UNIVERSIDADE DE CAXIAS DO SUL ÁREA DO CONHECIMENTO DE CIÊNCIAS EXATAS E ENGENHARIAS

LUCAS MORAES DOS SANTOS

SISTEMA AUTOMÁTICO DE DETECÇÃO DO SONO UTILIZANDO CÉLULAS DE CARGA

CAXIAS DO SUL

LUCAS MORAES DOS SANTOS

SISTEMA AUTOMÁTICO DE DETECÇÃO DO SONO UTILIZANDO CÉLULAS DE CARGA

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Bacharel em Engenharia de Computação na Área do Conhecimento de Ciências Exatas e Engenharias da Universidade de Caxias do Sul.

Orientador:

Prof. Dr. Andre Gustavo Adami

CAXIAS DO SUL

LUCAS MORAES DOS SANTOS

SISTEMA AUTOMÁTICO DE DETECÇÃO DO SONO UTILIZANDO CÉLULAS DE CARGA

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Bacharel em Engenharia de Computação na Área do Conhecimento de Ciências Exatas e Engenharias da Universidade de Caxias do Sul.

Orientador:

Prof. Dr. Andre Gustavo Adami

Aprovado em: ___/___/___.

Banca Examinadora

Prof. Dr. Andre Gustavo Adami (orientador) Universidade de Caxias do Sul

Prof. Dr. Guilherme Holsbach Costa Universidade de Caxias do Sul

Prof^a. Dr^a. Adriana Miorelli Adami Universidade de Caxias do Sul

AGRADECIMENTOS

Primeiramente, agradeço a Deus por ter me proporcionado saúde e força, ao longo de toda minha vida, para superar as dificuldades.

A meu pai Joceli, minha mãe Deolinda, minha avó Carlinda (*in memoriam*) e a toda minha família, pelo amor, incentivo e apoio incondicional.

Ao professor Dr. André Gustavo Adami, pela confiança a mim depositada e pelas palavras de sabedoria.

A todos os meus professores (do ensino fundamental a graduação) pelo conhecimento e experiência passados a mim.

E, por fim, a meus colegas de graduação e todos aqueles que, direta ou indiretamente, fizeram parte da minha formação.

"Se enxerguei mais longe, foi porque me apoiei sobre os ombros de gigantes".

Isaac Newton

RESUMO

A qualidade do sono de uma pessoa está diretamente associada à sua saúde. Em vista disso, o monitoramento do sono é um excelente recurso para o diagnóstico e acompanhamento de diversas doenças. A polissonografia, padrão-ouro para monitoramento do sono, é amplamente utilizado em clínicas especializadas em medicina do sono. Porém, por ser um método intrusivo e caro, sua utilização contínua e a longo prazo torna-se inviável. Atualmente, existem diversas técnicas de monitoramento do sono, não-intrusivas, em estudo e desenvolvimento. Elas buscam remover a necessidade de intervenção do usuário ao dispositivo. Uma dessas técnicas faz o uso de células de carga posicionadas sob os suportes da cama, como um método alternativo e nãointrusivo para monitoramento do sono. A partir dos sinais adquiridos, podem ser extraídas informações sobre o ritmo respiratório, ritmo cardíaco e os movimentos da pessoa, informações estas que podem auxiliar no processo de detecção do sono. Diante do exposto, o presente trabalho apresenta o desenvolvimento de um sistema de detecção do sono baseado em aprendizado de máquina, capaz de determinar se um indivíduo está no estado de vigília ou sono, a partir de medições advindas de células de carga acopladas aos suportes do leito. O sistema foi avaliado com base nos resultados obtidos para 39 pacientes, resultando em uma sensitividade (classe acordado) de 50,1% e especificidade (classe dormindo) de 53,1%. Após aplicação de um filtro mediana sobre o sinal advindo da classificação, houve um aumento de 2,8% na sensitividade que ficou em 51,5%, enquanto na especificidade obteve-se 54,8%, que representa um aumento de 3,2%.

Palavras-chave: Detecção do sono. Células de carga. Qualidade do sono.

ABSTRACT

The quality of a person's sleep is directly associated with their health. In view of this, sleep monitoring is an excellent resource for the diagnosis and follow-up of various diseases. Polysomnography, the gold standard for sleep monitoring, is widely used in clinics specializing in sleep medicine. However, because it is an intrusive and expensive method, its continuous and long-term use becomes impracticable. Currently, there are several non-intrusive sleep monitoring techniques under study and development. They seek to remove the need for user intervention on the device. One such technique makes use of load cells positioned under the bed supports as an alternative and non-intrusive method for monitoring sleep. Information about the respiratory rhythm, heart rhythm and movements of the person can be extracted from the acquired signs, which can help in the process of detecting sleep. In view of the above, the present work presents the development of a sleep detection system based on machine learning, able to determine if an individual is in the waking state or sleep, from measurements from load cells coupled to the brackets of the bed. The system was evaluated based on the results obtained for 39 patients, resulting in a sensitivity (awake class) of 50.1% and specificity (sleeping class) of 53.1%. After applying a medium filter on the signal coming from the classification, there was an increase of 2.8% in the sensitivity that remained in 51.5%, while in the specificity was obtained 54.8%, which represents an increase of 3.2 %.

Keywords: Sleep detection. Load cells. Sleep quality.

LISTA DE FIGURAS

Figura 1 – Sinais do PSG em Vigília	19
Figura 2 – Sinais do PSG em Estágio I	20
Figura 3 – Sinais do PSG em Estágio II	21
Figura 4 – Sinais do PSG em Estágio III	22
Figura 5 – Sinais do PSG em Sono REM	23
Figura 6 - Paciente realizando o exame de polissonografia (PSG)	
Figura 7 - Estágios que envolvem a construção de um sistema de classificação de pad	lrões 35
Figura 8 - Ligação dos strain gauges em ponte de Wheatstone	
Figura 9 - Vista em corte longitudinal do transdutor de força (a) e vista superior, com e	os gauges
1 e 3 afixados na superfície superior das lâminas de flexão e gauges 2 e 4, na superfíc	cie oposta
(b)	
Figura 10 - Detalhes construtivos de uma célula de carga	
Figura 11 - (a) Célula de carga (b) Instalação de quatro células de carga acopladas aos	s suportes
do leito	
Figura 12 - Circuito empregado para medição de pressão com sensor piezoelétrico	
Figura 13 – (a) circuito empregado para varrer a distribuição de pressão da matriz do	sensor de
lençol (b) sujeito dormindo em um lençol sensível à pressão e o mapa de	pressão
correspondente	41
Figura 14 - Dois conjuntos de dados linearmente separáveis com hiperplanos de s	separação
rotulados como A.	47
Figura 15 - H1 e H2 são os hiperplanos canônicos. A margem é dada pela	distância
perpendicular entre o hiperplano de separação $gx = 0$ e um hiperplano através do mais	s próximo
ponto da classe $\omega 1 e \omega 2$. Estes pontos são denominados vetores de suporte.	Os eixos
correspondem as características	
Figura 16 - (a) Conjunto de dados não linear; (b) Fronteira não linear no espaço de ent	radas; (c)
Fronteira linear no espaço de características	49
Figura 17 - Os intervalos de confiança de 95% para uma dada probabilidade de erro	estimada
podem ser derivados de uma distribuição binomial. Para cada valor de p , a probabili	dade real
tem 95% de chance de se situar entre as curvas marcadas pelo número de amostras de	e teste n' .
Quanto maior o número de amostras de teste, mais precisa é a estimativa da probabili	idade real
e, portanto, menor o intervalo de confiança de 95%	54
Figura 18 - Processo de detecção do sono	59
Figura 19 - Decréscimo na amplitude do sinal de força devido ao movimento de leva	ntar-se da
cama	60
Figura 20 - Processo de detecção de movimento	61
Figura 21 - Sinal da célula de carga LR. E possível verificar uma variação abrupta na a	implitude
do sinal, durante um curto espaço de tempo, indicando a ocorrência de um moviment	062
Figura 22 - Diferença quadratica média para o sinal da célula de carga LR. Verifica-se	que si2t
e maior em momentos que ha maiores variações no sinal da células de carga, ou	seja, nos
momentos em que na movimento.	
Figura 25 – Segmentação do sinal em periodos de movimento (vermelho) e não-m	ovimento
(azuı)	

Figura 24 - Processo de detecção do ritmo cardíaco	66
Figura 25 - Ritmo cardíaco estimado (vermelho) resultante do processo de detecção	68
Figura 26 - Processo de detecção do ritmo respiratório	69
Figura 27 - Disposição das células de carga	72
Figura 28 - Sinais de células de carga disponíveis na base de dados	73
Figura 29 - Conjunto de características representado em 2-D para o paciente monitorado no) dia
28/01/2011. É possível verificar que há uma dissimilaridade maior entre as classes pa	ra a
maioria das características.	79
Figura 30 - Conjunto de características representado em 2-D para o paciente monitorado no) dia
01/02/2011. É possível verificar a dificuldade de distinguir as duas classes para a maioria	das
características	79
Figura 31 - Desempenho médio dos pacientes selecionados com base na média entre	re a
especificidade e a sensitividade. É possível verificar o aumento na sensitividade, à medida	que
o conjunto de treinamento é formado por mais pacientes. O melhor desempenho se deu para	ı um
conjunto de treinamento com 20 pacientes	80
Figura 32 - Desempenho do sistema após classificação	81
Figura 33 - Desempenho do sistema após aplicação do filtro mediana	81

LISTA DE TABELAS

Tabela 1 – Exemplos de trabalhos desenvolvidos para a detecção automática de estágios do sono. A	Acc.
= taxa de acerto de todas as classes (acurácia), Sen. = taxa de acerto para a classe pertencente ao s	sono
(sensibilidade) e Esp. = taxa de acerto da classe vigília (especificidade)	33
Tabela 2 - Funções de Kernel	50
Tabela 3 – Matriz de confusão 2x2: Verdadeiro Positivos (<i>True Positives</i> - TP), Falsos Positivos	
(False Positives - FP), Falsos Negativos (False Negatives - FN), Verdadeiros Negativos (True	
Negatives - TN).	51
Tabela 4 - Sistemas de classificação do sono em 3 classes (Vigília, REM, NREM)	55
Tabela 5 - Sistemas de classificação do sono em 2 classes (Vigília e Sono)	56
Tabela 6 - Matriz de confusão após aplicação do algoritmo k-means para detecção de presença no	
leito	75
Tabela 7 - Matriz de confusão após aplicação do detector de movimentos (minutos)	75

LISTA DE ACRÔNIMOS

AAMS	Academia Americana de Medicina do Sono
ABS	Associação Brasileira do Sono
Acc	Acurácia
ACF	Short-Term Autocorrelation Function
AMDF	Average Magnitude Difference Function
AOS	Apnéia Obstrutiva do Sono
BCG	Balistocardiografia
BNSQ	Basic Nordic Sleep Questionnaire
СР	Centro de pressão
DFT	Discrete Fourier Transform
DMPM	Distúrbio dos movimentos periódicos dos membros
ECG	Eletrocardiografia
EEG	Eletroencefalografia
EMG	Eletromiografia
EOG	Eletro-oculografia
EQM	Erro quadrático médio
Esp	Especificidade
FFT	Fast Fourier Transform
FN	False Negatives
FP	False Positives
IBI	Intervalo entre batimentos cardíacos
KNN	K-Nearest Neighbor
LDA	Linear Discriminant Analysis
LOOCV	leave-one-out cross validation
LOSOCV	leave-one-subject-out cross validation
LR	likelihood ratio
MAPE	Mean Absolute Percentage Error
MLP	Multilayer Perceptron

msd	Mean Square Difference
MSQ	Mini-sleep Questionnaire
NREM	Non - Rapid Eye Movement
NSQ	Núcleo Supraquiasmático
PCA	Principal Component Analysis
PBS	Pressure Bed Sensor
Prec	Precisão
PRI	Pletismografia respiratória por indutância
PSG	Polissonografia
PVDF	Polyvinylidene fluoride
QDA	Quadratic Discriminant Analysis
REM	Rapid Eye Movement
RNA	Redes Neurais Artificiais
SAHOS	Síndrome da apneia e hipopneia obstrutiva do sono
SBC	Sociedade Brasileira de Cardiologia
Sens	Sensibilidade
SNC	Sistema Nervoso Central
SVM	Support Vector Machines
TN	True Negatives
TP	True Positives
TVAM	Time-Variant Autoregressive Model
VFC	Variabilidade de frequência cardíaca
WDT	Wavelet Discrete Transform

SUMÁRIO

1	Inti	rodu	ção	
	1.1			
	1.2	Estr	utura do trabalho	
2	Fisi	olog	ia do Sono	17
	2.1	Son	0	17
	2.1.	1	Vigília	
	2.1.	2	Sono NREM	
	2.1.	3	Sono REM	
	2.2	Qua	lidade do sono	
	2.2.	1	Insônia	
	2.2.	2	Síndrome da Apneia e Hipopneia Obstrutiva do Sono	25
	2.2.	3	Movimentos Periódicos dos Membros Durante o Sono	
	2.3	Ava	liação da Qualidade do Sono	
	2.3.	1	Polissonografia	
	2.3.	2	Actigrafia	
	2.3.	3	Questionários	
	2.4	Con	siderações Finais	30
3	Det	ecçã	o Automática do Sono	
	3.1	Mét	odos de Detecção Automática do Sono	
	3.2	Prol	plema de Detecção Automática do Sono	
	3.3	Dete	ecção Automática do Sono usando TRANSDUTORES de Força	35
	3.3.	1	Transdutores de Força	
	3.3.	2	Extração de Caraterísticas	41
	3.3.	3	Classificação	
	3.3.	4	Avaliação do Classificador	
	3.4	Sist	emas de Detecção Automática do Sono	54
4	Mét	todo	de Detecção de sono proposto	
	4.1	Proc	cesso de detecção	58
	4.2	Pré-	Processamento	59
	4.2.	1	Detecção de presença no leito	60
	4.2.	2	Detecção de Períodos de Movimento	61
	4.2.	3	Estimativa do ritmo cardíaco	65
	4.2.	4	Estimativa do ritmo respiratório	
	4.3	Exti	ação de características	70

	4.4	Classificação e metodologia de avaliação	70
4	4.5	Decisão	71
5	Aná	ilise ExperimentalErro! Indicador não definid	о.
	5.1	Base de Dados	72
	5.2	Extração dos rótulos e preparação dos sinais empregados na detecção do sono	73
	5.3	Detecção de presença no leito	74
	5.4	Detecção de movimentos	75
	5.5	Ritmo cardíaco	76
	5.6	Ritmo respiratório	76
	5.7	Detecção de sono	17
6	Con	nsiderações Finais	33
Re	eferên	cias	35

1 INTRODUÇÃO

A medicina do sono consiste em uma área da saúde cujo campo de estudo abrange a filogênese e função do sono, bem como a análise de distúrbios associados à privação ou baixa qualidade do sono (HOSHINO, 2008; MARTINEZ, 1999). Tendo seu início na segunda metade do século XX, é um ramo de estudo cujas raízes estão na Neurologia e Neurofisiologia (REMIÃO, 2000). Mas apesar de ser jovem, seu dinamismo está associado à expansão na aquisição e transmissão do conhecimento, impulsionadas pela difusão da informática e imensa velocidade com a qual tornou-se possível transmitir dados, percebidas nas últimas décadas (REMIÃO, 2000). A medicina do sono é caracterizada por sua multidisciplinaridade, já que os problemas da área geralmente exigem o concurso de diferentes áreas do conhecimento (MARTINEZ, 1999). Sua preocupação é maior com a qualidade do sono, do que até mesmo a quantidade deste, haja vista que esta influencia vários aspectos da vida cotidiana tais como a saúde, cognição, memória e comportamento (EL-MANZALAWY *et al.*, 2017).

O sono, por sua vez, caracteriza-se por um estado funcional primordial à manutenção fisiológica do organismo (TUFIK, 2008). De acordo com Martinez (2005, p.28), "O estado de sono ocupa mais ou menos o tempo de vida de cada espécie para modular, permitir ou impedir funções ou comportamentos.". Martinez ainda complementa que a vida desenvolve-se dentro de dois estados, basicamente: a vigília e o sono¹. De acordo com estudos neurofisiológicos, numerosas regiões do cérebro são responsáveis pela regulação entre esses estados (JOUVET², 1967; PACE-SCHOTT & HOBSON³, 2002 *apud* PHILLIPS, 2013), dentre elas o hipotálamo, controlador do sistema neurovegetativo, intervém em diversas funções orgânicas, inclusive a alternância rítmica do ciclo vigília-sono (BENEDITO-SILVA, 2008). A importância do estudo do ciclo vigília-sono pode ser fundamentada a partir da sua capacidade preditiva para surgimento de distúrbios do sono, bem como sua gravidade (GUERRERO-MORA *et al.*, 2012). Pacientes que possuem transtornos relacionados ao sono costumam apresentar irregularidades no ciclo vigília-sono (GUERRERO-MORA *et al.*, 2012). Nesse sentido, e de acordo com Malaekah (2014), o fator mais relevante na avaliação da qualidade de sono é a detecção das fases sono-vigília, a qual permite extrair diferentes medidas estatísticas do sono.

¹ Martinez (2005) afirma que, no caso dos mamíferos, o estado do sono ainda pode ser dividido em sono REM (*rapid eye movement* – movimentos oculares rápidos) e sono REM (*non*-REM – não-REM).

² Jouvet M. Neurophysiology of the states of sleep. Physiol Rev. 1967; 47:117–77. [PubMed: 5342870]

³ Pace-Schott EF, Hobson JA. The neurobiology of sleep: Genetics, cellular physiology and subcortical networks. Nat Rev Neurosci. 2002; 3:591–605. [PubMed: 12154361]

Por outro lado, a deficiência da qualidade do sono é um fator que vem preocupando inúmeros especialistas no campo de estudo do sono. Em seu trabalho, que investiga os indicadores de saúde associados à má qualidade do sono entre universitários, Araújo et al. (2014) estimaram que 96,4% dos 662 estudantes amostrados relataram má qualidade no sono. Esta por sua vez é responsável pelo desenvolvimento de diversos distúrbios ligados ao sono, sendo um deles a apneia obstrutiva do sono (AOS). De acordo com a Academia Americana de Medicina do Sono (AAMS), a AOS pode ser caracterizada pela obstrução completa do fluxo de ar durante o sono apesar da manutenção dos esforços inspiratórios (BITTENCOURT & PALOMBINI, 2008).

