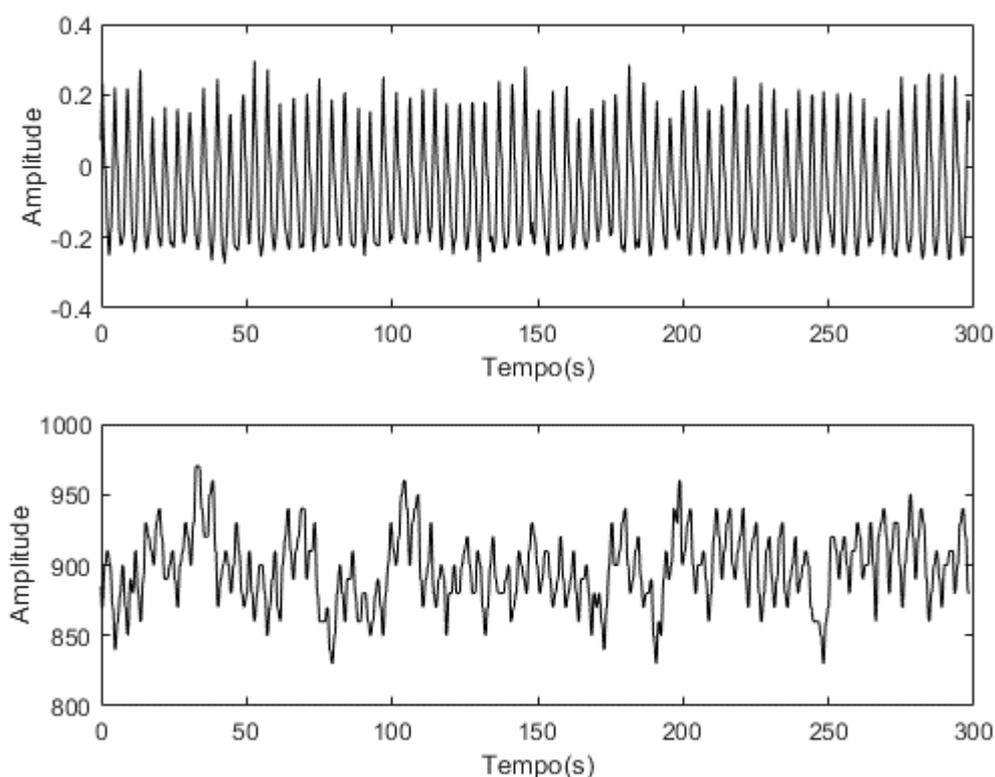


Figura 4.1 - De cima para baixo: sinal de entrada (respiração, em L) e sinal de saída (intervalo RR, em ms) para um indivíduo do grupo SAOS

4.1.1 Algoritmo de Lee-Schetzen

A Figura 4.2 mostra o resultado da simulação obtido a partir do algoritmo de Lee-Schetzen. Podemos observar que a estimação da saída obtida através do algoritmo é bastante discrepante do sinal original, embora essa diferença fosse esperada devido ao tipo de entrada utilizada. A Figura 4.3 mostra os kernels obtidos. Podemos observar que k_1 e k_2 apresentaram um resultado bastante diferente do esperado, uma vez que se esperava um comportamento assintótico. Além disso, ambos os kernels oscilaram bastante.

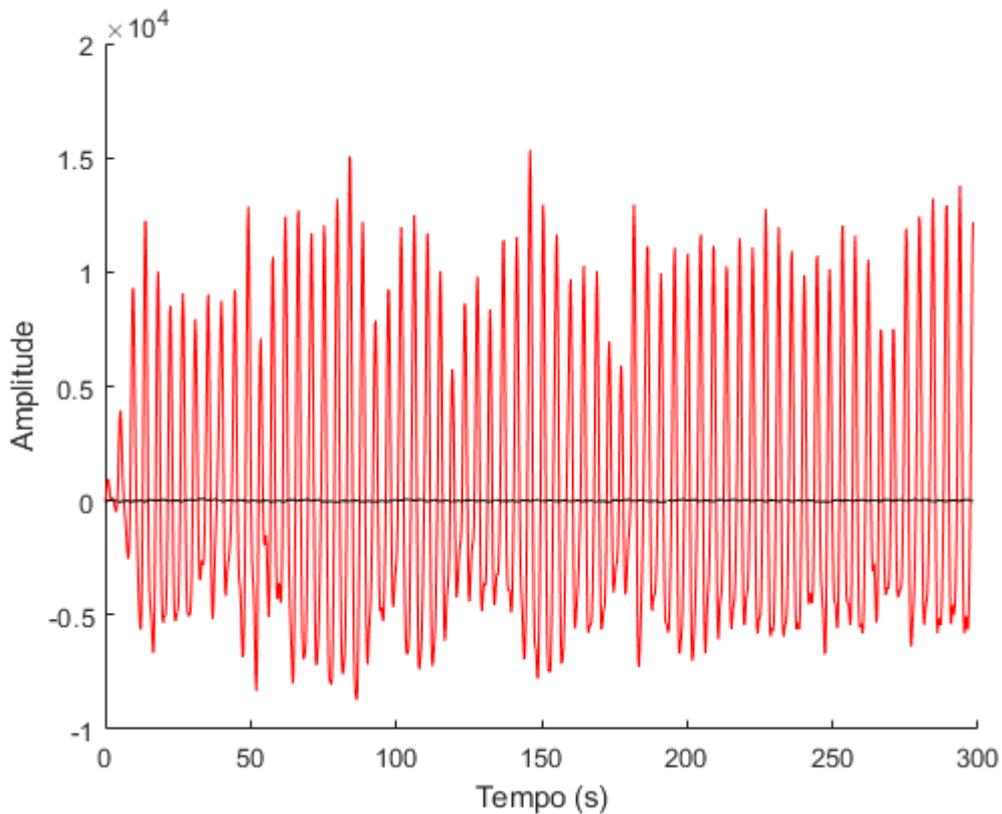


Figura 4.2 – Saída real (em preto) e saída estimada (em vermelho) obtida através do algoritmo de Lee-Schetzen para um indivíduo do grupo SAOS

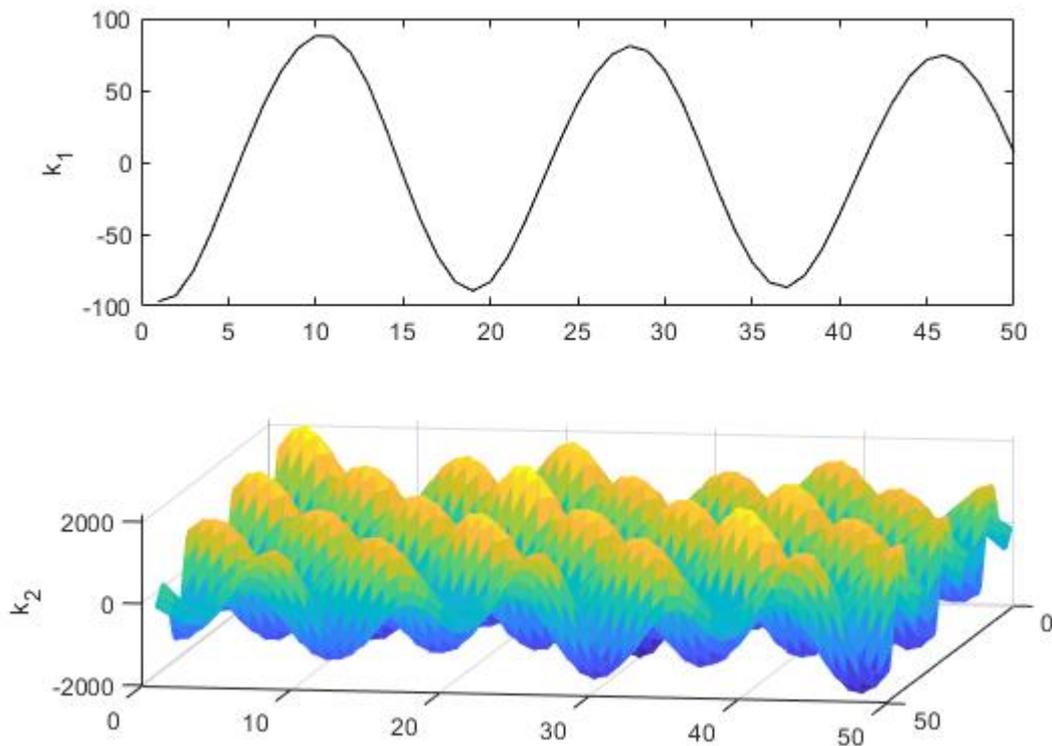


Figura 4.3 – De cima para baixo: kernel de primeira e kernel de segunda ordem obtidos através do algoritmo de Lee-Schetzen para um indivíduo do grupo SAOS

4.1.2 Expansão de Laguerre

Para a simulação do método de expansão de Laguerre, foram utilizados como parâmetros $\alpha = 0,7$, para que as funções apresentassem um decaimento menor e um número de funções de Laguerre igual a 9, para que tivéssemos uma base de funções apropriada. É importante mencionar que o programa Lysis limita o número de funções de Laguerre em até 9, porém esta quantidade é mais que suficiente para garantir estimativas consistentes. A Figura 4.4 mostra o resultado da simulação obtido a partir do método da expansão de Laguerre. Podemos observar que a estimação da saída obtida através do método é bastante próxima do sinal original, ainda mais quando comparada com a resposta obtida anteriormente através do algoritmo de Lee-Schetzen. A Figura 4.5 mostra os kernels de Volterra obtidos. Podemos observar que para o método de Laguerre, os kernels k_1 e k_2 apresentaram um resultado bem mais próximo do esperado, uma vez que ambos têm um comportamento assintótico.

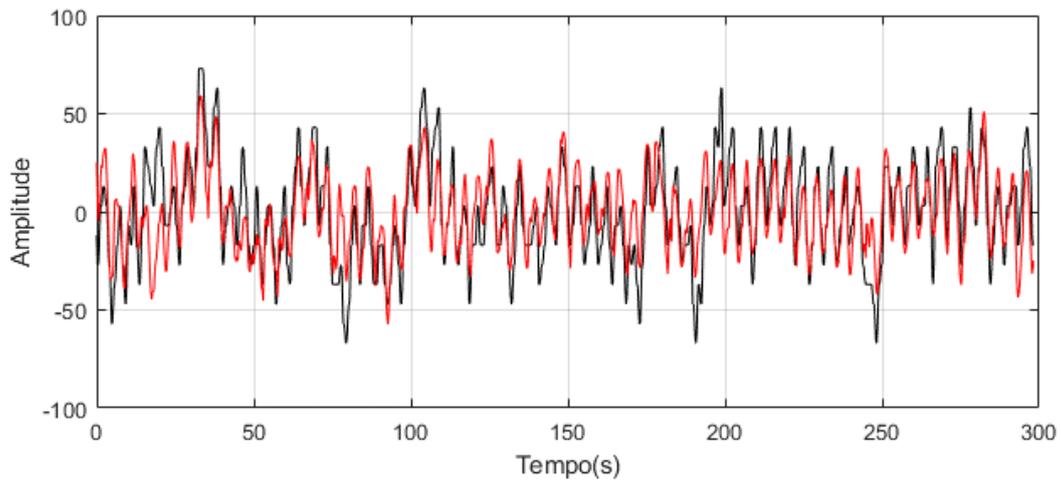


Figura 4.4 - Saída real (em preto) e saída estimada (em vermelho) obtida através da expansão de Laguerre para um indivíduo do grupo SAOS