Distúrbios do sono geralmente são diagnosticados a partir do exame de polissonografia (PSG). Mas apesar de ser considerado um procedimento padrão no diagnóstico de doenças relacionadas ao sono, a PSG possui algumas inconveniências à sua realização tais como: elevado custo, característica intrusiva e a limitada portabilidade. Estas restrições dificultam a aplicabilidade dessa técnica a estudos em grande escala por mais de uma ou duas noites (AUSTIN *et al.*, 2012; EL-MANZALAWY *et al.*, 2017; GUERRERO-MORA *et al.*, 2012).

Com vistas a contornar as limitações da PSG, tem sido desenvolvidas novas técnicas menos intrusivas à aquisição de sinais fisiológicos. Além de serem mais confortáveis ao paciente, permitem uma melhor precisão e avaliação pois o indivíduo estaria em seu ambiente natural e os estudos seriam conduzidos por períodos de tempo maiores (EL-MANZALAWY *et al.*, 2017; GUERRERO-MORA *et al.*, 2012). Dentre estas técnicas, encontram-se o emprego de sinais de eletroencefalografia (EEG), combinados a sinais de eletro-oculografia (EOG), na detecção dos estágios do sono, separando-os em vigília, sono REM e não-REM (NREM) (KEMPFNER et al., 2012), o uso de sinais cardiorrespiratórios junto a dados advindos de acelerômetros na detecção dos estágios sono-vigília (BIANCHI & MENDEZ, 2010) ou ainda, o uso de sinais de eletrocardiografia (ECG) (JEZZINI et al., 2015) ou de sinais de voz (GOLDSHTEIN et al., 2011) no diagnóstico de AOS.

No entanto, a maioria destas técnicas exigem sensores conectados ao corpo, causando relativa intrusão ao usuário. Além disso, alguns ainda dependem de informações aferidas em exames de PSG. Neste sentido, com vista a prover mais conforto e uma medição mais robusta, pesquisadores têm desenvolvido novas técnicas para aquisição de sinais fisiológicos, não intrusivas e que independam de uma avaliação por PSG. A título de exemplo, está o sensor de pressão integrado ao colchão (PBS – *Pressure Bed Sensor*), que registra sinais de movimentações do corpo causados pelos sistemas cardiovascular e respiratório, permitindo a análise dos batimentos cardíacos, respiração e movimentos corporais (GUERRERO-MORA *et al.*, 2012).

Outra tecnologia não obstrutiva cujo estudo tem sido considerado promissor é a célula de carga. As células de carga caracterizam-se por transdutores de força, geralmente colocados sob os suportes da cama, e medem a força aplicada em cada suporte. Suas medições têm sido usadas na classificação de eventos respiratórios, ou de posições no leito (AUSTIN et al., 2012). Outros estudos usaram das células de carga para estimar a variação de frequência cardíaca e na detecção do sono de ondas lentas (CHOI et al., 2009). Aliado a estas tecnologias, o aprendizado de máquina tem oferecido uma abordagem promissora à construção de modelos detectores dos estados do sono, a partir de sinais fisiológicos (EL-MANZALAWY *et al.*, 2017). Métodos automatizados que se utilizam de algoritmos de inteligência artificial são mais confortáveis e rápidos na detecção de distúrbios do sono, levando a um melhor prognóstico e a um tratamento mais rápido da doença (JEZZINI *et al.*, 2015).

1.1 OBJETIVO

O presente trabalho tem por objetivo desenvolver um sistema de detecção do sono, baseado em aprendizado de máquina, capaz de detectar se um indivíduo está no estado de vigília ou sono a partir de medições advindas de células de carga acopladas aos suportes do leito.

1.2 ESTRUTURA DO TRABALHO

O presente trabalho apresenta a seguinte estrutura:

- O capítulo 2 versará sobre os conceitos relativos aos aspectos fisiológicos do sono, os principais transtornos relacionados a este e como são diagnosticados atualmente e, por fim, a importância na manutenção de um sono com boa qualidade.
- No capítulo 3 será abordado, de forma geral, o processo de detecção automática do sono. Neste capítulo, serão descritas as recentes técnicas empregadas na aquisição de sinais fisiológicos que caracterizam os estágios do sono, além de discorrer sobre as principais etapas do processo de reconhecimento de padrões, em especial, no que se refere ao estagiamento sono-vigília.
- O capítulo 4 abordará sobre a implementação do sistema proposto. Serão descritas as etapas que constituem o sistema de detecção do sono.
- Por fim, o capítulo 5 apresentará os resultados para cada uma das etapas descritas no capítulo 4 e o desempenho geral do sistema de detecção do sono.

2 FISIOLOGIA DO SONO

Durante anos a ciência preocupou-se em compreender os aspectos fisiológicos do sono e dos sonhos. Na falta de recursos tecnológicos que lhes permitissem uma abordagem mais próxima do real, pesquisadores lançavam mão de metodologias empíricas para tentar explicar os fenômenos do sono. Até meados da década de 1940, as teorias convergiam a um caminho que explicava o sono como resultado da diminuição da atividade cerebral (ROSINHA, 2000). Mas foi na década 1950 que as descobertas no campo de estudo do sono tornaram-se marcantes na definição do sono. A partir da compilação dos trabalhos de Aserinsky e Kleitman (1953) e Dement (1955), foram descritas as duas fases básicas de divisão do fenômeno do sono, a fase REM caracterizada por movimentos oculares rápidos, associada geralmente a ocorrência dos sonhos, e a fase não REM, na qual estes movimentos oculares não ocorrem (ROSINHA, 2000; TIMO-LARIA, 2008). Atualmente, sabe-se que o sono deriva-se do sistema nervoso central (SNC), alternando-se ritmicamente com o estado de vigília, desenvolvendo-se em diversas fases consecutivas que se repetem ciclicamente (ANDERSEN & BITTENCOURT, 2008). Ao longo deste capítulo, serão aprofundados os conceitos relativos aos aspectos fisiológicos do sono, bem como a importância na manutenção de um sono com boa qualidade.

2.1 SONO

Martinez (1999, p. 27) define sono como "um estado fisiológico caracterizado por abolição prontamente reversível da consciência, por quiescência motora relativa e por elevação do limiar de respostas ao meio ambiente que ocorre em episódios periódicos". Sua periodicidade pode ser compreendida a partir de uma abordagem cronobiológica, a qual tem por objetivo investigar as características temporais dos organismos vivos (HALBERG4, 1969 apud BENEDITO-SILVA, 2008). Variações regulares de estados nos organismos vivos, por exemplo, correspondem a respostas adaptativas à alternância dos dias e das noites, estações do ano, fases da lua, bem como outros ciclos ambientais (ANOKHIN⁵, 1974 apud BENEDITO-SILVA, 2008). Dentre as adaptações do organismo a fatores exógenos, como a alternância dianoite (claro-escuro), está o ciclo vigília-sono definido por um ritmo cicardiano⁶ gerado e regulado endogenamente por uma estrutura neural, localizada no hipotálamo, denominada

⁴ Halberg F. Chronobiology. Annual Review of Physiology 1969; 31:675-725.

⁵ Anokhin P. Biology and neurophysiology of the conditioned reflex and its role in adaptive behavior. Oxford: Pergamon Press, 1974. p 1-24.

⁶ "[...] em condições naturais este ritmo apresenta sincronização com fatores ambientais e oscila em um período de 24 horas." (ALMONDES; ARAÚJO, 2003, p.37).

núcleo supraquiasmático (NSQ), considerado o relógio biológico aos mamíferos (ASCHOFF⁷, 1979 apud ALMONDES; ARAÚJO, 2003).

A incorporação de mecanismos fisiológicos ativos para promover e sincronizar os períodos de repouso, tal como o ciclo vigília-sono, indica a necessidade de garantir a restauração das condições internas do organismo (BENEDITO-SILVA, 2008). Por ser uma função adaptativa, parece ter sido agregada ao longo dos anos, a partir dos genes responsáveis pelo controle dos ritmos biológicos (HAMET & TREMBLAY, 2006 apud HOSHINO, 2008). A título de exemplo, Hoshino (2008, p. 20) afirma que "as semelhanças comportamentais do sono em aves e mamíferos pode ser explicada como sendo devida à preservação filogenética de um processo que confere funções adaptativas importantes". Nesse sentido, além de compreender o estudo da evolução do sono, a história evolucionária deste possibilita-nos o entendimento do próprio sono, bem como dos processos relacionados a ele (HOSHINO, 2008), estando o ciclo vigília-sono inserido neste contexto. De acordo com Kleitman⁸ (1963, apud BENEDITO-SILVA, 2008), o sono é considerado um processo ativo ligado funcionalmente à vigília, com a qual constitui o ciclo vigília-sono. Enright (1980) ainda afirma que estudar o sono significa investigar sua alocação temporal e da vigília, bem como a alternância rítmica entre esses dois estados, caracterizando a proposição feita por Kleitman. Dessa forma, depreende-se que a compreensão do sono exige a compreensão da vigília (KLEITMAN, 1963, apud BENEDITO-SIVA, 2008).

2.1.1 Vigília

A vigília é um estágio que se dá antes do início do sono e no despertar matinal, além de ocorrer em despertares breves, geralmente nas trocas de estágio do sono, acompanhada de movimentos corpóreos sutis (MARTINEZ, 1999). Acredita-se que a geração e manutenção da vigília dependem de estruturas neurais que estabelecem redes ascendentes as quais projetam-se ao córtex, produzindo ativação cortical representada pelo aumento da atividade do EEG, e redes descendentes que se projetam à medula espinhal, onde estimulam a ativação sensorial-motora, refletida na elevada atividade do eletromiograma (EMG) (HIPÓLIDE, 2008). Durante os estágios do ciclo vigília-sono emergem tipos particulares de oscilações neurais, sendo que cada uma dessas oscilações é caracterizada por uma amplitude e uma frequência distintas

⁷ Aschoff, J. (1979). Circadian rhythms: general features and endocrinological aspects. In D. T. Kriegger (Org.), *Endocrine rhythms* (pp. 1-29). Nova York: Raven Press.

⁸ Kleitman N. Sleep and wakefulness. Chicago: Univ. Chicago Press, 1963.

(NICOLELIS, 2017). Na vigília (Figura 1), o EEG apresenta ondas alfa, em áreas occipitais, com frequência mista, variando em torno de 8 a 12 Hz, e baixa amplitude. Os movimentos oculares são voluntários, consistindo em movimentos sacádicos ou piscamento. O EMG demonstra atividade tônica elevada (MARCHI & BORGES, 2000).

EDG.
EOG De Contraction and the contraction of the contr
and an analytic state of the st
international and and and and and and and a second and a
hat hat hat hat hat hat hat he had had had her her had her
ECG
ResTh
ResAb

Figura 1 - Sinais do PSG em Vigília

Fonte: (MARTÍNEZ, 1999).

2.1.2 Sono NREM

No início da década de 1950, os pesquisadores Eugene Aserinsky, Nathaniel Kleitman e William Dement descreveram os dois estados básicos de divisão do fenômeno do sono, o estado REM, no qual ocorrem movimentos oculares rápidos, e o estado não-REM (NREM) onde estes movimentos não ocorrem (ROSINHA, 2000). O sono NREM, também conhecido por sono de ondas lentas, inicia de forma gradual e é caracterizado pela lentificação da frequência das ondas cerebrais do EEG (HIPÓLIDE, 2008). Para Deboer *et al.*⁹ (2003, *apud* PHILLIPS *et al.*, 2013,

⁹ Deboer T, Vansteensel MJ, Detari L, Meijer JH. Sleep states alter activity of suprachiasmatic nucleus neurons. Nat Neurosci. 2003; 6:1086–1090. [PubMed: 12958601]

tradução nossa¹⁰) "em uma determinada fase circadiana, os neurônios NSQ disparam em taxas semelhantes durante a vigília e o sono REM, mas a uma taxa significativamente menor durante sono NREM", o que acaba por caracterizar sinais de EEG com baixa frequência também. Este estado do sono pode ser dividido em quatro estágios principais, numerados conforme o aparecimento sequencial, sendo reconhecidos por ondas características no EEG e indo do sono mais superficial ao mais profundo (MARTINEZ, 1999).

O estágio I (Figura 2) representa a transição da vigília para o sono, e os movimentos oculares são lentos e intermitentes. O EEG apresenta ondas teta com amplitude relativamente baixa e frequência mista, com valores na faixa de 3 a 7 Hz. O EMG permanece tônico, embora em menor nível que durante a vigília (MARCHI & BORGES, 2000).



Figura 2 - Sinais do PSG em Estágio I

Fonte: (MARTÍNEZ, 1999).

No estágio II (Figura 3) surgem dois tipos de ondas características, sobrepondo o ritmo teta: os complexos K e os fusos. Os complexos K são ondas difásicas com amplitude elevada. Os fusos caracterizam-se por ondas de 12 a 15 Hz, frequentemente sinusoidais, com amplitude baixa ou moderada. O EMG se reduz, indicando que o tono muscular ficou menor, e as movimentações oculares não são percebidas (MARCHI & BORGES, 2000).

¹⁰ "At a given circadian phase, SCN neurons fire at similar rates during Wake and REM sleep, but at a significantly lower rate during NREM sleep."





Fonte: (MARTÍNEZ, 1999)

Nos estágios III e IV (Figura 4) verificam-se ondas delta no EEG, de elevada amplitude e baixa frequência, em torno de 0,3 a 2 Hz, indicando o sono profundo. O EMG se reduz, mas ainda permanece ativo (MARCHI & BORGES, 2000).





Fonte: (MARTÍNEZ, 1999).

2.1.3 Sono REM

Em 1953, pesquisadores constataram em bebês humanos que os períodos "ativos" do sono eram caracterizados por elevada movimentação ocular, e que esses períodos intercalavamse com períodos de sono quiescentes (ASERINSKI & KLEITMAN, 1953). Anos mais tarde, Kleitman e Dement mostraram que esses movimentos rápidos dos olhos em adultos estavam associados a ondas cerebrais específicas e a períodos do sono em que a pessoa estava sonhando (PEEVER & FULLER, 2016). A constatação de períodos de sono com dessincronização da atividade eletro-cortical, a partir da ativação da formação reticular mesencefálica, resultou na descoberta do sono REM, ou paradoxal (HIPÓLIDE, 2008; MARTÍNEZ, 1999). Neste estado do sono, neurônios ativos incluem células que enviam projeções ascendentes ao córtex, eliminando a atividade cortical rápida, e aquelas com projeções descendentes ao tronco encefálico e à medula espinhal, diminuindo tônus muscular (HIPÓLIDE, 2008). Segundo Iber *et al.*¹¹ (2007, *apud* PHILLIPS *et al.*, 2013), no sono REM (Figura 5) os sinais EEG possuem baixa amplitude e elevada frequência, semelhante ao estágio I do sono NREM. As ondas Teta assumem uma característica bífida, similar a dentes de serra, sendo importante no reconhecimento do sono REM (MARTINEZ, 1999). Percebe-se também uma movimentação ocular rápida, caracterizada por sinais advindos do EOG com uma oposição de fase e amplitude elevada. O EMG reduz-se ao mínimo¹² neste estado do sono, com uma atonia muscular que estende-se por toda musculatura corporal, exceto o diafragma e músculos oculomotores (MARTINEZ, 1999).

Figura 5 – Sinais do PSG em Sono REM



Fonte: (MARTÍNEZ, 1999).

¹¹ Iber, C.; Ancoli-Israel, S.; Chesson, A.; Quan, SF. The AASM manual for the scoring of sleep and associated events: Rules, terminology and technical specifications. American Academy of Sleep Medicine; Westchester, Illinois: 2007.

¹² "No deitar, pela mudança dos vetores gravitacionais, os músculos posturais relaxam completamente e não servem para sinalizar a atonia do REM. Por isso, usa-se como critério eletrográfico do sono REM o registro da eletromiografia dos músculos do pescoço ou do queixo, que só relaxam nesse estágio" (TUFIK, 2008, p. 38).

2.2 QUALIDADE DO SONO

Muito embora o sono seja um estado fisiológico fundamental ao organismo, torna-se cada vez mais comum a restrição crônica do sono, principalmente no âmbito das sociedades industrializadas, afetando uma parcela de aproximadamente 45% da população (TUFIK, 2008). A qualidade do sono é reconhecidamente um parâmetro preditivo de saúde mental, vitalidade e bem-estar (OHAYON *et al.*, 2017). Em vista disso, estudos na busca da compreensão dos mecanismos de manutenção do sono e da vigília, bem como as consequências da privação do sono, têm adquirido o interesse de inúmeros pesquisadores nos últimos anos (TUFIK,2008). Compreender a qualidade do sono e os fatores que afetam esta é de particular importância, em vista de uma maior conscientização pública acerca do sono como um componente de saúde e bem estar (OHAYON, 2017). Nesse sentido, Bin (2016) ressalta a importância da qualidade do sono, por vezes mais importante que a própria duração do sono, na previsão da saúde futura.

A má qualidade do sono tem sido relacionada a diversas consequências adversas à saúde (AUSTIN *et al.*, 2012). Em seu estudo, Bin (2016), a partir de meta-análises, mostra que o desenvolvimento de hipertensão e diabetes fica em torno de 20 a 30%, associado ao sono de curta duração. Quanto à baixa qualidade do sono, tem-se taxas que variam de 5 a 20% para o desenvolvimento de hipertensão e 40% para diabetes, dependendo do distúrbio operacionalizado. Ainda foram observadas consequências diurnas associadas à baixa qualidade do sono tais como angústia significativa e comprometimento funcional (ANCOLI-ISRAEL & ROTH¹³, 1999, *apud* SHORT *et al.*, 2016), aumento de sintomas de transtorno de estresse depressivo e pós-traumático, e a necessidade do uso de substâncias para melhorar a qualidade do sono (WRIGHT *et al.*¹⁴, 2011; VANDREY *et al.*¹⁵, 2014 *apud* SHORT *et al.*, 2016).