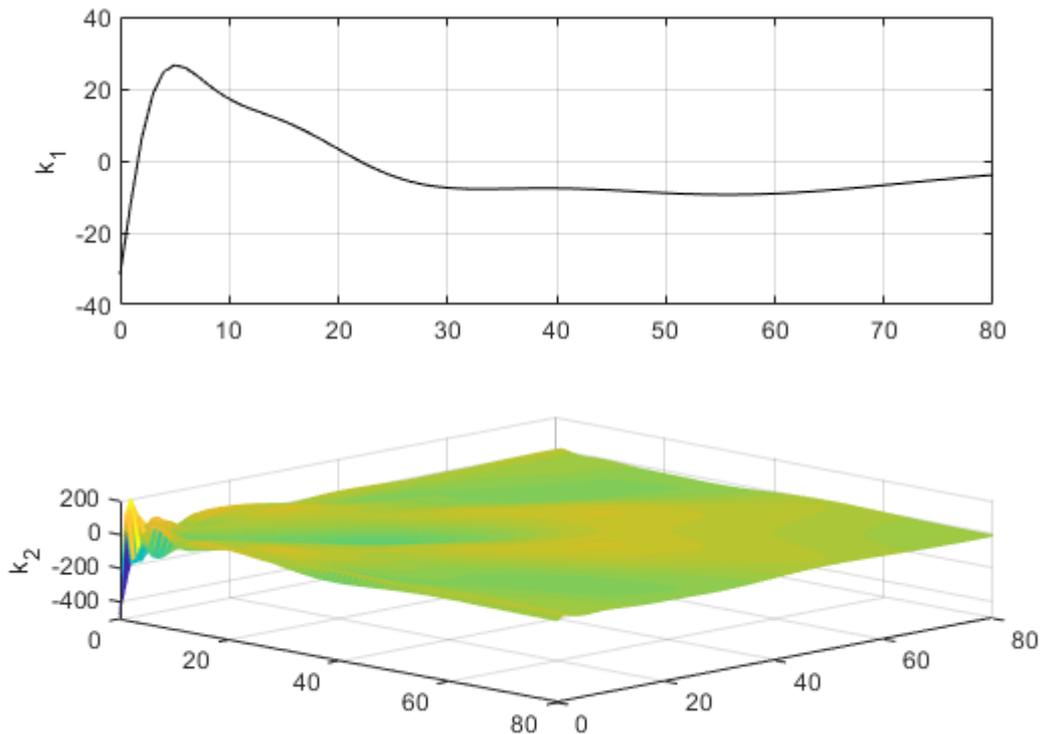


Figura 4.5 - De cima para baixo: kernel de primeira e kernel de segunda ordem obtidos através da expansão de Laguerre para um indivíduo do grupo SAOS

4.1.3 Análise da comparação

Com base nas simulações obtidas através dos dois métodos, o algoritmo de Lee-Schetzen e o método de expansão de Laguerre, foi possível observar como o segundo método

mostrou-se muito superior na determinação da resposta de sistemas com entrada e saída reais. A dependência da técnica de Lee-Schetzen por entradas aleatórias para que a mesma possa gerar estimações precisas ficou evidente, enquanto a técnica de Laguerre apresentou estimativas consistentes para outros tipos de entrada, mostrando-se uma ferramenta mais eficaz para a modelagem de sistemas não-lineares.

4.2 Discussão dos resultados

A partir dos resultados obtidos, demonstrou-se que o método da expansão de Laguerre pode ser utilizado na identificação de sistemas não-lineares, devido à sua capacidade de gerar resultados consistente para diversos tipos de entrada. Esta seção busca mostrar como esta ferramenta pode ser aplicada em situações práticas. As comparações a serem feitas são baseadas no estudo de (JO, BLASI, *et al.*, 2007). O trabalho citado trata da utilização de um modelo de Volterra-Wiener para caracterizar quantitativamente os efeitos da respiração e da pressão arterial na VFC de indivíduos saudáveis e com SAOS.

Para fazer a comparação dos resultados obtidos com os resultados encontrados no estudo citados acima, foi feita a simulação utilizando os dados de um dos indivíduos do grupo C (grupo controle) nos mesmos moldes de antes, com exceção de que para esta etapa foi utilizado somente o método de Laguerre, uma vez que foi demonstrado que ele é o mais adequado para avaliar este tipo de sistema. Dessa forma, de maneira similar ao estudo, foi possível analisar os resultados obtidos para indivíduos saudáveis e não-saudáveis.

A Figura 4.6 mostra os sinais originais de entrada e de saída do sistema, onde o sinal de cima é a entrada (sinal de respiração) e o sinal de baixo é a saída (intervalo RR do ECG).

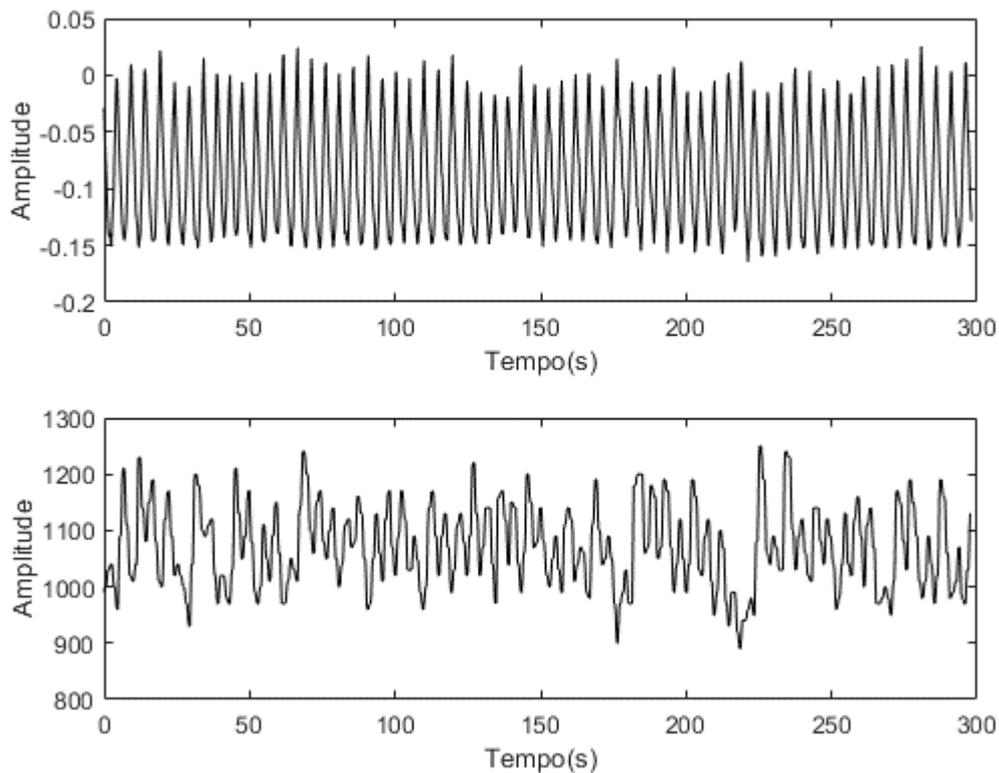


Figura 4.6 - De cima para baixo: sinal de entrada (respiração, em L) e sinal de saída (intervalo RR, em ms) para um indivíduo do grupo Controle

A Figura 4.7 mostra o resultado da simulação obtido a partir do método da expansão de Laguerre, enquanto a Figura 4.8 mostra os kernels de Volterra obtidos através da simulação. De maneira similar ao que foi observado na simulação para o paciente com apneia, nota-se que a estimativa obtida através de Laguerre é bastante compatível com o sinal original e que tanto k_1 quanto k_2 apresentam o comportamento assintótico esperado.

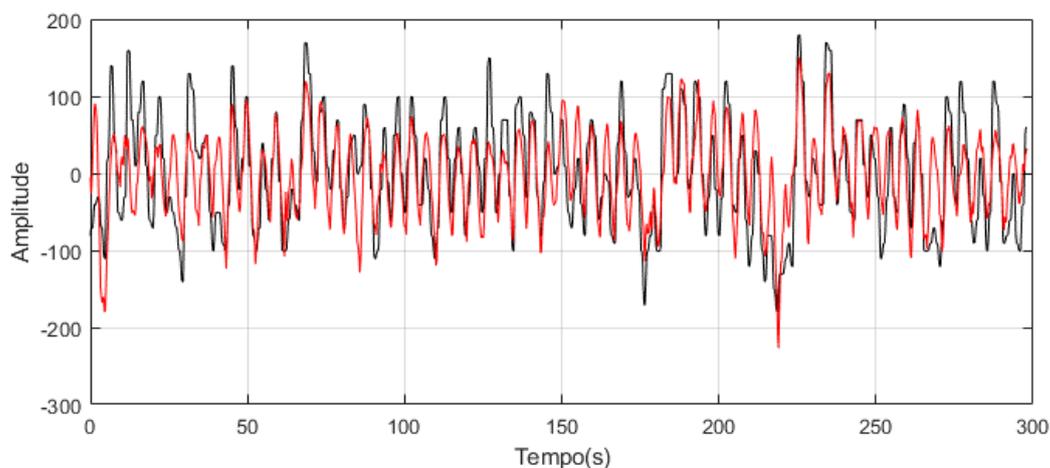


Figura 4.7 - Saída real (em preto) e saída estimada (em vermelho) obtida através da expansão de Laguerre para um indivíduo do grupo Controle