Existem fatores também que afetam diretamente a qualidade do sono. Um deles é a insônia, geralmente associada à redução da quantidade de horas necessárias a um sono saudável (JÚNIOR, 2008). Essa redução pode estar relacionada a hábitos e condições ambientais inadequadas ao estabelecimento do sono, provocadas pelo próprio indivíduo (JÚNIOR, 2008). Dentre estes hábitos inapropriados estão o horário irregular da pessoa ir para a cama, o uso de estimulantes, principalmente à base de cafeína, ou a ingestão de bebidas alcoólicas próximo a

¹³ Ancoli-Israel, S., & Roth, T. (1999). Characteristics of insomnia in the United States: Results of the 1991 National Sleep Foundation Survey. Sleep, 22, S347–53.

¹⁴ Wright, K. M., Britt, T. W., Bliese, P. D., Adler, A. B., Picchioni, D., & Moore, D. (2011). Insomnia as predictor versus outcome of PTSD and depression among Iraq combat veterans. The Journal of Clinical Psychiatry, 57, 1240–1258.

¹⁵ Vandrey, R., Babson, K. A., Herrmann, E. S., & Bonn-Miller, M. O. (2014). Interactions between disordered sleep, post-traumatic stress disorder, and substance use disorders. International Review of Psychiatry, 26, 237–247.

hora de dormir, o uso crônico de hipnóticos, sobretudo os benzodiazepínicos, e o envolvimento com outras atividades na cama antes de dormir (JÚNIOR, 2008). Pacientes que sofrem da AOS também reclamam da excessiva sonolência diurna, resultando não somente na substancial deterioração do sono como também, da qualidade de vida. Alterações no padrão de atividade motora durante o sono podem ser um indicador de doença. Em vista disso, é importante levar em consideração as condições individuais, sociais e ambientais que promovem o bem estar físico e mental, promovendo assim um sono saudável com duração adequada, eficiente e constante alerta na vigília (BUYSSE, 2014).

2.2.1 Insônia

Em medicina do sono, o termo insônia é usado para designar sintomas relacionados a dificuldades de iniciar o sono, dificuldades de manutenção do sono, ou alguma combinação dos mesmos que ocorrem apesar da oportunidade e circunstância adequadas para dormir (PILLAI *et al.*, 2015). O distúrbio de insônia crônica atinge, aproximadamente, 10% dos adultos (CHUNG *et al.*¹⁶,2015 *apud* KAY *et al.*, 2016), estando associado a prejuízos cognitivos, redução da produtividade durante o trabalho, baixa qualidade de vida, transtornos mentais comórbidos, custos mais altos à saúde e risco de mortalidade (LÉGER *et al.*¹⁷, 2016; PARTHASARATHY *et al.*¹⁸, 2015 *apud* KAY, 2016). Somente no Brasil, segundo estimativas da Associação Brasileira do Sono (ABS), 73 milhões de brasileiros sofrem de insônia, problema cada vez mais comum na maioria da população, em especial nas grandes cidades, devido ao ritmo da vida urbana e estresse do dia a dia (VARELLA, 2018). A insônia pode ser diagnosticada através de polissonografia, a qual pode mensurar, por meio da avaliação da eficiência do sono, o tempo efetivo de sono durante uma noite. Para um sono normal, a eficiência deve ser acima de 85%, sendo que o aumento da latência para iniciar o sono ou dos despertares durante o sono podem ser indicativos do distúrbio de insônia (JÚNIOR, 2008).

2.2.2 Síndrome da Apneia e Hipopneia Obstrutiva do Sono

A síndrome da apneia e hipopneia obstrutiva do sono (SAHOS) ocorre durante o sono, sendo caracterizada por um recorrente colapso faríngeo que acaba por obstruir o fluxo de ar,

¹⁶ Chung KF, Yeung WF, Ho FY, Yung KP, Yu YM, Kwok CW. Crosscultural and comparative epidemiology of insomnia: the Diagnostic and Statistical Manual (DSM), International Classification of Diseases (ICD) and International Classification of Sleep Disorders (ICSD) Sleep Med 2015;16:477–82.

¹⁷ Léger D, Bayon V. Societal costs of insomnia. Sleep Med Rev 2010;14:379–89.

¹⁸ Parthasarathy S, Vasquez MM, Halonen M, et al. Persistent insomnia is associated with mortality risk. Am J Med 2015;128:268–75.

causando repetidos despertares do sono (MANUEL & HARDINGE, 2016). A obstrução faríngea poderá ser completa (apneia) ou parcial (hipopneia) (JORDAN *et al.*, 2014). Na apneia, a interrupção das vias aéreas ocorre por mais de 10 segundos, e sua gravidade é calculada pelo número de ocorrências por hora¹⁹. No caso da hipopneia, a redução do fluxo aéreo é em torno de 50% em relação ao fluxo normal (MANUEL, 2016; BITTENCOURT & PALOMBINI, 2008). Sintomas comuns, indicativos da SAHOS, são a dificuldade de iniciar ou manter o sono, fadiga ou o cansaço e a cefaleia matinal (JORDAN *et al.*, 2014). A ocorrência de morte em indivíduos que sofrem da SAHOS está associada a fatores coadjuvantes potentes, dentre eles a obesidade, hipertensão e doenças cardiovasculares (REIMÃO & JOO, 2000).

De acordo com Jordan et al. (2014), a AOS é considerada um problema de saúde global e, apesar de não apresentar altas taxas de obesidade²⁰, o Brasil, junto a vários países asiáticos, apresenta elevados percentuais de desenvolvimento da apneia. Devido à seriedade da doença, torna-se crucial um diagnóstico eficaz, atualmente obtido por polissonografia. O PSG envolve um monitoramento simultâneo dos parâmetros fisiológicos do sono, coração e da respiração, usando múltiplos dispositivos sensoriais que realizam a aquisição dessas variáveis (JORDAN *et al.*, 2014; EL-MANZALAWY *et al.*, 2017).

2.2.3 Movimentos Periódicos dos Membros Durante o Sono

De acordo com Rogers *et al.* (2011), o distúrbio dos movimentos periódicos dos membros (DMPM) durante o sono caracteriza o transtorno em que o indivíduo apresenta uma movimentação repetitiva e altamente estereotipada dos membros inferiores (geralmente, braços ou pernas), durante o sono. Os movimentos duram em média de 0.5 a 5 segundos, ocorrendo a cada 20, 40 segundos (MELLO & ESTEVES, 2008). Estudos apontam que a disfunção do sistema neurotransmissor dopaminérgico²¹ influencia no desenvolvimento do DMPM (VETRUGNO *et al.*²², 2006 *apud* ROGERS *et al.*, 2011; MELLO & ESTEVES, 2008). A ocorrência maior que cinco movimentos por hora durante o sono é considerada um padrão patológico (WALTERS *et al.*, 1995 *apud* MELLO & ESTEVES, 2008). O DMPM costuma

¹⁹ "AOS grave pode ser definida como tendo um índice de apneia e hipopneia (IAH) maior que 35 / hora durante a noite e sono normal como tendo um IAH inferior a 5 / hora" (MANUEL & HARDINGE, 2016, p.1).

²⁰ A obesidade é considerada um dos principais fatores de risco ao desenvolvimento da SAHOS (JORDAN et al, 2014).

²¹ Dopamina - neurotransmissor associado ao movimento, atenção, aprendizado e sistema de prazer e recompensa do cérebro. PubMed Health [Internet]. Bethesda (MD), USA. [citado em 11 de Agosto de 2018]. Disponível em: https://www.ncbi.nlm.nih.gov/pubmedhealth/PMHT0024929/.

²² Vetrugno R, Provini F, Montagna P. Restless legs syndrome and periodic limb movements. Rev Neurol Dis 2006;3:61-70.

incidir após os 30 anos, e a prevalência é maior em pacientes idosos, atingindo taxas em torno de 44% para indivíduos com idade acima de 65 anos (BIXLER *et al.*, 1982 *apud* MELLO & ESTEVES, 2008; CHELLAPPA, 2009).

Dentre os sintomas característicos do DMPM estão o cansaço, estresse, insônia e a hipersonolência. Além disso, é comum o transtorno acometer pessoas que sofrem de problemas mentais (BIXLER *et al.*, 1982 *apud* MELLO & ESTEVES, 2008). Seu diagnóstico pode ser obtido a partir de uma avaliação por polissonografia, ou ainda por actigrafia, usada na monitoração da atividade motora generalizada ou específica (MELLO & ESTEVES, 2008).

2.3 AVALIAÇÃO DA QUALIDADE DO SONO

Os métodos diagnósticos utilizados na investigação dos distúrbios do sono incluem a aplicação de questionários específicos e a coleta de informações biológicas por meio de exames de polissonografia e registros actigráficos (TOGEIRO & SMITH, 2005).

2.3.1 Polissonografia

Júnior e Silva (2008, p. 161) afirmam que "a polissonografia, introduzida na medicina a partir da década de 1960, é atualmente o principal método para diagnóstico dos distúrbios do sono". Nesse sentido, caracteriza-se por uma técnica tradicional²³ que permite avaliar a qualidade do sono a partir de diversos sinais fisiológicos durante o sono (GUERRERO-MORA *et al.*, 2012). A PSG efetua vários registros, tais como sinais EEG, EOG, EMG de mento, ECG, fluxo aéreo nasal e bucal, movimentos respiratórios, posição corporal e saturação de oxigênio (SPO2) (JÚNIOR & SILVA, 2008; HACHEM, 2015). De posse desses registros resultam alguns parâmetros importantes tais como: latência para iniciar o sono, latência para despertar do sono, latência e densidade do sono REM²⁴, tempo total de sono, tempo total de despertar e, por fim, eficiência do sono ou seja, a razão entre o tempo total de sono e o tempo total no leito (DEVOT *et al.*, 2010). O exame é aplicado em laboratórios do sono (Figura 6), em hospitais e clínicas, e sua execução se dá durante a noite inteira (MARTINEZ *et al.*, 1999).

²³ De acordo com Martínez (1999, p.76), "Para praticar a especialidade, o médico necessita dominar as bases conceptuais dos atos de solicitar, realizar e interpretar o exame."

²⁴ "Define-se densidade REM a quantidade de movimentos oculares rápidos compreendida dentro de um período REM (TUFIK, 2008)."



Figura 6 - Paciente realizando o exame de polissonografia (PSG)

Fonte: (BITTENCOURT & CAIXETA, 2010)

Apesar de ser considerado o padrão ouro no estudo e avaliação de transtornos do sono, a PSG possui algumas limitações que acabam por dificultar sua aplicação. Dentre estas limitações estão o elevado custo do exame, característica intrusiva, pois o paciente necessita ser conectado a diversos dispositivos através de eletrodos e interfaces, limitada portabilidade, pois à realização da PSG o indivíduo necessita pernoitar em um ambiente desconhecido e artificial, geralmente um laboratório em clínicas de sono (AUSTIN *et al.*, 2012). O ambiente deve estar a uma temperatura em torno de 22 e 24°C, permitindo que os pacientes possam dormir bem e que também, não ocorram dados inadequados, interferindo na posterior interpretação dos resultados (MARTINEZ, 1999). Os registros da PSG geralmente são realizados por técnicos em polissonografia (GUERRERO-MORA *et al.*, 2012).

2.3.2 Actigrafia

Actigrafia é uma técnica caracterizada pela medição da atividade motora a partir de dados advindos de acelerômetros (DEVOT, 2010). O método oferece uma alternativa de baixo custo a PSG convencional (EL-MANZALAWY *et al.*, 2017). O exame é mais objetivo na validação do ciclo vigília-sono. Um actígrafo²⁵ é fixado a um membro do paciente, geralmente ao pulso não dominante, para registrar os movimentos. Um aumento da atividade caracteriza o estado de vigília e a redução, o sono (JÚNIOR, 2008).

²⁵ Actígrafo: é um acelerômetro que fornece medidas úteis do ciclo vigília-sono e QS através da detecção dos movimentos dos membros durante 24 horas (MOREIRA *et al.*, 2016).

O uso da actigrafia na avaliação da qualidade do sono requer métodos confiáveis na detecção dos estados sono-vigília a partir dos dados mensurados, tendo sido propostos alguns algoritmos baseados em aprendizado de máquina para solucionar este problema (EL-MANZALAWY *et al.*, 2017). O emprego da técnica nos diagnósticos de insônia ainda é controverso, sendo associada em alguns casos a um diário de sono²⁶ que poderá fornecer mais dados sobre o sono do paciente (JÚNIOR, 2008). Ainda assim, o método requer que o paciente use o actígrafo durante o sono, e que o dispositivo fique acoplado de forma consistente ao corpo (AUSTIN *et al.*, 2012). Para um monitoramento a longo prazo, o paciente deverá efetuar o download regular dos dados capturados, e manter os registros do horário que foi à cama, bem como do horário que levanta, com vistas a evitar a perda dos dados, bem como a interpretação incorreta destes (AUSTIN *et al.*, 2012).

2.3.3 Questionários

Diferentes questionários podem ser utilizados na rotina clínica para fins diagnósticos, na monitorização da resposta ao tratamento instituído, em estudos epidemiológicos e em pesquisa clínica. Na sua maioria, eles são internacionais e poucos são validados para a língua portuguesa, sendo que erros de interpretação, bem como aspectos culturais, podem influenciar a especificidade e sensibilidade destes métodos (TOGEIRO & SMITH, 2005).

Alguns deles avaliam o sono em seus aspectos gerais, dando enfoque ao tempo para o seu início (latência do sono), qualidade, aspectos comportamentais, presença de despertares e sonolência diurna. Dentre esses, destacam-se o *Sleep Disorders* Questionnaire (GORESTEIN et al., 2000), com questões de avaliação quantitativa e qualitativa; o *Pittsburgh Sleep Quality Index* (GORESTEIN et al., 2000), que refere-se à qualidade do sono no último mês, fornecendo um índice de gravidade e natureza do distúrbio; o *Mini-sleep Questionnaire* (MSQ) (GORESTEIN et al., 2000), que avalia a freqüência das queixas; o *Basic Nordic Sleep Questionnaire* (BNSQ) (PARTINEN & GISLASON, 1995), que analisa as queixas mais comuns em termos de frequência e intensidade nos últimos três meses com especificação quantitativa; e o questionário de auto-avaliação do sono (GORESTEIN et al., 2000), utilizado em pesquisas psicofarmacológicas (TOGEIRO & SMITH, 2005).

O outro grupo é o dos questionários mais direcionados e específicos para determinadas alterações, tendo como mais conhecidos e utilizados a escala de sonolência de Epworth

²⁶ "Para se obter um perfil dos hábitos de vida e aqueles relacionados ao sono, pode-se utilizar um diário de sono, por um determinado período de tempo, compreendido de 7 a 14 dias" (TUFIK, 2008, p.211).

(JOHNS, 1991), cuja pontuação vai de 0 a 24, sendo caracterizada a sonolência excessiva para valores acima de 10; a escala de sonolência de Stanford (GORESTEIN et al., 2000), que se refere ao estado momentâneo de sonolência; aqueles para avaliação dos distúrbios respiratórios do sono, como os de Hoffstein, Douglass, Deegan e o do Fletcher e Luckett (FLETCHER & LUCKETT, 1991; CHERVIN, 2003); os questionários para avaliação do ritmo sono-vigília (CHERVIN, 2003; HORNE & OSTBERG, 1976); e os específicos para utilização em pediatria (TOGEIRO & SMITH, 2005).

2.4 CONSIDERAÇÕES FINAIS

Diante do exposto, fica clara a necessidade de desenvolver técnicas de avaliação da qualidade do sono que sejam alternativas à PSG. Em virtude das inconveniências impostas pelo exame, sua aplicabilidade em larga escala populacional é prejudicada. Além disso, torna-se inviável manter o paciente com PSG durante longos períodos de tempo. Tal constatação é deveras preocupante, haja vista que determinadas doenças relacionadas ao sono não são facilmente diagnosticadas, necessitando de uma avaliação mais duradoura e, principalmente, contínua. Ainda que a actigrafia tenha surgido com o propósito de contornar os problemas relacionados à PSG, a técnica ainda é intrusiva pois depende que o paciente mantenha controle das atividades relacionadas ao ato de dormir, como por exemplo o horário. A falta de informações ou perda dos registros realizados durante o sono poderá acarretar em uma incorreta avaliação dos resultados. Além disso, ainda que a actigrafia se comporte positivamente quando aplicada ao estagiamento sono-vigília, para análises onde é necessário detectar fases mais específicas do sono, como os estados do sono NREM, sua aplicabilidade, por vezes, é deficiente. Em vista disso, torna-se crucial a investigação de técnicas alternativas à detecção de estágios do sono.

3 DETECÇÃO AUTOMÁTICA DO SONO

Em vista das desvantagens relacionadas a PSG tais como alto custo, portabilidade limitada e característica intrusiva, diversos pesquisadores tem focado seus estudos no desenvolvimento de técnicas e sensores que permitam registrar o sono de maneira não intrusiva. Com isso, possibilita-se uma avaliação contínua da qualidade do sono. O presente capítulo fará uma abordagem dos principais e mais recentes estudos que propõem novas técnicas à detecção dos estágios e distúrbios do sono.

3.1 MÉTODOS DE DETECÇÃO AUTOMÁTICA DO SONO

Os métodos de detecção automática do sono podem ser categorizados pelo número de estados a serem identificados. Alguns pesquisadores buscam identificar os estados sono-vigília (*Sleep/Wake*) (ORELLANA et al., 2014) (MALAEKAH et al., 2014), enquanto outros propõem técnicas que visam separar o sono nos estágios REM e NREM (*Wake*/REM/NREM) (KEMPFNER et al., 2013). A fim de produzir um método diagnóstico alternativo, muitos estudos têm sugerido a redução da quantidade de eletrodos sobre a pele na detecção do sono de forma automática (MALAEKAH et al., 2014). Em geral, costumam ser avaliados dados de actigrafia, sinais cardiorrespiratórios, ou sinais EEG/EOG no estagiamento do sono (DEVOT et al., 2010).