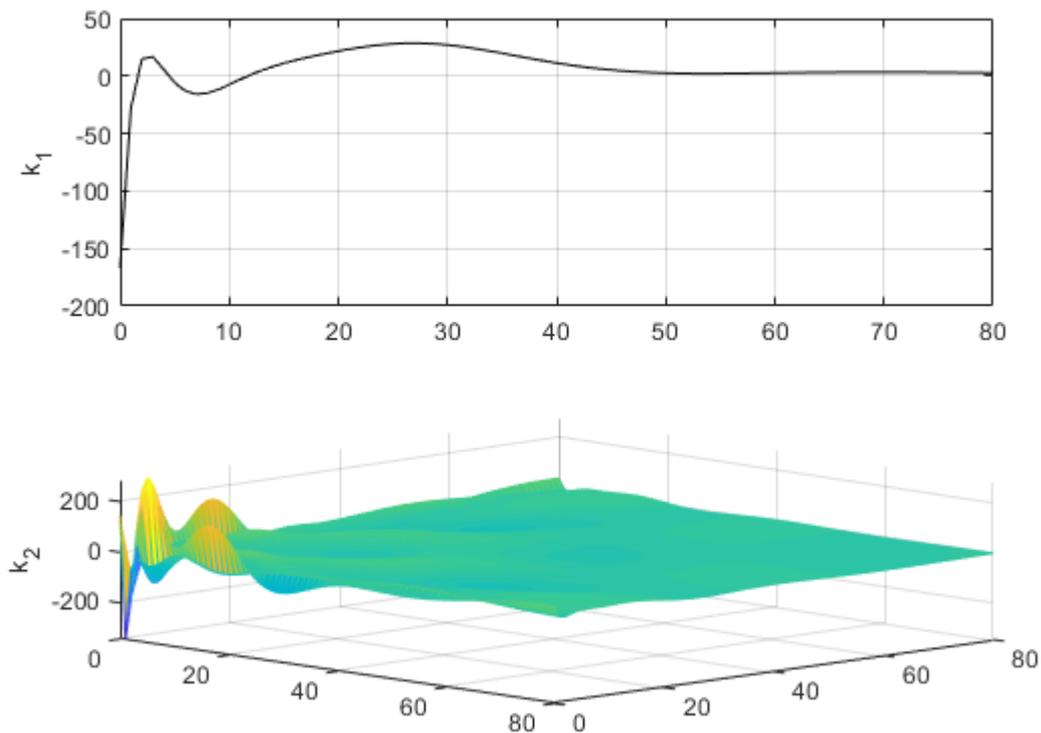


Figura 4.8 - De cima para baixo: kernel de primeira e kernel de segunda ordem obtidos através da expansão de Laguerre para um indivíduo do grupo Controle

Em relação ao estudo de (JO, BLASI, *et al.*, 2007), algumas diferenças relevantes devem ser observadas:

- No estudo citado acima foi considerada a influência da pressão arterial, dado que não está presente na base de dados utilizada neste trabalho;
- O estudo realiza sua análise levando em consideração o estado do paciente em relação à fase do sono (acordado, fase REM e fase 2), distinção que não está presente na base de dados utilizada neste trabalho;
- A amostragem disponível no estudo era consideravelmente maior, constituída de 9 pacientes com SAOS e 8 pacientes saudáveis.

Levando os aspectos levantados acima em consideração, as comparações entre os resultados foram limitadas àquelas que não tem dependência da pressão arterial e do estágio do sono, uma vez que estes parâmetros que não faziam parte do escopo do trabalho. A Tabela 2 traz o resumo dos parâmetros encontrados, na forma (média \pm desvio padrão).

Tabela 2 – Resumo dos parâmetros encontrados para cada grupo

Parâmetro	Grupo		p-valor
	SAOS	Controle	
RRI médio (ms)	802 ± 73	1013 ± 148	0,032
IRM	35,5 ± 15,4	382,7 ± 310,8	0,014
KM	272,1 ± 287,5	2714,4 ± 4040,1	0,057
	1ª ordem	2ª ordem	p-valor
NMSE	72,4 ± 12,7 %	45,6 ± 7 %	0,0006

Fazendo uma comparação entre o valor médio do RRI, que pode ser visualizado na Figura 4.9 em vermelho para um indivíduo apneico e um saudável respectivamente e na Tabela 2, notamos que os resultados encontrados através das simulações realizadas são compatíveis com os encontrados por (JO, BLASI, *et al.*, 2007). Em ambos os casos se nota que o valor médio do RRI foi consideravelmente menor nos pacientes com SAOS ($p < 0,05$). Para os indivíduos apneicos o valor médio do RRI foi de 802 ± 73 ms e para os saudáveis foi de 1013 ± 148 ms. De acordo com (DINGLI, ASSIMAKOPOULOS, *et al.*, 2003), essa diferença pode ser devido a ativações do sistema simpático.