Muitos grupos de pesquisa têm desenvolvido sistemas de classificação de sono-vigília baseados em actigrafia (ORELLANA et al., 2014; EL-MANZALAWY et al., 2017). Na maioria destes estudos, a detecção dos estados do sono é realizada com o auxílio de algoritmos de aprendizado de máquina (EL-MANZALAWY et al., 2017). Orellana et al. (2014) utilizam redes neurais artificiais treinadas em dados de actigrafia de pulso para identificar as fases do sono (vigília e sono) por épocas de 1 minuto (uma decisão é produzida para um minuto completo) de adolescentes com uma faixa etária de 15 anos. El-Manzalawy et al. (2017) utilizam algoritmos de aprendizado não supervisionados e heurísticas estimados em dados não rotulados de actigrafia de um grupo de 37 pessoas de diferentes faixas etárias para detectar os estados de sono-vigília. Ambos trabalhos usaram da PSG para avaliar os classificadores desenvolvidos e de modelos baseados em aprendizado de máquina na construção dos detectores sono-vigília.

A respiração também é uma das principais medidas no monitoramento dos distúrbios relacionados ao sono (GUERRERO-MORA *et al.*, 2012). Tataraidze et al. (2015) propõe um sistema de detecção de vigília e dos estágios REM e NREM do sono, a partir de sinais de

pletismografia respiratória por indutância (PRI) advindos de cintos torácicos presentes nos pacientes. Por outro lado, Guerrero-Mora et al. (2012) desenvolveram um algoritmo capaz de identificar os estágios sono-vigília baseado em sinais de movimentos respiratórios, advindos de sinais de balistocardiografia (BCG) registrados, de forma não intrusiva, por um sensor de pressão no leito. O sensor mede a força dinâmica causada pelos esforços respiratórios, uma vez que durante o sono a respiração é a principal fonte de movimentos (GUERRERO-MORA *et al.*, 2012). No mesmo sentido, Austin *et al.* (2012) propõem um detector sono-vigília não intrusivo, empregando células de carga acopladas aos suportes do leito de pacientes que realizam simultaneamente a PSG. A partir dos dados advindos das células de carga, os pesquisadores estimaram os sinais de centro de pressão (CP), respiração e movimentos no leito (AUSTIN et al., 2012). Para caracterizar a respiração do paciente, foi estimada a frequência de pico do sinal respiratório, e o sinal de CP (nas direções x e y), usando a Transformada rápida de Fourier (FFT, do inglês: *fast Fourier Transform*). De posse destas informações, foi aplicado um algoritmo de aprendizado de máquina para classificar os períodos em sono ou vigília (AUSTIN et al., 2012).

Diversos trabalhos têm demonstrado um alinhamento dos sinais ECG e de variabilidade da frequência cardíaca (VFC) aos sinais respiratórios, o que tem proporcionado o estudo de novas técnicas à detecção de estágios e distúrbios do sono (BIANCHI & MENDEZ, 2010). Devot et al. (2010) combinaram sinais cardiorrespiratórios a dados de actigrafia para avaliar o desempenho de um classificador dos estágios sono-vigília. A partir de sinais de PRI, foram extraídas algumas medidas estatísticas referentes à respiração, dentre elas a mediana de pico a vale de um ciclo respiratório, semelhante a abordagem realizada, anos mais tarde, por Tataraidze et al. (2015). Junto a estas informações, os pesquisadores combinam séries de intervalos RR²⁷, derivadas de ECG, e dados de actigrafia (DEVOT et al., 2010). Os autores concluem que o uso de características advindas de atividades cardíacas e respiratórias podem melhorar a acurácia de detectores sono-vigília, apresentando resultados melhores do que aqueles baseados somente em actigrafia. Mendez et al. (2009) propõe um sistema de detecção dos estágios REM e NREM do sono baseado em sensores colocados no colchão da cama. Neste trabalho a variabilidade de frequência cardíaca (VFC) foi obtida a partir do intervalo entre batimentos cardíacos (IBI) e sinais de movimentos, extraídos de sinais de BCG do sensor de leito (MENDEZ et al., 2009). A partir disso, os pesquisadores estimaram os componentes

²⁷ Os intervalos RR caracterizam-se por variações cíclicas na duração de um batimento cardíaco (intervalo de tempo entre uma onda R e a próxima onda R) (JEZZINI et al., 2015).

espectrais dos intervalos RR usados na obtenção do subconjunto de características para separar os estágios do sono em REM e NREM (MENDEZ et al., 2009).

Ainda existem estudos que sugerem o uso de sinais de EEG e EOG na detecção de estágios do sono. Kempfner *et al.* (2013) propõe um detector automático dos estágios de vigília, sono REM e NREM usando sinais advindos dos canais de EEG e EOG (esquerdo e direito). Sobre os sinais foi aplicado um filtro *Butterworth* passa banda com frequências de corte que variavam de 1 a 5 Hz, com vistas a selecionar as frequências características de cada estágio do sono. Sobre as bandas de frequência EEG e ECG obtidas, foram estimadas algumas variáveis estatísticas, bem como extraídas algumas características posteriormente usadas no detector (KEMPFNER et al., 2015). Usando de uma abordagem semelhante, Malaekah et al. (2014) desenvolveram um sistema para detecção de estágios sono-vigília usando apenas sinais de EOG. Em ambos os estudos, os registros de EEG e EOG foram obtidos a partir de avaliações por PSG sobre diversos pacientes (KEMPFER et al., 2013; MALAEKAH et al., 2014).

A Tabela 1 apresenta alguns trabalhos desenvolvidos na área de detecção de estágios do sono, bem como seus respectivos desempenhos. Os resultados mostram que o número de estágios não influencia no desempenho dos métodos. Esperava-se que o problema de duas classes seria mais simples, mas não é o que os resultados mostram.

Trabalho	Técnica de	Sinais	Número de	Estágios do	Desempenho
	aquisição	mensurados	participantes	sono	
Austin et al.	Células de	Respiratórios e	07 . 1. (1	V. 4.	Esp.: 81.2
(2012)	carga	movimentos	27 individuos	vigilia e sono	Sen.: 80.8
Devot et al	ECG DDI a	Cardíacos,			Acc.: 85.3
(2010)	eco, rkie	respiratórios e	36 indivíduos	Vigília e sono	Esp.: 67.7
(2010)	actigiana	movimentos			Sen.: 91.3
El Monzoloury					Acc.: 85.0
(2017)	Actigrafia	Movimentos	37 indivíduos	Vigília e sono	Esp.: 98.0
(2017)					Sen.: 30.0
Guarrara Mora	Sensor de pressão no	Respiratórios	20 indivíduos	Vigília e sono	Acc.: 81.9
(2012)					Esp.: 83.6
(2012)	leito (PBS)				Sen.: 83.6
Kompfpor at al	FEG e EOG			Vigilia PEM	Acc.: 91.0
(2013)	(PSG)	EEG e EOG	40 indivíduos	o NREM	Esp.: 93.0
(2013)	(150)			CINKEN	Sen.: 87.0-95.0
Malaekah et al.	FOG (PSG)	FOG	18 indivíduos	Vigilia a sono	Esp.: 91.5
(2014)	E00 (F30)	EOO		v Igilia e solio	Sen.: 84.5
Mendez et al.	Sansor da laita	Cardíacos	6 indivíduos	Vigília, REM	Acc.: 83.0
(2009)	Sensor de leito	Cardiacos	omaividuos	e NREM	
Orallana at al					Acc.: 92.8
(2014)	(2014) Actigrafia	Movimentos	119 indivíduos	Vigília e sono	Esp.: 73.4
(2014)					Sen.: 97.6

Tabela 1 – Exemplos de trabalhos desenvolvidos para a detecção automática de estágios do sono. Acc. = taxa de acerto de todas as classes (acurácia), Sen. = taxa de acerto para a classe pertencente ao sono (sensibilidade) e Esp. = taxa de acerto da classe vigília (especificidade).

Trabalho	Técnica de aquisição	Sinais mensurados	Número de participantes	Estágios do sono	Desempenho
Tataraidze et al. (2015)	PRI	Respiratórios	29 indivíduos	Vigília, REM e NREM	Acc.: 80.4
Γ_{1} (Γ_{1}) Γ_{1}) Γ_{1} (Γ_{1}) Γ_{1} (Γ_{1}) Γ_{1}) Γ_{1}) Γ_{1}) Γ_{1} (Γ_{1}) Γ_{1}) Γ_{1	1				

Fonte: Elaborada pelo autor.

3.2 PROBLEMA DE DETECÇÃO AUTOMÁTICA DO SONO

A detecção automática do sono pode ser tratada como um problema de reconhecimento de padrões de duas classes, onde o objetivo é determinar se um padrão observado corresponde ao estado de vigília ou sono. Assim, o problema pode ser formulado como um teste de duas hipóteses mutuamente exclusivas:

- H_0 , conhecida como hipótese nula, a pessoa está acordada;
- H_1 , hipótese alternativa, a pessoa está dormindo.

Como são somente duas hipóteses, o teste da razão da verossimilhança (LR, do inglês: *likelihood ratio*) é utilizado para tomar uma decisão (FUKUNAGA, 1990). O classificador ótimo pode ser obtido pelo teste de razão da verossimilhança, entre duas hipóteses e um limiar, pode ser representado por

$$\frac{p(f|H_1)}{p(f|H_0)} \stackrel{H_1}{\underset{H_0}{\geq}} \lambda,$$

onde $p(f|H_i)$ é a função de verossimilhança para a hipótese H_i , $i = \{0,1\}$, avaliada para amostra $f \in \lambda$ é o limiar de decisão (também conhecido como ponto de operação). Também conhecida por regra de decisão de Bayes, a regra pode ser interpretada da seguinte forma: para uma dada amostra f, a hipótese H_1 será aceita, caso a razão de verossimilhança seja maior que um limiar λ , que é independente de f (DUDA et al., 2000).

Existem dois tipos de erros que podem ocorrer em um sistema de detecção. Erros do tipo I ocorrem quando a hipótese nula H_0 é rejeitada quando é verdadeira. Os erros deste tipo são chamados de perdas (do inglês *misses*), isto é, o sistema decide que a pessoa está dormindo quando a mesma não está. Erros do tipo II ocorrem quando a hipótese nula não é rejeitada quando for falsa. Os erros deste tipo são chamados de falso alarme (do inglês, *false alarm*), isto é, o sistema decide que a pessoa está acordada quando a mesma está dormindo.

Em geral, o processo de construção de um sistema de reconhecimento de padrões possui os seguintes estágios (Figura 7): aquisição de dados, extração de características, classificação e

avaliação do classificador (THEODORIDIS & KOUTROUMBAS, 2008). A aquisição dos dados caracteriza-se pela coleta dos dados, em geral, realizada a partir de um, ou mais, sensores. A etapa de extração de características envolve a obtenção das variáveis mais apropriadas à tarefa de classificação. Na classificação são empregadas técnicas que constroem uma regra de discriminação que pode ser expressa como uma regra interpretável. Por fim, avalia-se o desempenho do classificador baseado em métricas de desempenho (WEBB & COPSEY, 2011).





Fonte: Elaborada pelo autor.

3.3 DETECÇÃO AUTOMÁTICA DO SONO USANDO TRANSDUTORES DE FORÇA

A proposta de utilizar transdutores de força para avaliar a qualidade do sono se enquadra no objetivo de fornecer um método de aquisição contínuo, mas que não seja intrusivo ao paciente. Nesta seção, vamos descrever alguns métodos de avaliação da qualidade do sono e de medidas correlatas que utilizam transdutores de força.

3.3.1 Transdutores de Força

Os transdutores de força caracterizam-se por equipamentos eletromecânicos que medem cargas estáticas ou dinâmicas, convertendo-as em sinais elétricos para posterior análise. São geralmente aplicados a situações onde não ocorrem grandes deslocamentos. O princípio de funcionamento dos transdutores de força baseia-se na deformação que sofre um material quando submetido à aplicação de uma força. Mensura-se então a deformação de um elemento elástico interno, processando-se por meios eletrônicos a conversão do sinal elétrico em registro equivalente em unidades de força (FIALHO, 2010).

Uma das categorias de transdutores existentes capazes de converter deformações mecânicas em sinais elétricos proporcionais são os *strain gauges*. Estas pequenas células extensiométricas caracterizam-se por empregar elementos cuja resistência elétrica varia em função de deformações sofridas em sua superfície. Geralmente, são afixadas junto ao corpo de prova, realizando a leitura das deformações longitudinais e transversais sofridas. Para mensurar
pequenas variações de resistências, a partir das deformações, é empregado um circuito do tipo ponte de *Wheatstone*, apresentado na Figura 8 (FIALHO, 2010).



Figura 8 - Ligação dos strain gauges em ponte de Wheatstone



Uma forma esquemática de um transdutor de força com quatro *strain gauges*, dispostos em uma ponte de *Wheatstone*, pode ser visualizada na Figura 9. Neste caso os gauges 1 e 3 são afixados na superfície superior das lâminas de flexão, enquanto que os gauges 2 e 4 na superfície oposta.

Figura 9 – Vista em corte longitudinal do transdutor de força (a) e vista superior, com os gauges 1 e 3 afixados na superfície superior das lâminas de flexão e gauges 2 e 4, na superfície oposta (b).



Fonte: Adaptado de FIALHO (2010).

Um transdutor do tipo *strain gauge* bastante comum e aplicado na indústria é a célula de carga. As células de carga são estruturas mecânicas projetadas para receber esforços e deformar-se dentro de um determinado regime elástico. Essa deformação gera um sinal de saída linear e proporcional a carga aplicada (THOMAZINI & ALBUQUERQUE, 2011). São amplamente empregadas em sistemas industriais como, por exemplo, na pesagem de tanques e

silos (THOMAZINI & ALBUQUERQUE, 2011), ou ainda em balanças eletrônicas comerciais que torna seu custo e aquisição a aplicação deveras facilitado.

O funcionamento das células de carga é baseado na variação da resistência ôhmica de um *strain gauge*²⁸ quando submetido a uma deformação. Essa deformação, produto da aplicação de uma força, altera o comprimento (l) e a área da seção transversal (A) do *strain gauge*, sendo que sua resistência passa a ser dada por

$$R = \rho \frac{l_0 + \Delta l}{A_0 + \Delta A}.$$

Neste caso, a resistência ôhmica corresponde à deformação sofrida pela célula de carga que, consequentemente, representa a deformação da peça a ser mensurada. Os *strain gauges* caracterizam-se por elementos sensíveis capazes de converter pequenas deformações na sua estrutura em uma variação equivalente de resistência elétrica. Dessa maneira, sua aplicação constitui em uma forma prática de registrar deformações como uma grandeza elétrica, possibilitando a medição de pressão, tensão, força, aceleração, entre outras grandezas físicas, usadas em campos que abrangem desde de a análise experimental de tensão até a investigação e práticas médicas e cirúrgicas (THOMAZINI & ALBUQUERQUE, 2011).

Dentre as características dos *strain gauges* que corroboram sua aplicação na indústria estão sua alta precisão de medida, baixo custo, excelente resposta dinâmica e linear, facilidade de instalação e possibilidade de efetuar medições à distância. Dentre os metais usados na construção de *strain gauges* estão as ligas de resistividade elevada como Constantan (45% Ni, 55% Cu) ou Nicromo (80% Ni, 20% Cr), as quais permitem obter resistências na ordem de 60, 120, 240, 350, 500 e 1 k Ω . A Figura 10 mostra os detalhes construtivos de uma célula de carga.

$$R = \rho \frac{l_0}{A_0},$$

²⁸ A variação de resistência ôhmica de um metal pode ser obtida pela seguinte equação:

onde ρ corresponde à resistividade do material, l_0 o comprimento inicial e A_0 a área de seção transversal inicial (THOMAZINI & ALBUQUERQUE, 2011).



Figura 10 - Detalhes construtivos de uma célula de carga

Fonte: (THOMAZINI & ALBUQUERQUE, 2011)

Austin et al. (2012) propõem um sistema de detecção, não intrusivo, dos estados sonovigília a partir do uso de células de carga acopladas aos suportes do leito. No trabalho, as células de carga foram posicionadas sob cada um dos cinco suportes da cama onde o paciente realizava a PSG, sendo que os dados das células eram coletados de forma concomitante ao exame. Um classificador, baseado em aprendizado de máquina, é responsável por identificar os registros advindos das células de carga e separá-los duas classes, vigília ou sono (AUSTIN et al., 2012).

Outro estudo, conduzido por Choi et al. (2009), emprega células de carga para estimar a VFC e, a partir destes dados, separar o sono de ondas lentas e o sono de ondas não-lentas. Os dispositivos são acoplados aos suportes da cama, como pode ser ilustrado na Figura 11.



Figura 11 - (a) Célula de carga (b) Instalação de quatro células de carga acopladas aos suportes do leito

Fonte: (CHUNG et al., 2007)

Há também outros estudos que empregam sensores de pressão fixados ao leito, em geral, confeccionados especificamente para efetuar medições dos movimentos respiratórios, ou ainda corporais do indivíduo enquanto dorme.

Ao serem expostos a pressões ou forças em um determinado sentido, os cristais piezo elétricos são elasticamente deformados. Como consequência, essa deformação produz um potencial elétrico que resulta em um fluxo de cargas elétricas, durante um instante de tempo, nas faces opostas do cristal. Esse fluxo de cargas, ou sinal elétrico, (q) é proporcional a força aplicada (f), e por conseguinte, a deformação sofrida pela superfície do cristal, sendo relacionado da seguinte forma (FRANCHI, 2015):

$$q = d \cdot f$$
,

onde a constante d é a sensibilidade do dispositivo, e indica a quantidade de carga gerada a uma determinada força aplicada.

Em um típico transdutor piezoelétrico, placas metálicas são colocadas na superfície do cristal, que é comprimido em aplicações de medição. O sinal de carga obtido a partir de um transdutor piezoelétrico é geralmente convertido em sinal de tensão utilizando-se um capacitor, cuja tensão pode ser dada por

$$E = \frac{Q}{c},$$

onde E é tensão elétrica do capacitor, Q é a carga e C é a capacitância. Em resposta à força aplicada sobre a superfície do cristal, a carga armazenada q no capacitor é descarregada a uma taxa exponencial em um resistor, com uma constante de tempo $R \cdot C$, em que R é a resistência (Figura 12) (FRANCHI, 2015)

$$q = Qe^{-t/RC}$$





Fonte: (FRANCHI, 2015).

Os transdutores piezoelétricos oferecem algumas vantagens à medição de pressão dinâmica. São pequenos em tamanho, peso e muito robustos. Estas vantagens conferem a esses dispositivos características essenciais à construção de sensores de pressão. Devido às características de rigidez, os sensores de pressão são empregados em aplicações críticas tais como, balística, ensaios explosivos, combustão interna, injeção de combustível, som, entre outros (FRANCHI, 2015).

Os sensores de pressão de leito são compostos por películas Emfit sensíveis a variações de pressão. Emfit é uma película de polipropileno porosa, que possui espaços internos que carregam-se eletricamente quando em sua espessura é exercida uma determinada pressão. A força do campo elétrico interno varia, gerando carga nas superfícies externas. Os eletrodos nas superfícies opostas são usados para medir carga acumulada. A estrutura laminada inclui a película Emfit e várias camadas de isolamento, usando eletrodos impressos para condução de sinal e blindagem (KORTELAINEN et al., 2010).

Guerrero-Mora et al. (2012), Kortelainen et al. (2010) e Migliorini et al. (2010) empregam um modelo comum de sensores de pressão de leito (PBS), desenvolvidos pela VTT em cooperação com o fabricante do sensor Emfit Ltd. O sensor foi colocado abaixo do colchão de plástico de espuma normal com uma espessura de 12 cm. Os pesquisadores compararam diferentes formas e números de eletrodos para encontrar o melhor entre confiabilidade, complexidade e baixo custo. O modelo selecionado possuía oito eletrodos laterais com tamanho de 7 cm x 34 cm cada, colocados em duas colunas e quatro linhas, cobrindo uma área total de 72 cm x 72 cm sob o corpo médio do sujeito. Essa reconfiguração dos eletrodos do sensor de leito foi testada posteriormente para os dados coletados do sensor original de leito de 160 canais, calculando a média dos sinais do canal da vizinhança para compor um sinal de uma área de eletrodo maior e combinada.

Por outro lado, Kortelainen et al. (2012) empregam um sensor de leito de fluoreto de polivinilideno (PVDF, do inglês: *Polyvinylidene fluoride*) adquirido da Measurement Systems Inc., colocado em quatro linhas e duas colunas, cobrindo a área total de 0,7 m \times 0,7 m. Em comparação aos sensores de pressão Emfit, os pesquisadores não encontraram diferenças significantes na extração de sinais cardiorrespiratórios.

Samy et al. (2014) empregam sensores de pressão de baixo custo, conhecidos por Etêxteis no monitoramento de estágios do sono. E-têxteis são tecidos que possuem componentes eletrônicos e interconexões, constituídos de uma folha de tecido piezoresistivo muito fina, inserida entre duas folhas de tecido tradicional. O tecido piezoelétrico possui uma resistência elétrica que diminui com o aumento da pressão e sua espessura é da ordem de mícrons, comparável ao diâmetro de um fio de cabelo humano. Essas características permitem a construção de um sistema sensor de pressão de baixo custo, flexível e confortável. A Figura 13 ilustra o circuito usado para captar a distribuição de pressão da matriz de sensores do tecido.

Figura 13 – (a) circuito empregado para varrer a distribuição de pressão da matriz do sensor de lençol (b) sujeito dormindo em um lençol sensível à pressão e o mapa de pressão correspondente.





3.3.2 Extração de Caraterísticas

A extração de características é o processo de seleção de variáveis, a partir de um conjunto de medições, que são apropriadas à tarefa de classificação (WEBB & COPSEY, 2011). Caracteriza-se pela transformação de um espaço n-dimensional, formado por variáveis de um conjunto de medições, para um espaço de características de menor dimensão, de forma que o mapeamento não reduza a separabilidade das classes (FUKUNAGA, 1990).

Uma das principais razões para reduzir o espaço de características a um número suficiente mínimo é a complexidade computacional. Ao selecionar características com maior poder de discriminação, o modelo do classificador tornar-se-á bastante simplificado. No entanto, casos as variáveis selecionadas não contribuam na caracterização das classes, a complexidade computacional poderá aumentar, sem proporcionar um ganho de desempenho (THEODORIDIS & KOUTROUMBAS, 2008). Em vista disso, Duda et al. (2000) refere-se à extração de características como uma tarefa mais problemática que a classificação, pois além de ser mais dependente do domínio, requisita um sólido conhecimento deste.

Movimentos Corporais

No processo de detecção automática de estados do sono, alguns trabalhos utilizam sinais de movimentos corporais adquiridos via transdutores de força. Para caracterizar esses movimentos, costumam ser estimados os sinais de centro de pressão (WALSH et al., 2017), bem como algumas medidas estatísticas sobre estes, tais como a média e variância (AUSTIN et al., 2012). O centro de pressão (CP) contém uma estimativa da localização do ponto central através do qual a pressão foi aplicada, relativo a um sistema de coordenados cartesianas. Mudanças no centro de pressão, ao longo do tempo, fornecem uma medida espacial do movimento do sujeito no leito (AUSTIN et al., 2012; WALSH et al., 2017). A partir de N células de carga acopladas ao leito, os sinais de centro de pressão CoP(t) podem ser estimados a partir de

$$CoP(t) = \frac{\sum_{i=1}^{N} LC_i(t) \cdot (x_i, y_i)}{\sum_{i=1}^{N} LC_i(t)},$$

onde (x_i, y_i) é a coordenada da célula de carga *i*, relativo a um sistema de coordenadas cartesianas *xy* no leito, e $LC_i(t)$ é a força medida pela célula de carga *i* no instante *t* (BEATTIE, 2013).

Além dos sinais de CP, outros parâmetros costumam ser empregados na caracterização dos sinais de movimento. Samy et al. (2014) utilizam características geométricas que incluem a simetria corporal, equilíbrio, localização do quadril e localização do ombro na identificação dos estágios do sono. Esses recursos resumem a postura e orientação do corpo, sendo extraídos do mapa de distribuição de pressão do sensor de leito (SAMY et al., 2014). Pouyan et al. (2015) estimam a matriz de distribuição de pressão $P_{K x L}$, que representa matematicamente o mapa de pressão corporal do sujeito a partir de medições realizadas pelo sensor de pressão de leito. No trabalho são dispostos 1728 (64 x 27) sensores de pressão com distribuição uniforme, cobrindo a área da interface de contato entre o sujeito e o leito. A matriz *P* pode ser representada por

$$P = \begin{pmatrix} p_{0,0} & \cdots & p_{0,L-1} \\ \vdots & \ddots & \vdots \\ p_{K-1,0} & \cdots & p_{K-1,L-1} \end{pmatrix},$$

onde $p_{i,j}$ é o valor de pressão captada pelo sensor localizado na coordenada $(i, j), 0 \le i < K$ (*K*, número de linhas da matriz *P*, em um total de 64) e $0 \le j < L$ (*L* é o número de colunas da matriz *P*, em um total de 27). Com base nos valores de pressão extraídos da matriz *P*, os pesquisadores estimam a mobilidade que pode ser calculada por

$$m_t = \sum_{i=0}^{K-1} \sum_{j=0}^{L-1} \Delta p_{i,j}(t),$$

onde $\Delta p_{i,j}(t)$ é a diferença de pressão em dois instantes consecutivos de amostragem $(p_{i,j}(t) - p_{i,j}(t-1))$ (POUYAN et al., 2015). Então, a sequência de mobilidade (*M*) é definida usando a seguinte série temporal:

$$M = m_1, m_2, ..., m_{t-1}, m_t.$$

Depois que a sequência de mobilidade M é criada, uma abordagem é aplicada para extrair características de M. Uma janela deslizante SW é considerada. A SW proposta inclui três sub-janelas: sw_1 , $sw_2e sw_3$. Essas sub-janelas são definidas para ter 20% de sobreposição para dessensibilizar o ponto inicial das sub-janelas e evitar ter sub-janelas redundantes em um fluxo longo. Além disso, cada SW tem 50% de sobreposição com a janela sucessiva para minimizar a sensibilidade do tamanho constante e a posição das janelas. O objetivo é classificar o estado de sono (incluindo vigília) com resolução de 1 minuto (ou seja, $|SW_l| = 60$ seg e $|sw_i| = 23$ seg). Os dados de mobilidade em cada SW são analisados e três características estatísticas por cada sub-janela são extraídas (POUYAN et al., 2015).

Considerando uma sub-janela sw_i (i = 1, 2, 3) com comprimento $k \in m_j$ um termo da sequência de mobilidade M, as medidas estatísticas relacionadas a cada sw_i são:

$$\mu_{i} = \frac{\sum_{j=1}^{k} m_{j}}{k},$$

$$\sigma_{i} = \sqrt{\frac{\sum_{j=1}^{k} (m_{j} - \mu_{i})^{2}}{k}},$$

$$\kappa_{i} = \frac{\sum_{j=1}^{k} (m_{j} - \mu_{i})^{4}}{(k-1) \cdot \sigma_{i}^{4}}.$$

onde μ é média, σ desvio padrão e κ o valor de *kurtosis* (quarto momento) que indica o grau de pico / nivelamento da amostra de dados em sw_i . A razão de extrair essas características é para preservar as relações de tempo entre os mesmos tipos de características, e relatar padrões de correlação significativos para cada estado do sono.

Adami et al. (2012) usam de uma abordagem semelhante, estimando a média e variância sobre os sinais de diferença quadrática média (*msd*, do inglês: *mean-square difference*), que caracterizam os movimentos no leito sendo estimados individualmente a cada célula de carga

$$x_{i,msd}(t) = \frac{1}{L-1} \cdot \sum_{i=-(K-1)/2}^{(K-1)/2} (x_i(t-j) - \overline{x}_i(t))^2,$$

onde $\overline{x_l}(t)$ é a média local do sinal calculado sobre uma janela de tamanho L, restrito a ser um número ímpar e definido como 11 para a análise. Mendez et al. (2017) utilizam um algoritmo

baseado em limiares para caracterizar a atividade de movimento, obtida a partir do sensor de pressão de leito, e então identificar os períodos de vigília e sono.

Movimentos Respiratórios

No geral, tratando-se de sinais respiratórios, os pesquisadores costumam estimar variáveis estatísticas sobre os valores de amplitude e frequência dos ciclos respiratórios (SAMY et al., 2014; VANDEKERCKOVE et al., 2014; YANG et al., 2016), ou ainda estimam a taxa respiratória (WALSH et al., 2017). Dentre essas variáveis estão a média e o desvio padrão (SAMY et al., 2014), ou ainda a média e variância (WILLEMEN et al., 2014). Por sua vez, Guerrero-Mora et al. (2012) aplica o método de análise de componentes principais (PCA, do inglês: *Principal Component Analysis*) na extração de sinais respiratórios, a partir de sinais de BCG advindos de um sensor de pressão no leito (PBS). Com base em projeções lineares, o primeiro componente principal proporciona a máxima variância do sinal de saída composto, melhorando a sensibilidade na extração dos sinais respiratórios (GUERRERO-MORA et al., 2012).

Ainda é possível encontrar estudos que, além dos sinais de movimentos respiratórios ou corporais, extraem informações sobre frequência cardíaca do indivíduo, a partir de sinais de BCG. Para estimar a VFC e os IBIs são usados o modelo autoregressivo variante no tempo (TVAM, do inglês: *Time-Variant Autoregressive Model*) e a Transformada discreta de *Wavelet* (WDT, do inglês: *Wavelet Discrete Transform*). Com esses sinais podem ser obtidos os IBI e sinais respiratórios (MIGLIORINI et al., 2010), ou ainda a VFC (KORTELAINEN et al., 2010). Os componentes espectrais foram usados na obtenção do subconjunto de características para separar os diferentes estágios do sono: vigília, sono REM e NREM. Mendez et al. (2017) estimam a potência na faixa de baixa e alta frequência, a média do módulo e ângulo dos pólos na alta frequência e potência total de cada batimento a partir das flutuações do batimento cardíaco. O TVAM é estimado por

$$\widehat{y} = -\sum_{k=1}^{P} a_k y(n-k),$$

onde a_k representa os coeficientes do modelo, *n* representa o tempo, *P* é a ordem do filtro e \hat{y} representa a saída. Kortelainen et al. (2012) emprega a Transformada Discreta de Fourier (DFT, do inglês: *Discrete Fourier Transform*) para extrair os IBIs e a VFC, sobre os sinais de BCG. Dado que ω é a frequência angular, *n* o tempo e x(n) o sinal, a DFT é dada por

$$X(\omega) = \sum_{n=-\infty}^{\infty} x(n) e^{-i\omega n}$$

Há estudos que extraem a média e variância dos intervalos RR a partir da VFC (WILLEMEN et al., 2014). Park et. al (2014) utilizam a eficiência e latência de início do sono, que pode ser calculada pela seguinte relação

$$Eficiência \ do \ sono = \frac{tempo \ total \ de \ sono}{tempo \ no \ leito}.$$

3.3.3 Classificação

O estágio de classificação corresponde à aplicação de um procedimento de discriminação ou regressão sobre um conjunto de amostras independentes das amostras rotuladas, ou conhecidas (WEBB & COPSEY, 2011). A construção do classificador envolve postular alguma forma geral de modelo e usar de padrões de treinamento para aprender, ou estimar, parâmetros desconhecidos pelo modelo (DUDA et al., 2000). Nesse sentido, Duda et al. (2000) afirma que métodos que armazenem informações das amostras de treinamento na construção de classificadores empregam alguma técnica de aprendizado. O aprendizado caracteriza-se por um algoritmo responsável pela redução do erro em um conjunto de dados de treinamento (DUDA et al., 2000).

Classificadores podem ser construídos a partir de um determinado conjunto de dados. Neste sentido, para um dado classificador, é empregado um algoritmo de aprendizado que objetiva pesquisar o espaço de parâmetros, e encontrar o modelo que melhor descreve a relação entre as medidas e os rótulos de classe para o conjunto de treinamento. Existem duas divisões principais de classificação: a classificação supervisionada (baseada em algoritmos de aprendizado supervisionado, também conhecida por discriminação) e não supervisionada (baseada em algoritmos de aprendizado não-supervisionado) (WEBB & COPSEY, 2011).

No aprendizado supervisionado, para cada padrão do conjunto de treinamento é atribuído um rótulo de categoria ou função de custo, sendo que o projeto do classificador deverá explorar esta informação, "*a priori*", na construção do modelo (DUDA et al., 2000; THEODORIDIS & KOUTROUMBAS, 2008). No caso do aprendizado não-supervisionado, o sistema forma agrupamentos "naturais", ou seja, conjuntos de particulares padrões ou funções de custo (DUDA et al., 2000). Este tipo de técnica na qual a classificação das amostras é realizada sem o auxílio de um conjunto de treinamento, também é conhecida por *clustering* (FUKUNAGA, 2008).

A maioria dos trabalhos que tratam da detecção automática do sono aplicam algum método de aprendizado supervisionado na construção do classificador. Nesses trabalhos destacam-se tanto as técnicas lineares, como as não lineares para classificação. Dentre as principais técnicas lineares empregadas estão a máquina de vetores de suporte (AUSTIN et al., 2012; SAMY et al., 2014; WILLEMEN et al., 2014; YANG et al., 2016; MENDEZ et al., 2017; WALSH et al., 2017) e o discriminante linear (LDA, do inglês: *Linear Discriminant Analysis*) (MIGLIORINI et al., 2010; WALSH et al., 2017). SVM caracteriza-se por um algoritmo baseado em aprendizado de máquina comumente empregado em problemas de classificação de duas classes (classificação binária) (AUSTIN et al., 2012). Dentre as técnicas não lineares destacam-se as Redes Neurais Artificiais (RNAs) (WALSH et al., 2017) e o discriminante quadrático (QDA, do inglês: *Quadratic Discriminant Analysis*) (MIGLIORINI et al., 2010; WALSH et al., 2017).

Por outro lado, existem abordagens que exploram técnicas de classificação baseadas no aprendizado não supervisionado. Samy et al. (2014) e Walsh et al. (2017) empregam o algoritmo dos *k*-vizinhos mais próximos (KNN, do inglês: *K-Nearest Neighbor*), uma técnica de aprendizado não-supervisionado que usa a noção de distância entre os pontos de dados no espaço de características como base à classificação (SAMY et al., 2015).

Podem ser encontrados ainda trabalhos que abordam o problema da detecção de estágios do sono a partir de outras técnicas de aprendizado ou seja, que não se baseiam apenas em técnicas lineares ou não-lineares. Nesse sentido, existem estudos que aplicam modelos probabilísticos tais como o classificador *Naïve Bayes* (SAMY et al., 2012) e o Modelo Oculto de Markov (HMM, do inglês: *Hidden Markov Model*) (KORTELAINEN et al., 2010). Pouyan et al. (2015) e Yang et al. (2016) empregam árvores de decisão, um classificador estatístico, enquanto Guerrero-Mora et al. (2012) usam algoritmos adaptativos baseados em limiares na identificação de estágios do sono.