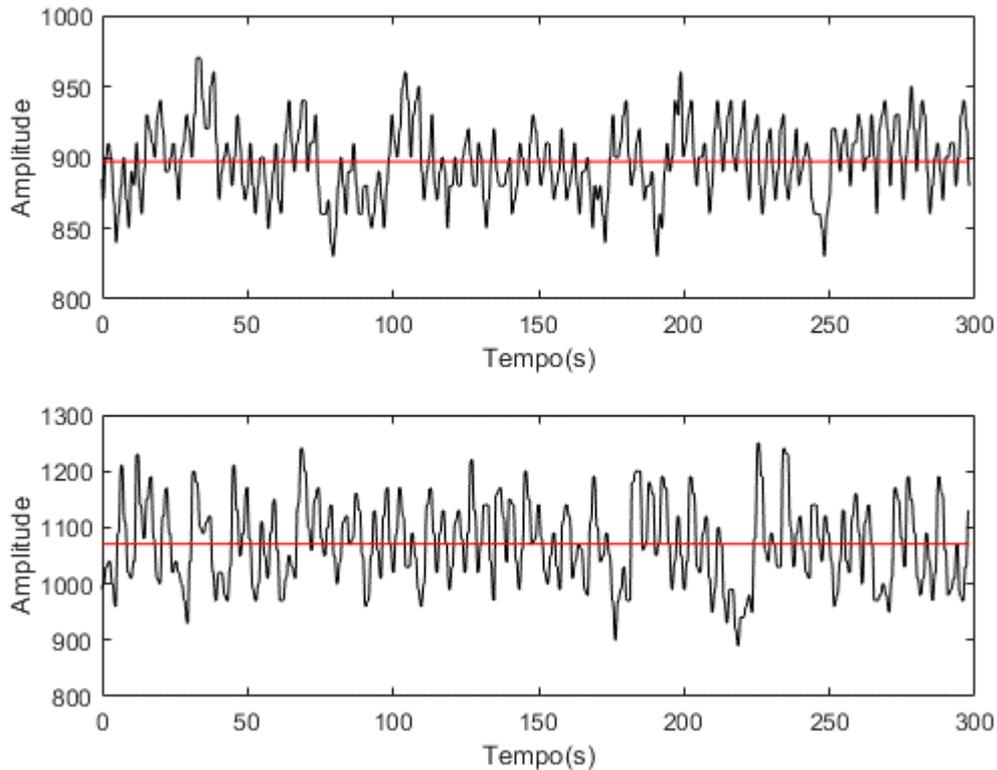


Figura 4.9 – De cima para baixo: sinal de RRI (em preto) e valor médio (em vermelho) para um indivíduo do grupo SAOS e do grupo Controle

Verifica-se também como a inclusão do modelo não-linear de segunda ordem diminui o erro das estimativas geradas ($p < 0,05$). O tipo de erro considerado é o NMSE (erro quadrático médio normalizado, do inglês *Normalised Mean Square Error*) que faz uma estimação dos desvios globais entre os valores medidos e os previstos. Com o auxílio do Lysis, o NMSE foi calculado primeiramente utilizando somente a parte linear do modelo e em seguida utilizando o modelo de segunda ordem. Podemos observar na Tabela 2 que o NMSE diminui de $72,4 \pm 12,7 \%$ para $45,6 \pm 7 \%$ com a introdução do modelo de segunda ordem. Essa redução apresentada confirma as características não-lineares envolvidas na modulação da VFC, indicando que os efeitos dinâmicos de segunda ordem não podem ser desprezados (JO, BLASI, *et al.*, 2007). Os gráficos de erro gerados podem ser visualizados na Figura 4.10.

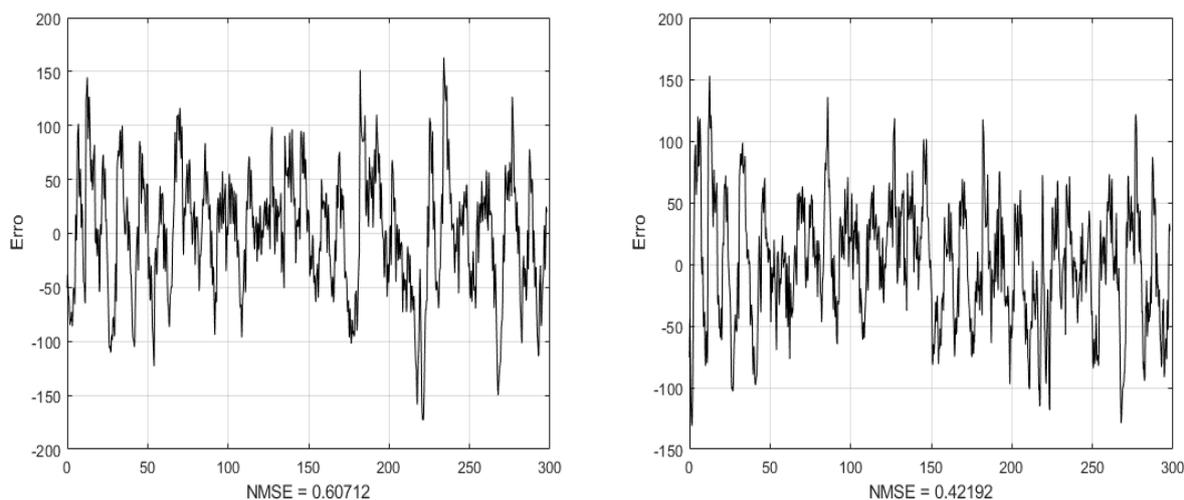


Figura 4.10 – Da esquerda para a direita: gráfico de erro utilizando o modelo de 1ª ordem e utilizando o modelo de 2ª ordem

O kernel k_1 de primeira ordem, que representa a dinâmica linear do componente central da arritmia sinusal respiratória (JO, BLASI, *et al.*, 2007), apresenta um pico negativo inicial bem rápido, o que é consistente com o fato de ocorrer um aumento na frequência cardíaca durante a inspiração e está de acordo com os processos fisiológicos envolvidos (JO, BLASI, *et al.*, 2003). Ainda em relação à k_1 , quando analisamos a resposta ao impulso, percebe-se pela Tabela 2 que seu ganho é consideravelmente maior nos pacientes saudáveis ($p < 0,05$), o que indica que o mecanismo da respiração controlado pelo sistema parassimpático é mais suprimido nestes pacientes. Além disso, o fato de que o pico observado na resposta ao impulso ocorre depois nos indivíduos apneicos sugere que o mecanismo da respiração necessita de um tempo maior para ajustar totalmente a frequência cardíaca (JO, BLASI, *et al.*, 2007). O comportamento e a magnitude de k_1 podem ser visualizados na Figura 4.11 para um indivíduo apneico e um saudável respectivamente.