Máquina de Vetores de Suporte

Uma máquina de vetores de suporte (SVM, do inglês: *support vector machine*) implementam o mapeamento dos dados em um espaço vetorial de maior dimensão, onde é construído um hiperplano de separação cuja margem maximize a distância entre as classes (WEBB & COPSEY, 2011). Considere um problema de classificação binária com um conjunto de treinamento X, composto por N vetores multidimensionais de características x_i , onde i =1, 2, 3 ... N. Cada vetor x_i do conjunto de treinamento corresponde a uma das duas classes, ω_1 ou ω_2 , linearmente separáveis, com rótulos $y_i = \pm 1$. A função discriminante linear g(x), também conhecida como hiperplano (THEODORIDIS & KOUTROUMBAS, 2008), a ser estimada é dada por

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0$$

com a seguinte regra de decisão,

$$\boldsymbol{w}^{T}\boldsymbol{x} + \boldsymbol{w}_{0} \begin{cases} > 0 \\ < 0 \end{cases} \Rightarrow \boldsymbol{x} \in \begin{cases} \omega_{1}, y_{i} = +1 \\ \omega_{2}, y_{i} = -1 \end{cases}$$

Assim, cada hiperplano é caracterizado por uma direção w e uma posição no w_0 espaço.

É importante ressaltar que o hiperplano pode não ser único (THEODORIDIS & KOUTROUMBAS, 2008). A Figura 14 apresenta dois exemplos de hiperplanos de separação (retas são utilizadas somente para o propósito de ilustração de um hiperplano), para o mesmo conjunto de dados.

Figura 14 - Dois conjuntos de dados linearmente separáveis com hiperplanos de separação rotulados como A.



Fonte: (WEBB & COPSEY,2011)

O objetivo no treinamento de uma SVM é encontrar o hiperplano de separação que possua a maior margem. A margem de um hiperplano pode ser definida como a soma das distâncias entre o hiperplano separador para o padrão mais próximo da classe ω_1 e para o padrão mais próximo da classe ω_2 (WEBB & COPSEY, 2011). Assim, é esperado que quanto maior a margem (Figura 14.b), melhor será a generalização do classificador (DUDA et al., 2000). Em vista disso, o objetivo em treinar uma SVM é encontrar a direção do hiperplano que maximize a margem (THEODORIDIS & KOUTROUMBAS, 2008). A distância z de um padrão ao hiperplano pode ser dada por

$$z=\frac{|g(x)|}{||w||}.$$

A Figura 15 apresenta o hiperplano $g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0$ e os hiperplanos canônicos $H_1: \mathbf{w}^T \mathbf{x} + w_0 = +1$ e $H_2: \mathbf{w}^T \mathbf{x} + w_0 = -1$, para dois conjuntos de dados linearmente separáveis. Os pontos que estão sobre os hiperplanos canônicos são chamados de vetores de suporte. Neste caso tem-se que a margem do hiperplano g(x) é dada por

$$\frac{1}{||w||} + \frac{1}{||w||} = \frac{2}{||w||}$$

e a regra de decisão pode ser escrita da seguinte forma:

$$w^T x + w_0 \ge +1, \quad \forall x \in \omega_1$$

 $w^T x + w_0 \le -1, \quad \forall x \in \omega_2$

Figura 15 - $H_1 e H_2$ são os hiperplanos canônicos. A margem é dada pela distância perpendicular entre o hiperplano de separação $g(\mathbf{x}) = 0 e$ um hiperplano através do mais próximo ponto da classe $\omega_1 e \omega_2$. Estes pontos são denominados vetores de suporte. Os eixos correspondem as características.



Fonte: (WEBB & COPSEY, 2011)

Na maioria dos problemas encontrados na natureza, a separação de dados de treinamento por meio de um hiperplano não é suficiente. As SVMs são empregadas, na maioria das vezes, em problemas de classificação não lineares, mapeando o conjunto de treinamento de seu espaço original, conhecido também por espaço de entradas, para um novo espaço de maior dimensão, comumente referenciado como espaço de características (Figura 16) (LORENA e CARVALHO, 2007). Seja $\Phi: X \to \Im$ um mapeamento, em que *X* é o espaço de entradas e \Im denota o espaço de características. Com base no teorema de Cover²⁹, aplicando-se um mapeamento não linear apropriado Φ , para uma dimensão suficientemente alta, os dados de duas categorias sempre podem ser separados por um hiperplano (DUDA et al., 2000).





FONTE: Adaptado de Lorena e Carvalho (2007).

Para realizar o treinamento de uma SVM são escolhidas funções não-lineares que mapeiam os dados de entrada para um espaço de alta dimensão. Frequentemente, essa escolha é baseada no conhecimento sobre o domínio do problema. Na ausência dessa informação, optase por usar polinômios, gaussianas ou ainda outras funções básicas. A dimensionalidade do espaço mapeado pode ser arbitrariamente alta (DUDA et al., 2000).

Como a dimensionalidade de \Im pode ser alta (até mesmo infinita), a computação de Φ pode ser extremamente custosa ou inviável. Uma solução para este problema é o uso de funções denominadas de kernels. Uma função kernel recebe dois pontos do espaço de entradas ($x_i e x_j$) e computa o produto escalar desses dados no espaço de características, o que pode ser representado da seguinte forma:

$$K(\mathbf{x}_i, \mathbf{x}_i) = \mathbf{\Phi}(\mathbf{x}_i)\mathbf{\Phi}(\mathbf{x}_i).$$

²⁹ Teorema de Cover: dado um conjunto de dados não linear em um espaço de entradas *X*, é possível transformar *X* em um espaço de características \Im , com alta probabilidade de os dados serem linearmente separáveis. Para isso duas condições devem ser satisfeitas. A primeira é que a transformação seja não linear, enquanto a segunda é que a dimensão do espaço de características seja suficientemente alta (COVER, 1965).

A função discriminante g(x), neste caso, pode ser representada em função do kernel $K(x_i, x_j)$, dos parâmetros de peso duais da SVM α_n , rótulos da classe y_n e de um limiar w_0 .

$$g(x) = \sum_{n=1}^{Vetores \ de \ Suporte} \alpha_n y_n K(x_i, x_j) + w_0$$

É comum o emprego da função kernel sem conhecer o mapeamento Φ , que é gerado implicitamente. Neste caso, a utilidade dos kernels está na simplicidade de seu cálculo e em sua capacidade de representar espaços abstratos. Alguns dos kernels mais utilizados na prática são os polinomiais, os gaussianos ou RBF (Radial-Basis Function), e os sigmóides (LORENA e CARVALHO, 2007), conforme Tabela 2.

Tabela 2 - Funções de Kernel

Função de Kernel	Forma matemática
Polinomial	$(\delta(\boldsymbol{x}_i \cdot \boldsymbol{x}_j) + k)^d$
Gaussiano	$exp(-\sigma \ \boldsymbol{x}_i - \boldsymbol{x}_j\ ^2)$
Sigmóide	$tanh(\delta(\boldsymbol{x}_i \cdot \boldsymbol{x}_j) + k)$
FONTE: Adaptado de Lo	rang a Carvalho (2007)

FONTE: Adaptado de Lorena e Carvalho (2007).

3.3.4 Avaliação do Classificador

Ao avaliar o desempenho de um sistema de classificação, a probabilidade de erro, às vezes, não é uma métrica suficiente (THEODORIDIS & KOUTROUMBAS, 2008). Nesse sentido, a avaliação de classificadores pode ser feita a partir da comparação de desempenho de vários classificadores treinados sob o mesmo conjunto de dados. Para isso, são necessárias algumas métricas que caracterizem o modelo de classificador escolhido, sob a perspectiva do desempenho. Estas métricas podem ser extraídas a partir da matriz de confusão (WEBB & COPSEY, 2011).

Uma matriz de confusão A pode ser definida de modo que, seu elemento $a_{i,i}$ seja o número de amostras cujo rótulo de classe verdadeira é j e são classificadas como classe i (THEODORIDIS & KOUTROUMBAS, 2008). A Tabela 3 apresenta uma matriz de confusão para o problema de 2 classes (positivo - P e negativo - N). Ela mostra o número de predições verdadeiras e falsas para cada uma das classes. Os verdadeiros positivos (TP) representam o número de amostras da classe positiva, corretamente preditos pelo classificador para pertencer à classe positiva. Os falsos positivos (FP), por sua vez, representam o número de amostras da classe negativa que estão incorretamente previstos pelo classificador para pertencer à classe positiva. Assim, o total de amostras positivas e negativas podem ser estimadas por, respectivamente,

$$P = TP + FN$$

$$N = FP + TN.$$

Tabela 3 - Matriz de confusão 2x2: Verdadeiro Positivos (True Positives - TP), Falsos Positivos (False Positiv	ves
- FP), Falsos Negativos (False Negatives - FN), Verdadeiros Negativos (True Negatives - TN).	

		Classe Verdadeira		
		Positivo	Negativo	
Classe Estimada	Positivo	Verdadeiro	Falsos	
		Positivos (TP)	Positivos (FP)	
	Negativo	Falsos	Verdadeiros	
		Negativos (FN)	Negativos (TN)	

Fonte: (adaptado de WEBB & COPSEY, 2011)

No contexto do problema de detecção dos estados sono-vigília, as classes Positivos e Negativos referem-se aos estados de sono e vigília, respectivamente. Quando a hipótese H_0 (pessoa está acordada) for verdadeira e o detector produzir a classe vigília, isto quer dizer que o detector está realizando a inferência correta de não rejeitar a H_0 . Na teoria de teste de hipóteses, o detector tomou uma decisão negativa (por não rejeitar H_0) verdadeira (correta), representando a medida Verdadeiro Positivo.

As principais medidas de desempenho usadas para avaliar detectores sono-vigília a partir de uma matriz de confusão *A* são:

a) Acurácia (Acc): é o percentual de amostras da classe j que foram corretamente classificadas. Dado um problema de M classes, e N seja o número de amostras do conjunto de testes, a Acc pode ser estimada, a partir da matriz de confusão A, por (THEODORIDIS & KOUTROUMBAS, 2008)

$$Acc = \sum_{j=1}^{M} A(j,j).$$

Para o caso de um problema de 2 classes, pode-se estimar a acurácia de um classificador (WEBB & COPSEY, 2011) utilizando

$$Acc = \frac{TP + TN}{P + N}.$$

 b) Sensibilidade (Sen): é o percentual de amostras positivas, que foram classificados corretamente nessa classe (WEBB & COPSEY, 2011), estimado por

$$Sen = \frac{TP}{P}$$

c) Especificidade (*Esp*): é o percentual de amostras negativas, que foram classificadas corretamente nessa classe (WEBB & COPSEY, 2011), estimado por

$$Esp = \frac{TN}{N}.$$

 d) Precisão (*Prec*): é o percentual de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas (WEBB & COPSEY, 2011), estimado por

$$Prec = \frac{TP}{TP + FP}$$

Como o problema de detecção vigília-sono lida com conjunto de dados frequentemente desbalanceados para as classes, a acurácia pode enganar os resultados porque muito mais peso na classe com maior quantidade de amostras em detrimento da classe com menos amostras (WEBB & COPSEY, 2011). Por exemplo, em uma situação onde a probabilidade (a priori) de uma classe ocorrer é de 0.9 e o detector sempre decidir por esta classe durante o teste, é possível afirmar que este detector terá uma acurácia de 90% mesmo quando errou todas as amostras da outra classe. Assim, outras medidas como sensibilidade e especificidade são comumente utilizadas para avaliar o desempenho nestes tipos de problemas com classes desbalanceadas, pois proporcionam uma melhor caracterização dos resultados obtidos.

Em geral, para avaliar o desempenho de classificadores é empregada alguma técnica para dividir o espaço de características em dados de treinamento e teste. Uma das técnicas aplicadas é conhecida por *leave-one-out cross validation* (LOOCV). Como na área médica é comum ter poucas amostras, este método auxilia na obtenção de uma melhor avaliação. No método, uma amostra é excluída, e o classificador é treinado nas N - 1 amostras restantes, sendo que a amostra excluída é testada pelo classificador. Esta operação repete-se N vezes para testar todas as N amostras. Em seguida, o número de amostras incorretas é contado para estimar o erro. Como cada amostra de teste é excluída do conjunto de amostras de treinamento, a independência entre os conjuntos de treinamento e teste é mantida. Neste caso, todas as N

amostras são testadas, e N - 1 amostras são usadas para o projeto do classificador. Assim, as amostras disponíveis são mais efetivamente utilizadas. Também, não é necessário preocuparse com a dissimilaridade entre as distribuições de projeto e de teste (FUKUNAGA, 1990).

Uma das desvantagens do método é que, para *N* grande, é computacionalmente custoso, pois os *N* classificadores devem ser projetados (um classificador para testar cada amostra). No entanto, é aproximadamente imparcial, embora à custa de um aumento na variância do estimador (FUKUNAGA, 1990; WEBB & COPSEY, 2011).

A validação cruzada caracteriza-se por uma abordagem empírica que testa o classificador experimentalmente. Ao treinar um classificador usando validação cruzada, o erro de validação fornece uma estimativa da acurácia do classificador final para o conjunto de testes desconhecido (DUDA et al., 2000). Se a taxa de erro verdadeira, mas desconhecida, do classificador for p, e se k de n' amostras de teste independentes, são classificadas erroneamente, então k tem uma distribuição binomial P(k) que pode ser dada por

$$P(k) = \binom{n'}{k} p^k (1-p)^{n'-k}.$$

Dessa forma, a fração de amostras testadas com erro de classificação é exatamente a estimativa de máxima verossimilhança para p

$$\hat{p} = \frac{k}{n'}.$$

As propriedades dessa estimativa para o parâmetro \hat{p} de uma distribuição binomial são bem conhecidas. A Figura 17 mostra intervalos de confiança de 95% em função de \hat{p} e n'. Para um dado valor de \hat{p} , a probabilidade é de 0,95 que o verdadeiro valor de p esteja no intervalo entre as curvas inferior e superior marcadas pelo número n' de amostras de teste. Essas curvas mostram que, a menos que n' seja razoavelmente grande, a estimativa da probabilidade máxima deve ser interpretada com cautela. Por exemplo, se nenhum erro ocorrer para 50 amostras do conjunto de validação, a taxa de erro verdadeira tende a situar-se entre zero e 8%. (DUDA et al., 2000). Dessa forma, a partir do conjunto de validação, pode-se ter uma estimativa à cerca da acurácia do classificador. Figura 17 - Os intervalos de confiança de 95% para uma dada probabilidade de erro estimada podem ser derivados de uma distribuição binomial. Para cada valor de \hat{p} , a probabilidade real tem 95% de chance de se situar entre as curvas marcadas pelo número de amostras de teste n'. Quanto maior o número de amostras de teste, mais precisa é a estimativa da probabilidade real e, portanto, menor o intervalo de confiança de 95%



Fonte: (DUDA et al., 2000)

Uma variação do LOOCV é o *leave-one-subject-out cross validation* (LOSOCV). Nesta técnica, um indivíduo é relacionado iterativamente como dados de teste e os restantes são utilizados para treinamento (HUANG et al., 2016).

3.4 SISTEMAS DE DETECÇÃO AUTOMÁTICA DO SONO

A partir das métricas de desempenho, podem ser avaliadas algumas diferenças entre os sistemas de detecção automática do sono para mais de uma classe e com duas classes. Kortelainen et al. (2010) atentam ao problema de separação do estágio REM da vigília, quando apenas sinais de VFC, ou quaisquer sinais baseados em flutuações de batimento cardíaco ou sinais respiratórios, são empregados. Esses dois estágios têm características fisiológicos semelhantes, incluindo as atividades respiratórias (YANG et al., 2016). Com vistas a contornar este problema, pesquisadores utilizam-se também de sinais que caracterizam a atividade movimento corporal. Dessa maneira, a distinção entre os estágios de vigília e REM tende a melhorar (MENDEZ et al., 2017; SAMY et al., 2014). A Tabela 4 relaciona diversos classificadores empregados na detecção automática por movimentos dos estágios de vigília, sono REM e NREM. É possível verificar a diferença de desempenho obtido nos trabalhos de Kortelainen et al. (2010), Mendez et al. (2017) e Willemen et al. (2014), que empregam tanto

sinais cardiorrespiratórios e de movimentos, quando comparados aos trabalhos de Migliorini et al. (2010) e Yang et al. (2016), que empregam somente sinais cardíacos.

Trabalho	Características Extraídas	Classificador	Participantes	Resultados
Kortelainen et	IBI e sinais de movimentos	HMM	9 indivíduos	Acc.: 81.0
al. (2010)	corporais (BCG)			
Mendez et al.	Potência na faixa de baixa e alta frequência, média do módulo e ângulo dos polos na alta frequência e potência total de cada batimento,	SVM	6 indivíduos	Acc.: 87.0
(2017)	a partir das flutuações do batimento cardíaco; sinais de movimento corporal para diferenciar a vigília do sono.	5.11		
Migliorini et	IBI e sinais de movimentos	LDA	11 indivíduos	$Acc \cdot 76.0$
al. (2010)	respiratórios (BCG)	QDA	11 martiauos	110011 / 010
Samy et al. (2014)	Média e desvio padrão dos sinais respiratórios e dados geométricos sobre a postura e orientação do corpo no leito	SVM KNN Naive Bayes	7 indivíduos	Acc.: 69.9 Prec.: 70.3 Sens.: 71.1
Willemen et al. (2014)	Média e variância sobre sinais de movimentos respiratórios e de FC (BCG)	SVM	36 indivíduos	Acc.: 81.0
Yang et al. (2016)	Sinais de movimentos respiratórios	SVM Árvores de decisão	20 indivíduos	Acc.: 74.0

Tabela 4 - Sistemas de classificação do sono em 3 classes (Vigília, REM, NREM)

FONTE: Elaborada pelo autor.

Embora os trabalhos que empregam sinais de movimento e cardiorrespiratórios tenham obtido um melhor desempenho quando comparados àqueles que utilizam apenas sinais cardiorrespiratórios, se confrontados os resultados da classificação para duas classes, o desempenho de sistemas de detecção para mais de um estágio do sono ainda é menor. A Tabela 5 relaciona outros trabalhos que empregam diversos algoritmos de classificação na detecção automática por movimentos dos estágios de vigília e sono. Neste caso, verifica-se que a acurácia dos classificadores, em média, melhorou consideravelmente quando apenas os estágios de vigília e sono são identificados, ficando em torno de 88,1%, com um desvio padrão de 4,4%.

Verifica-se então que a acurácia de classificadores para duas classes é relativamente alta, com valores que não variam muito entre si e com relação à média.

Quando considerados os estágios NREM e REM ainda, a acurácia dos classificadores reduz-se para 78,2%, com um desvio padrão de 5,5%. Com isso, verifica-se que as acurácias desses sistemas são menores, variando mais entre si e em relação à média. Willemen et al. (2014) comparam o desempenho obtido para o mesmo detector de estágios do sono, utilizando SVM. Ao identificar apenas os estágios de sono e vigília, os pesquisadores obtém uma acurácia de 92% enquanto que, ao subdividir o sono em NREM e REM, a acurácia reduz para 81%.

Alguns sistemas de classificação do sono em duas classes ainda podem ser avaliados por outras duas métricas: sensibilidade e especificidade. Essas métricas quantificam a proporção de amostras positivas e negativas corretamente classificadas, respectivamente. Nos trabalhos relacionados na Tabela 5 observam-se valores elevados de sensibilidade e especificidade, indicando um bom desempenho do classificador na detecção dos estágios de vigília e sono, quando as amostras realmente representarem vigília e sono (AUSTIN et al., 2012; GUERRERO-MORA et al., 2012; POUYAN et al., 2015). Em comparação com os resultados obtidos para os sistemas que detectam três classes, os valores de sensibilidade e especificidade da Tabela 5 (duas classes) também são maiores.

Trabalhos	Características Extraídas	Classificador	Participantes	Resultados
Austin et al. (2012)	Média e variância dos sinais de CP, <i>msd</i> e das células de carga	SVM	27 indivíduos	Esp.: 81.2 Sen.: 80.8
Guerrero-Mora et al. (2012)	Sinais de movimentos respiratórios (BCG)	Algoritmos adaptativos, baseados em limiares	20 indivíduos	Acc.: 81.9 Esp.: 83.6 Sens.: 83.6
Pouyan et al. (2015)	Média e desvio padrão da mobilidade, estimada a partir dos valores de pressão extraídos do sensor de pressão no leito	Árvores de decisão	8 indivíduos	Acc.: 90.5 Esp.: 89.2 Prec.: 90.2 Sens.: 94.0
Vandekerckhove et al. (2014)	Média e variância sobre sinais respiratórios e de FC (BCG)	SVM	36 indivíduos	Acc.: 92.0

Tabela 5 - Sistemas de classificação do sono em 2 classes (Vigília e Sono)

Trabalhos	Características Extraídas	Classificador	Participantes	Resultados
Walsh et al. (2017)	Sinais de CP e sinais de movimentos respiratórios	SVM	30 pessoas	Esp.: 53.1 Sens.: 96.1
		RNAs		
		LDA		
		QDA		
		KNN		

FONTE: Elaborada pelo autor.

4 MÉTODO DE DETECÇÃO DE SONO PROPOSTO

Considerando-se o contexto e objetivos apresentados até o momento, amparado no estado da arte e na fundamentação teórica, esta proposta tem por objetivo descrever as etapas que compõem o sistema de detecção de sono. A Seção 4.1 descreve o processo de detecção proposto. A Seção 4.2 descreve o pré-processamento dos sinais empregados na detecção de sono. A Seção 4.3 descreve as características extraídas dos sinais. Por fim, as Seções 4.4 e 4.5 descrevem o processo de detecção de sono: classificação, decisão e metodologia de avaliação do sistema.

4.1 PROCESSO DE DETECÇÃO

Como as células de carga sofrem a ação dos movimentos respiratórios e corporais, além da contração e dilatação cardíaca, a detecção do sono pode ser realizada a partir de sinais advindos de cada célula de carga. Destes sinais, podem ser extraídas três informações: ritmo respiratório, ritmo cardíaco e sinais de movimentos. Estes dados são posteriormente utilizados na detecção de sono. O processo de detecção do sono pode ser realizado em quatro estágios principais (Figura 18):

- Pré-processamento: etapa de pré-processamento é responsável por determinar os períodos onde é possível estimar as características. Primeiramente, o sinal é segmentado nos períodos nos quais o paciente se encontra no leito. Em seguida, para cada período em que o paciente está no leito, é realizada segmentação do sinal em períodos em que ocorre movimento e não ocorre movimento. A partir dos segmentos onde não ocorre movimento, o ritmo cardíaco, respiratório e a soma ponderada da diferença quadrática média são estimadas.
- Extração de características: para cada período sem movimento detectado no préprocessamento, os sinais são divididos em intervalos de tempo fixo, chamados de épocas. Para cada época, vetores de características são estimados para os sinais de ritmo cardíaco, respiratório e movimentos.
- Classificação: para cada vetor de característica, o SVM é empregado para estimar a classe (vigília ou sono) a qual ele pertence.
- 4. Decisão: apesar do classificador produzir a classe à qual o vetor de características pertence, é possível dirimir erros do classificador utilizando os resultados das épocas vizinhas. Por exemplo, se em uma sequência de épocas de um determinado segmento

todas as épocas são classificadas como sono, e somente uma no meio do segmento é classificada como vigília, é provável que a classificação de vigília está errada. Assim, será aplicado um filtro mediana para eliminar estas decisões.





FONTE: Elaborado pelo autor.

4.2 PRÉ-PROCESSAMENTO

Esta etapa do desenvolvimento consiste em produzir os sinais do ritmo cardíaco, respiratório e de movimento a partir dos sinais das células de carga. Como a aquisição dos dados foi realizada de forma contínua, podem existir momentos em que a pessoa não está na cama. Logicamente, não faz sentido detectar sono quando o paciente não se encontra no leito. Dessa forma, é necessário detectar os períodos em que a pessoa está presente no leito. Em seguida, é realizada a detecção de movimentos no sinal. De acordo com BRÜSER et al. (2013), movimentos realizados pela pessoa na cama introduzem ruídos ao sinal que podem impossibilitar a avaliação do ritmo cardíaco. A mesma ideia é válida para estimar o ritmo respiratório, onde é feita a classificação dos intervalos com ausência de movimentos não relacionados ao respirar. Neste caso, o objetivo é detectar períodos onde ocorram movimentos e removê-los do sinal. Dessa forma, o sinal resultante contém somente períodos onde o paciente está no leito e não se movimenta.

4.2.1 Detecção de presença no leito

É possível identificar os períodos em que a pessoa está no leito, ou fora dele, a partir das medições realizadas com células de carga devido à queda na força total percebida quando a pessoa levanta-se (Figura 19) (ADAMI et al., 2010). As forças sofridas pelas células de carga (*i*) colocadas sob cada suporte da cama, em cada tempo discreto t, $x_i(t)$, estão relacionadas com a distribuição instantânea da massa do corpo quando alguém está deitado no leito. A soma dos dados das células de carga ou a força total detectada é definida como

$$\sum_{1}^{M} x_{i}(t),$$

onde *M* é o número de suportes (ADAMI et al., 2010).



Figura 19 - Decréscimo na amplitude do sinal de força devido ao movimento de levantar-se da cama.

FONTE: Elaborada pelo autor.

A partir deste entendimento, os dados que representam o paciente no leito ou fora dele podem ser divididos em dois grupos, representados por seus centroides (média da força total percebida pelas células de carga), empregando-se o algoritmo *k-means*. O *k-means* é um método de agrupamento, não supervisionado, que visa particionar *n* observações em *k* grupos, a partir da minimização da variabilidade intra-grupo e maximização da variabilidade entre os clusters (DUDA; HART; STORK, 2000). As vantagens do *k-means* é que ele é não-supervisionado, isto é, não necessita de dados de treinamento, além de ser independente da pessoa pois emprega os próprios dados do sujeito no processamento (ADAMI et al., 2010).

Depois que os dados de cada sujeito são agrupados, os intervalos de tempo cujos dados estão no grupo de menor centroide são rotulados como fora do leito. Consequentemente, as amostras mais próximas do centroide de menor valor são classificadas como "paciente fora do leito", enquanto as mais próximas do centroide de maior valor como "paciente no leito". A

partir dos rótulos é possível determinar os intervalos nos quais a pessoa está no leito ou não. O conjunto de dados relacionado aos períodos em que o indivíduo não se encontra na cama podem ser desconsiderados do restante da rotina de pré-processamento (ADAMI et al., 2010).

4.2.2 Detecção de Períodos de Movimento

O algoritmo para detecção de movimentos, proposto por Adami et al. (2012), emprega um modelo estatístico estimado a partir da variação do sinal das células de carga para detectar períodos em que há movimento. Como os movimentos da pessoa causam variações do sinal nas células de carga, características baseadas na variância são utilizadas na construção do modelo. O processo de treinamento dos modelos e avaliação do sinal é ilustrado na Figura 20.

A partir de sinais advindos de células de carga, infere-se que movimentos do indivíduo sob observação provocam alterações de amplitude. Sabendo que a atividade respiratória ocorre em eventos abaixo de 1Hz, pode-se dizer que movimentos não relacionados à respiração, como o movimento de membros inferiores ou superiores, exibem componentes de maior frequência. Em vista disso, estes eventos exibem maior variabilidade de amplitude em curtos espaços de tempo se comparados à variabilidade média do sinal. Assim, a detecção de movimentos baseia-se na ocorrência de intervalos com variância muito maior que a variância do período analisado (ADAMI et al., 2008).





FONTE: Adaptado de Adami et al. (2012)

De acordo com Adami A. M. (2006), o processamento da extração das características consiste em três partes:

1. Inicialmente, são estimadas as diferenças médias quadráticas a curto prazo para cada sinal advindo das células de carga. Como o movimento do paciente no leito refletese no sinal de uma célula de carga, $w_i(t)$ (Figura 21), e sendo este sinal o que mais varia durante o movimento, a estimativa das diferenças quadráticas médias a curto prazo oferece uma maneira de capturar essas variações. Dessa forma, a análise a curto prazo da diferença quadrática média, para o sinal de cada célula de carga, $s_i^2(t)$ (Figura 22) é estimada por

$$s_i^2(t) = \frac{1}{L-1} \sum_{k=-(\frac{L-1}{2})}^{\frac{L-1}{2}} (w_i(t-k) - \overline{w}_i(t))^2,$$

onde *i* representa os índices das células de carga para i = 1, 2, ..., 5, L é o tamanho da janela de análise, e $\overline{w}_i(t)$ representa a média do sinal ao longo da janela e, é calculado por

$$\overline{w}_{i}(t) = \frac{1}{L} \sum_{k=-(\frac{L-1}{2})}^{\frac{L-1}{2}} w_{i}(t-k)$$

Figura 21 - Sinal da célula de carga LR. É possível verificar uma variação abrupta na amplitude do sinal, durante um curto espaço de tempo, indicando a ocorrência de um movimento.



FONTE: Elaborado pelo autor.

Figura 22 - Diferença quadrática média para o sinal da célula de carga LR. Verifica-se que $s_i^2(t)$ é maior em momentos que há maiores variações no sinal da células de carga, ou seja, nos momentos em que há movimento.



FONTE: Elaborado pelo autor.

2. Estima-se os coeficientes de escala para formar uma combinação ponderada de $s_i^2(t)$. De acordo com Adami A. M. (2006), o objetivo é atribuir graus de relevância aos sinais de célula de carga com base em sua distância do centro de massa estimado do corpo. As coordenadas do centro de massa $x_{CM}(t)$ e $y_{CM}(t)$ para uma disposição de células de carga, apresentada na Figura 27, são estimadas por

$$\begin{aligned} x_{CM}(t) &= x_{max} \; \frac{\widehat{w}_2(t) + \widehat{w}_3(t) + \widehat{w}_5(t)/2}{\sum_1^5 \widehat{w}_i(t)} \\ y_{CM}(t) &= y_{max} \; \frac{\widehat{w}_3(t) + \widehat{w}_4(t) + \widehat{w}_5(t)/2}{\sum_1^5 \widehat{w}_i(t)}, \end{aligned}$$

onde x_{max} e y_{max} representam o comprimento e a largura da cama, respectivamente e $\widehat{w}_i(t) = w_i(t) - w_i(t_0)$ são os pesos normalizados em cada célula de carga *i*, onde a subtração dos pesos coletados com a cama vazia $w_i(t_0)$ remove o efeito de qualquer assimetria da cama no cálculo do centro de massa (ADAMI et al., 2012). Dado que a posição das células de carga é conhecida a priori, e a posição do centro de massa do corpo ($x_{CM}(t)$ e $y_{CM}(t)$) é estimada pela proporção da força peso medida pelos transdutores, os coeficientes $c_i(t)$ são calculados por

$$c_i(t) = \frac{1}{d_i(t) + 1}$$

onde $d_i(t)$ é a distância no instante t entre a célula de carga i e o centro de massa da cama. Adami A. M. (2006) relaciona ainda os coeficientes de escala com a distância entre as células de carga e o centro de massa do corpo, como pode ser representado por

$$\lim_{d_i(t)\to 0} c_i(t) = 1 \quad \text{e} \quad \lim_{d_i(t)\to\infty} c_i(t) = 0.$$

Neste caso é possível verificar que $c_i(t)$ e $d_i(t)$ são inversamente proporcionais.

3. Por fim, é estimada a característica f(t) que representa a soma ponderada de $s_i^2(t)$, sendo denotada por

$$f(t) = \sum_{i=1}^{5} c_i(t) \, s_i^2(t).$$

Assim, o espaço de características é representado utilizando um vetor unidimensional dado por f(t). A soma ponderada da diferença quadrática média, f(t), também é empregada na detecção de sono representando os movimentos do paciente após segmentação do sinal em movimento e não-movimento. O processo de amostragem do sinal é o mesmo empregado na estimativa do ritmo cardíaco e respiratório, como será detalhado posteriormente.

O modelamento estatístico busca descrever a distribuição de cada classe (movimento e não movimento) para que seja possível discriminá-las. As distribuições são caracterizadas utilizando modelos Gaussianos unidimensionais

$$p(x|\mu_{i},\sigma_{i}^{2}) = \frac{1}{\sqrt{2\pi\sigma_{i}^{2}}}e^{\left[\frac{-(x-\mu_{i})^{2}}{2\sigma_{i}^{2}}\right]},$$

onde $\mu_i e \sigma_i^2$ representam a média e a variância da classe *i*. Após estimadas as distribuições, aplica-se a regra de decisão de máxima verossimilhança aos dados de teste para determinar a qual classe eles pertencem. Assumindo que ambas as classes são igualmente prováveis, o dado é atribuído à classe *C_i* cuja probabilidade for maior, conforme a equação

$$p(x|\mu_1, \sigma_1^2) \stackrel{\geq}{\underset{\leq}{\geq}} p(x|\mu_2, \sigma_2^2)$$

$$C_2$$

Para avaliação do método, Adami et al. (2012) compararam os resultados com anotações realizadas por um técnico durante exames de PSG.



Figura 23 - Segmentação do sinal em períodos de movimento (vermelho) e não-movimento (azul).

FONTE: Elaborado pelo autor.

4.2.3 Estimativa do ritmo cardíaco

Nesta etapa foi estimado o ritmo cardíaco, para cada paciente, utilizando os sinais das células de carga durante os períodos em que o paciente se encontra no leito e não há movimento. Será descrito o processo de estimativa do ritmo cardíaco sob a perspectiva do método AMDF e de técnicas para minimização do erro advindo da etapa de detecção. Por fim, será descrita, brevemente, a técnica MAPE de avaliação do ritmo cardíaco estimado.

A aquisição de batimentos cardíacos, por vezes, é realizada a partir de técnicas baseadas na variação de força mecânica, tornando o método extremamente sensível a quaisquer movimentos, inclusive os provenientes da respiração (PAALASMAA et al., 2014). Sinais de movimentos que reproduzem a contração e dilatação cardíaca podem ser extraídos a partir de sinais de células de carga, e empregados na estimativa do ritmo cardíaco (FURLANI, 2018). No entanto, faz-se necessário, anteriormente, remover sinais não relacionados tais como movimentos na cama. Todavia, ainda é necessária a aplicação de um filtro para extrair somente o sinal que representa os batimentos cardíacos, atenuando influências advindas de ruídos

diversos. O filtro possui frequências de corte próximas aos limites da frequência cardíaca, em torno de 0,5 e 1 Hz à baixa frequência e 2 a 20 Hz à alta frequência (BRINK; MÜLLER; SCHIERZ, 2006) (BRÜSER et al., 2011) (BRÜSER; WINTER; LEONHARDT, 2013).

Após extrair o sinal do coração a partir dos sinais das células de carga, é preciso identificar o intervalo de tempo entre dois batimentos cardíacos subsequentes. Para isso, Furlani (2018) utilizou a função de Diferença Média de Magnitude (AMDF, do inglês: *Average Magnitude Difference Function*) para detecção da frequência cardíaca, combinada com os estágios de correção, fusão e suavização, propostos por Furlani (2018). Estes estágios pósdetecção objetivam dirimir erros provenientes da detecção do ritmo cardíaco (Figura 24). Em seu trabalho, Furlani (2018) conclui que o melhor método para estimar o ritmo cardíaco, levando em consideração o MAPE médio entre as 5 células de carga, foi a AMDF³⁰, obtendo um erro de 5,71% (média entre os erros de cada célula de carga). Após as etapas de correção, fusão e suavização, o MAPE ainda foi reduzido para 1,90%, representando um erro absoluto médio de aproximadamente 1,17 bpm.





FONTE: (FURLANI, 2018)

A AMDF é comumente empregada no cálculo da frequência fundamental e extração da frequência cardíaca, ou ainda em aplicações envolvendo processamento de áudio para estimar o tom (ISASI et al., 2016). A AMDF, ou ainda a diferença D_m , pode ser definida por

$$D_m = \frac{1}{L} \sum_{k=1}^{L} |x[n] - x[n-m]|$$
, $m = 0, 1, ..., m_{max}$.