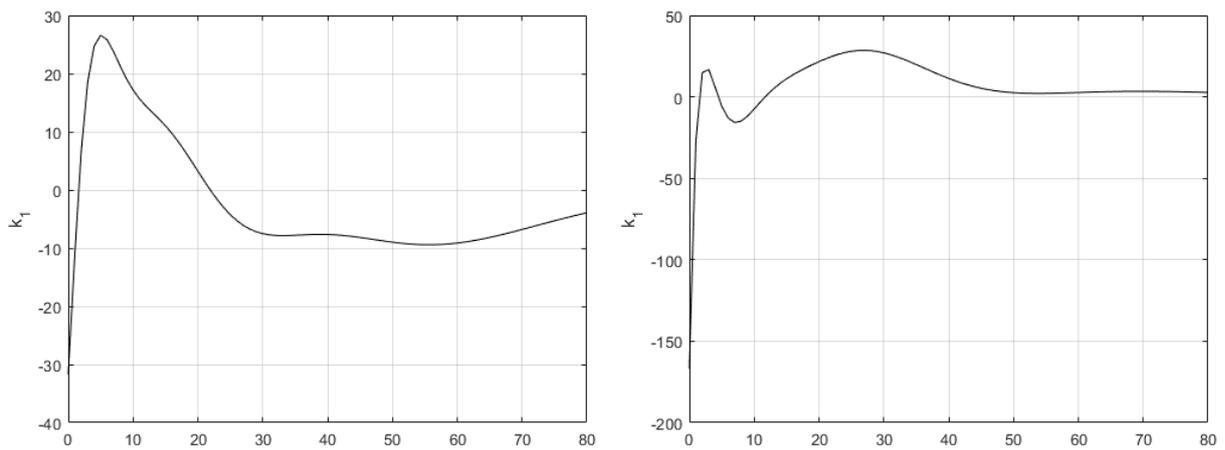


Figura 4.11 – Da esquerda para a direita: kernel k_1 para um indivíduo do grupo SAOS e do grupo Controle

O kernel k_2 por sua vez apresentou magnitudes bem distintas entre alguns dos indivíduos saudáveis e dos apneicos, em contraste com o que foi observado em (JO, BLASI, *et al.*, 2007). Além disso, os resultados relacionados com o parâmetro KM não apresentaram certeza estatística ($p > 0,05$). Esta divergência pode ser devida à fatores como a escolha dos parâmetros do método de Laguerre ou ainda devida aos próprios dados. O comportamento e a magnitude de k_2 podem ser visualizados na Figura 4.12 para um indivíduo apneico e um saudável respectivamente e na Tabela 2. Cabe ressaltar que os indivíduos utilizados para gerar as respostas abaixo apresentaram KM similares, mas outros pacientes apresentaram KM bastante discrepantes.

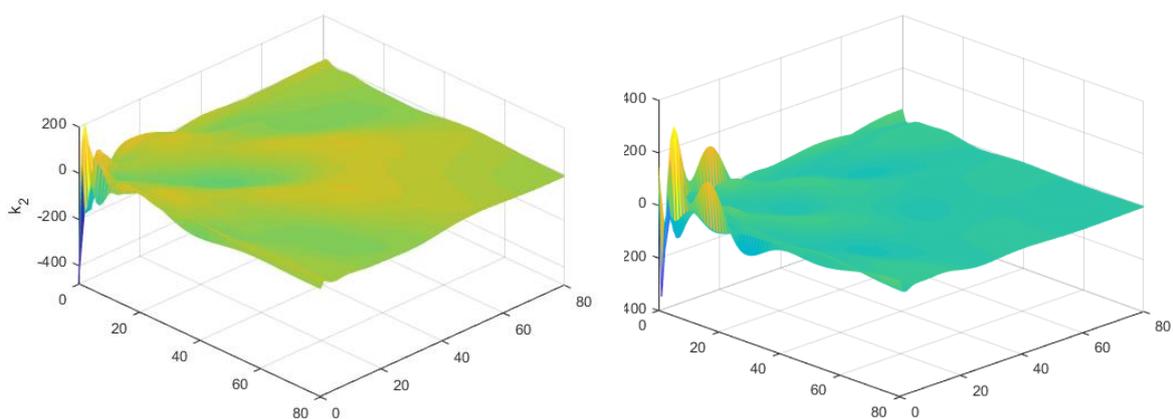


Figura 4.12 – Da esquerda para a direita: kernel k_2 para um indivíduo do grupo SAOS e para o grupo Controle

5 CONCLUSÕES

Este capítulo trata do fechamento do trabalho, reunindo as considerações finais em relação ao que foi produzido.

A comparação entre os métodos de resolução da série de Volterra mostrou que, para sistemas reais, com entradas não-aleatórias, a expansão de Laguerre é uma técnica muito mais confiável, produzindo estimativas mais precisas e kernels com comportamentos mais próximos do esperado. Além disso, a comparação evidenciou as limitações do algoritmo de Lee-Schetzen, restringindo seu uso para situações específicas onde o sinal de entrada é do tipo ruído branco gaussiano, condição dificilmente encontrada em sistemas físicos e fisiológicos.

A análise dos resultados obtidos com a expansão de Laguerre comprovou que ela é uma ferramenta bastante poderosa para a identificação de sistemas não-lineares. Uma parte relevante dos parâmetros encontrados mostrou-se de acordo com outros estudos, tanto no aspecto estatístico quanto no fisiológico.

Para possibilitar uma análise mais ampla da aplicabilidade da série de Volterra, em especial da técnica de Laguerre, sugere-se a utilização de uma base de dados mais extensa. Por conta do número limitado de indivíduos com dados de respiração, a média e o desvio padrão ficam muito sensíveis em à grandes variações nas medidas de cada indivíduo. Uma amostra maior poderia aumentar significativamente a certeza estatística dos parâmetros. Além disso, para que fossem estudados outros aspectos fisiológicos, sugere-se também a utilização de dados de pressão arterial.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ANATOMIA DO CORPO HUMANO. Sistema Nervoso Autônomo: Simpático e Parassimpático – Anatomia. **Anatomia do Corpo Humano**. Disponível em: <<https://www.anatomiadocorpo.com/sistema-nervoso/autonomo-simpatico-parassimpatico/>>.

BERGER, R. D. et al. An Efficient Algorithm for Spectral Analysis of Heart Rate Variability. **IEEE Transactions on biomedical engineering**, v. 9, p. 900-904, 1986.

CARVALHO, J. L. A. Manual ECGLab, 2001.

CARVALHO, J. L. A. et al. **Development of a Matlab Software for Analysis of Heart Rate Variability**. 6th International Conference on Signal Processing. [S.l.]: IEEE. 2002. p. 1488-1491.

CINTRA, F. et al. Sleep Apnea and Nocturnal Cardiac Arrhythmia: A Populational Study. **Arquivos brasileiros de cardiologia**, v. 103, n. 5, p. 368-374, 2014.

CLIFFORD, G. D. Signal processing methods for heart rate variability, Universidade de Oxford, Oxford, 2002.

DINGLI, K. et al. Spectral oscillations of RR intervals in sleep apnoea/hypopnoea syndrome patients. **European Respiratory Journal**, v. 22, n. 6, p. 943-950, 2003.

GOLDBERGER, A. et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. **Circulation**, v. 101, n. 23, p. e215-e220, 2000.

JO, J. et al. **Nonlinear Assessment Of Autonomic Function in Obstructive Sleep Apnea During Long-Term CPAP Therapy**. Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No. 03CH37439). [S.l.]: IEEE. 2003. p. 346-349.

JO, J. et al. A Nonlinear Model of Cardiac Autonomic Control in Obstructive Sleep Apnea Syndrome. **Annals of biomedical engineering**, v. 35, n. 8, p. 1425-1443, 2007.

KHAN, A. A.; VYAS, N. S. Non-linear parameter estimation using Volterra and Wiener theories. **Journal of Sound and Vibration**, v. 221, n. 5, p. 805-821, 1999.

LEE, Y. W.; SCHETZEN, M. Measurement of the Wiener kernels of a non-linear system by cross-correlation. **International Journal of Control**, v. 2, n. 3, p. 237-254, 1965.

MARMARELIS, V. Z. Identification of nonlinear biological systems using Laguerre expansions of kernels. **Annals of biomedical engineering**, v. 21, n. 6, p. 573-589, 1993.

MARMARELIS, V. Z. **Nonlinear dynamic modeling of physiological systems**. Hoboken: John Wiley & Sons, 2004.

MARMARELIS, V. Z. University of Southern Carolina BMSR. **Lysis**. Disponível em: <<https://bmsr.usc.edu/software/lysis/>>. Acesso em: Junho 2019.

MCCORRY, L. K. Physiology of the Autonomic Nervous System. **American Journal of Pharmaceutical Education**, v. 71, n. 4, p. 78, 2007.

PELTOLA, M. A. Role of Editing of R-R Intervals in the Analysis of Heart Rate Variability. **Frontiers in physiology**, v. 3, p. 148, 2012.

PENZEL, T. et al. **The Apnea-ECG Database**. Computers in Cardiology 2000. Vol. 27 (Cat. 00CH37163). [S.l.]: IEEE. 2000. p. 255-258.

PUMPRLA, J. et al. Functional assessment of heart rate variability: physiological basis and practical applications. **International journal of cardiology**, v. 84, n. 1, p. 1-14, 2002.

SHEA, M. J. Eletrocardiograma (ECG). **Manual MSD**. Disponível em: <<https://www.msmanuals.com/pt/casa/dist%C3%BArbios-do-cora%C3%A7%C3%A3o-e-dos-vasos-sangu%C3%ADneos/diagn%C3%B3stico-de-dist%C3%BArbios-do-cora%C3%A7%C3%A3o-e-dos-vasos-sangu%C3%ADneos/eletrocardiograma>>.

SHEPARD, J. W. Hypertension, cardiac arrhythmias, myocardial infarction, and stroke in relation to obstructive sleep apnea. **Clinics in chest medicine**, v. 13, n. 3, p. 437-458, 1992.

SILVA, I.; MOODY, G. An Open-source Toolbox for Analysing and Processing PhysioNet Databases in MATLAB and Octave. **Journal of open research software**, v. 2, n. 1, 2014.

SILVA, L. S. C. B. Quantitative Analysis of the Autonomic Nervous System: Toolbox Development and Application, Universidade de Brasília, Brasília, 2017.

SILVA, L. S. C. B.; OLIVEIRA, F. M. S. CRSIDLab: a Toolbox for Multivariate Autonomic Nervous System Analysis Using Cardiorespiratory Identification. **IEEE journal of biomedical and health informatics**, 2019.

SOMERS, V. K. et al. Sympathetic Neural Mechanisms in Obstructive Sleep Apnea. **The Journal of clinical investigation**, v. 96, n. 4, p. 1897-1904, 1995.

TASK FORCE. Heart Rate Variability Standards of Measurement, Physiological Interpretation, and Clinical Use, v. 17, p. 354-381, 1996.

VAN DRONGELEN, W. **Signal Processing for Neuroscientists, A Companion Volume**. 1^a. ed. [S.l.]: Elsevier, 2010.

VOLTERRA, V. **Theory of Functionals and of Integral and Integro-Differential**. Nova York: Dover Publications, Inc, 1959.