³⁰ No trabalho de Furlani (2018), foram realizados testes variando-se a janela de análise (ω_L) em 6, 12 e 30 segundos. O erro de 5,71% (melhor resultado) foi obtido com uma janela de 12 segundos, mesmo tamanho usado no desenvolvimento do presente trabalho, como posteriormente será melhor abordado.

onde x[n] são as amostras do sinal mensurado, x[n - m] as amostras deslocadas de um tempo m segundos e L o tamanho da janela de análise. A AMDF é utilizada em aplicações de tempo real e, apesar da semelhança existente com a ACF³¹, o método exige menos computacionalmente pois avalia a diferença entre os sinais, ao invés do produto como na ACF (MUHAMMAD, 2011; ROSS et al., 1974). Além disso, ao contrário do que ocorre na ACF, a amplitude é inversamente proporcional à semelhança entre o sinal e seu deslocamento. Neste caso é necessário avaliar os vales para encontrar o período do sinal (FURLANI, 2018).

Além da segmentação e filtragem do sinal do coração, o processo de estimativa do ritmo cardíaco desenvolveu-se em mais 4 etapas:

- 1. **Detecção**: sobre cada segmento (presença no leito e não movimento) resultante, aplicase uma janela de análise deslizante (ω_L) de 12 segundos sobre o sinal e o algoritmo de AMDF é executado. Como a frequência de amostragem do sinal (f_s) é igual a 250 Hz, conclui-se que cada segmento possui 3000 amostras. Sobre esse conjunto de amostras, o algoritmo estima o ritmo cardíaco (bpm) para cada uma das células de carga. Caso o intervalo em análise possua duração inferior ao da janela de análise ele é descartado. O processo é repetido deslocando a janela de análise por uma constante de tempo (ω_s) de 1 segundo. Um vetor de estimações do ritmo cardíaco é obtido.
- Correção: a fim de dirimir os erros de detecção, é aplicado um método probabilístico sobre os vetores de estimações para detectar os ritmos estimados que podem ter sido erroneamente estimados e corrigi-los.
- Fusão: os vetores de estimações do ritmo cardíaco do sinal de cada uma das células de carga são combinados. O resultado é um único vetor de estimações.
- Suavização: a fim de remover os valores atípicos (do inglês: *outliers*), as estimações por segmento são suavizadas utilizando um filtro mediana.
- O sinal resultante do processo representa o ritmo cardíaco estimado (bpm) (Figura 25).

$$ACF[n] = \sum_{k=0}^{N-1} x[k]x[k+n]$$

onde N pode variar de 0 a N - 1.

³¹ A função de autocorrelação de um sinal discreto no tempo $x \operatorname{com} N$ amostras é dada por



Figura 25 - Ritmo cardíaco estimado (vermelho) resultante do processo de detecção.

FONTE: Elaborado pelo autor.

4.2.4 Estimativa do ritmo respiratório

Partindo-se do mesmo princípio utilizado pelos algoritmos de estimação do ritmo cardíaco, Beattie (2013) explica que quando o indivíduo inspira, o diafragma acaba por deslocar órgão viscerais, movimento este que se ocorre em direção ao pé da cama. As células de carga fixadas nesta posição sofrem um incremento na força, enquanto as células situadas na cabeceira sofrem uma diminuição na força. Ao expirar, a massa dos órgãos viscerais desloca-se em direção à cabeceira, produzindo um aumento nas forças medidas pelas células de carga situadas nesta posição, e um decremento nas forças medidas pelas células de carga ao pé da cama.

Beattie (2013) propõe um algoritmo para automatizar a detecção de picos e vales em sinais de movimentos respiratórios captados por células de carga (Figura 26). Estes sinais representam as transições entre a inspiração e expiração. Os picos e vales detectados são utilizados para estimar a frequência e amplitude da respiração. Neste caso, o algoritmo desenvolvido detecta todos os máximos e mínimos locais dos sinais respiratórios, eliminando picos e vales que não são representam transições de inspiração-expiração. A técnica proposta por Beattie (2013) é composta por quatro etapas. Inicialmente, calcula-se o centro de pressão (CoP(t)) a partir de:

$$CoP(t) = \frac{\sum_{i=1}^{N} LC_i(t)[x_i, y_i]}{\sum_{i=1}^{N} LC_i(t)}$$

onde $LC_i(t)$ é a força medida pela *i*-ésima célula de carga no instante *t*. A linha de tendência é removida dos dados restantes da célula de carga usando dados de períodos em que o sujeito estava deitado quiescente. Após isso, um filtro passa-baixas *Chebyshev* Tipo II de 6^a ordem, com uma frequência de corte 0,76Hz e, atenuação na banda de parada de -40 dB, é aplicado a cada janela que desloca-se ao longo dos segmentos, classificados como presença no leito e não movimento. A interpolação das janelas aumenta o nível de detalhamento do sinal compreendido pelo segmento, contribuindo à minimização dos erros na estimativa do ritmo respiratório (BRINK, 2006). O *delay* dos filtros é corrigido em relação ao sinal original (BEATTIE, 2013).

Para estimar o ritmo respiratório empregou-se uma janela de análise ω_L de 12 s, com um deslocamento ω_s de 1s. Em seu trabalho, Piva relaciona alguns tamanhos de janelas de análise com o tempo útil e o erro quadrático médio. Para janelas de maior valor, o erro quadrático médio diminui, no entanto o tempo útil decresce. Um dos valores de janela analisados foi de 15 s, resultando em um tempo útil de 327,98h (69,77%) e um erro quadrático médio em torno de 5,5%. Baseado nestas constatações, inferiu-se que ao utilizar uma janela de análise de 12 s o erro na estimativa do ritmo respiratório poderia aumentar. Em contrapartida, o tempo útil aumentaria, indicando que em torno de 30% do sinal não seria utilizado na análise, valor este próximo ao que foi encontrado também para uma janela de análise de 60 s (melhor resultado). Com isso, seria possível realizar o alinhamento temporal entre o sinal cardíaco e respiratório para detectar de sono, sem perdas consideráveis na estimação do ritmo respiratório.

O próximo passo é a identificação dos pontos de máximo local para cada janela de análise ao longo dos segmentos. Picos com amplitudes inferiores a 45% do pico anterior e posterior são desconsiderados. O ritmo respiratório é estimado pela duração dos ciclos determinados pela ocorrência de 2 (dois) ou mais picos consecutivos, conforme a equação:

$$RPM = \frac{60}{\frac{1}{60}\sum_{i=1}^{N}\frac{d_i}{F_S}}$$

O número de respirações por minuto (RPM) pode ser inferido pela duração média de cada incursão respiratória (segundos por respiração). (BEATTIE, 2013; PIVA, 2018).



Figura 26 - Processo de detecção do ritmo respiratório

FONTE: Elaborada pelo autor.

4.3 EXTRAÇÃO DE CARACTERÍSTICAS

Esta etapa estima as características a partir dos sinais do ritmo cardíaco, respiratório e de movimentos. Estas características foram extraídas dos sinais em intervalos de tempo de 30 s conhecidos como épocas, geralmente empregados em trabalhos relacionados à detecção de sono (AUSTIN et al., 2012; GUERRERO-MORA, 2012; KORTELAINEN et al., 2010; MATAR et al., 2018; MENDEZ et al., 2017; MIGLIORINI et al., 2010; PARK et al., 2014; SAMY et al., 2014; VANDEKERCKHOVE et al., 2014; WALSH et al., 2014; YANG et al., 2016).

Sobre cada época foram removidos valores de ritmo cardíaco, ou respiratório, que não estivessem dentro da faixa de normalidade. Alguns trabalhos apontam que a frequência cardíaca normal de um adulto em repouso encontra-se na faixa de 50 a 100 bpm (MASON et al., 2007), sendo a mesma utilizada como base pela Sociedade Brasileira de Cardiologia. Frequências abaixo de 50 bpm podem ser diagnosticadas como bradicardia e acima de 100 bpm como taquicardia (FURLANI, 2018). Com relação a frequência respiratória, trabalhos apontam de 8 a 24 RPM (respirações por minuto) (BEATTIE, 2013). Caso esses valores não sejam removidos, o modelo gerado terá problemas, em vista de ter sido treinado com valores errôneos.

Após a remoção desses valores, foram estimados: a mediana do ritmo cardíaco, os intervalos de batimentos cardíacos (IBI), energia do sinal de ritmo cardíaco, valor quadrático médio do sinal de ritmo cardíaco, ritmo cardíaco máximo, logaritmo natural da variância do ritmo respiratório, coeficiente de variação, intervalo entre o máximo e mínimo ritmo respiratório (*range*) e logaritmo natural da variância da soma ponderada da diferença quadrática média dos sinais das células de carga (AUSTIN et al., 2012; KORTELAINEN et al., 2010; MIGLIORINI et al., 2010; VANDEKERCKHOVE et al., 2014; WALSH et al., 2017). Por fim, são gerados n vetores de características com 9 dimensões, para cada paciente, aptos a serem utilizados no treinamento do modelo SVM.

4.4 CLASSIFICAÇÃO E METODOLOGIA DE AVALIAÇÃO

Para desenvolvimento do detector de sono baseado em aprendizagem de máquina supervisionado empregou-se máquina de vetores de suporte (SVM). A função de mapeamento (kernel) usada foi a gaussiana, também conhecida como base radial não linear (RBF, do inglês: *Radial Basis Function*), comumente empregada em trabalhos envolvendo a detecção de sono (AUSTIN et al., 2012; MENDEZ et al., 2017; VANDEKERCKHOVE et al., 2014; WALSH et al., 2017).

4.5 DECISÃO

A existência de uma etapa após a classificação tem por objetivo dirimir erros da predição, melhorando o desempenho do sistema. No presente trabalho, foi empregado um filtro mediana unidimensional de ordem 13 ao sinal predito.
5 ANÁLISE EXPERIMENTAL

Este capítulo tem por objetivo apresentar os resultados obtidos para cada uma das etapas do processo de detecção de sono. As Seções 5.1 e 5.2 têm por objetivo descrever a base de dados utilizada e a extração dos rótulos a partir do hipnograma de sono dos pacientes. As Seções 5.3 e 5.4 apresentam resultados da detecção de presença no leito e movimentos, respectivamente. As Seções 5.5 e 5.6 apresentam resultados das estimativas do ritmo cardíaco e respiratório e, por fim, a Seção 5.7 apresenta o desempenho do sistema de detecção do sono.

5.1 BASE DE DADOS

A base de dados empregada neste trabalho contém informações adquiridas no monitoramento de 59 pacientes em um laboratório dedicado à análise do sono. Cada paciente submeteu-se à uma noite completa de monitoramento, com duração média de 8 horas, sendo que a soma das 59 noites de sono resultou em mais de 440 horas de monitoramento. Durante a execução dos protocolos, foram coletados simultaneamente dados referentes ao PSG, conectando ao paciente diversos sensores para monitorar a respiração. Os dados do PSG foram coletados através do Datalab, Rembrandt 9.0 (Embla 2008).

A base de dados contém sinais de força capturados por células de carga acopladas aos suportes da cama. Os protocolos de coleta foram executados de forma controlada, utilizando uma cama *queen size* com 5 suportes de apoio em que as células de carga (DS, DI, ES, EI, M), com capacidade de 100 Kg cada que foram instaladas conforme a Figura 27 (PIVA, 2018). Todos os sinais coletados (células de carga e PSG) foram posteriormente validados manualmente por técnicos vinculados ao laboratório (FURLANI, 2018; PIVA, 2018).





Fonte: (PIVA, 2018).

Para construir a base, foram empregadas células de carga de ponto único modelo AG100C3SH5eU (SCAIME, Annemasse). A taxa de amostragem utilizada para a aquisição dos dados das células de carga foi de 500 Hz. O sinal adquirido pela célula de carga passou por um filtro para atenuar radio-frequência, e foi amplificado (ganho de 265) pelo amplificador de instrumentação modelo LT1167, ajustando a tensão de offset para que a escala represente 0 Kg a -4V e 100 kg a 3,95V. Em seguida, o sinal foi filtrado por um Butterworth de ordem 4 e frequência de corte 150Hz. Por fim, os sinais foram submetidos à conversão analógico-digital através do USB-1608FS (16 bits) (FURLANI, 2018; PIVA, 2018).

A base de dados possui, além dos sinais advindos das células de carga, sinais de capnometria, EEG, EMG, ECG, cinto pletismográfico, oxímetro e EOG. A Figura 28 exemplifica os sinais de extensometria disponíveis na base de dados, sendo mostrado em verde o sinal da célula de carga central (M), em azul o canto superior direito (DS), em vermelho o canto direito inferior (DI), em roxo o canto esquerdo superior (ES), em amarelo o canto esquerdo inferior (EI) (PIVA, 2018).





Fonte: (PIVA, 2018).

5.2 EXTRAÇÃO DOS RÓTULOS E PREPARAÇÃO DOS SINAIS EMPREGADOS NA DETECÇÃO DO SONO

A base de dados empregada no trabalho possui o hipnograma dos pacientes, com informações sobre a data e hora de início e término do monitoramento, o segmento, duração e um rótulo referente ao estágio do sono. Este rótulo era anotado a cada 30 s, pelo técnico responsável pela realização da PSG. Rótulos iguais a -1 ou 0 indicam que o paciente está acordado. Rótulos de 1 a 5 são usados para indicar os estágios do sono, sendo que rótulos de 1

a 4 correspondem ao sono NREM e 5, o sono REM. Rótulos iguais ou maiores a 6 são ignorados.

Como o presente trabalho foca apenas na detecção de períodos em que o paciente se encontra acordado ou dormindo, os rótulos de 1 a 5 foram considerados como "*sleep*" (paciente dormindo) e os rótulos iguais a 0 ou -1 como "*wake*" (paciente acordado). Os rótulos maiores ou iguais a 6 considerou-se como "*ignored*" (ignorados). Com os rótulos definidos, foram executados *scripts* para leitura dos arquivos que continham o hipnograma de cada paciente, sendo gerados arquivos com informações sobre a data inicial, hora inicial, data final, hora final e o dado relativo ao rótulo para os 59 pacientes.

Cada amostra estimada de ritmo cardíaco, ritmo respiratório e movimento, deveria receber o rótulo correspondente. Como as amostras encontravam-se alinhadas temporalmente, um processo semelhante ao utilizado para estimá-las foi empregado para rotulá-las. A amostra foi rotulada com base na comparação do período correspondente à janela e ao período correspondente a cada rótulo no arquivo gerado, após extração das informações do hipnograma. Caso a janela se encontrasse em um período que corresponde a "acordado", era atribuído o rótulo igual a 1 (*wake*) à amostra. Caso a janela se encontrasse em um período que corresponde a "dormindo", era atribuído o rótulo igual a 0 (*sleep*). Um período correspondente a "ignorado"

Antes que os sinais pudessem ser empregados na detecção do sono, foi necessária uma prévia preparação para utilizá-los nas etapas posteriores. As amostras com rótulos iguais a 2 (*ignored*) foram removidas, restando apenas amostras com rótulos 0 ou 1 (*sleep* ou *wake*). Sobre as amostras restantes, as que estavam rotuladas como 0, trocou-se por um rótulo igual a -1. Essa alteração foi realizada com vistas a deixar as classes *wake* e *sleep* com valores padrão 1 e -1, respectivamente, geralmente empregados por modelos SVM (THEODORIDIS & KOUTROUMBAS, 2008).

5.3 DETECÇÃO DE PRESENÇA NO LEITO

A avaliação do algoritmo de detecção de presença no leito foi feita com base na rotulação dos dados em duas classes: presente e ausente. O processo foi realizado manualmente, a partir da análise do sinal das células de carga e com auxílio das anotações do técnico que acompanhou as noites de monitoramento. Utilizando o algoritmo *k-means*, conforme descrito na Seção 4.2,

obteve-se resultados satisfatórios à detecção de presença no leito. A matriz de confusão, em minutos, é apresentada na Tabela 6.

		Classe Verdadeira			
		Presente	Ausente		
Classe Estimada	Dracanta	26501,06	1,55		
	riesente	(100%)	(1,44%)		
	Auconto	1,33	105,47		
	Ausenie	(0,00%)	(98,56%)		

Tabela 6 - Matriz de confusão após aplicação do algoritmo k-means para detecção de presença no leito.

FONTE: O autor.

5.4 DETECÇÃO DE MOVIMENTOS

Do mesmo modo como foi realizada a detecção de presença no leito, a rotulação dos dados às classes movimento e não-movimento foi manual, com o auxílio das anotações do técnico. Porém, os dados fornecidos pelas anotações do técnico não contemplavam todos os intervalos de movimento do paciente. De acordo com Furlani (2018), para rotular os intervalos com movimentos que não constavam nas anotações, foi feita uma inspeção visual nos sinais das células de carga, procurando por períodos onde fossem visíveis grandes distúrbios no sinal. Em virtude da dificuldade de execução e da demanda de tempo necessária à análise de cada paciente, foram rotulados os dados de apenas 8 dos 59 pacientes, totalizando 58 horas de análise. A Tabela 7, apresenta a matriz de confusão após detecção de movimentos. Empregando-se uma janela L de 6 segundos (FURLANI,2018), obteve-se uma sensitividade 82,61% e especificidade de 92,89%.

Tabela 7 - Matriz de confusão após aplicação do detector de movimentos (minutos)

		Classe Verdadeira			
		Movimento	Não-movimento		
Classe Estimada	Movimento	477,68	210,31		
	Wovimento	(82,61%)	(7,11%)		
	Não movimento	100,56	2747,67		
	inao-movimento	(17,39%)	(92,89%)		

FONTE: O autor.

5.5 RITMO CARDÍACO

A estimativa do ritmo cardíaco foi desenvolvida com base no processo descrito na Seção 4.2.3, sendo os resultados comparados aos encontrados por Furlani (2018). O ritmo cardíaco estimado foi avaliado com base no ritmo cardíaco real advindo do ECG, durante a PSG. Dentre as técnicas existentes para avaliar algoritmos de detecção do ritmo cardíaco, empregou-se o cálculo do erro percentual absoluto médio (MAPE, do inglês: *Mean Absolute Percentage Error*) (BRÜSER; WINTER; LEONARD, 2013) (KORTELAINEN; VIRKKALA, 2007). O MAPE entre o número de batimentos estimado \hat{T}_i e a referência do ECG T_i é obtida a partir da equação:

$$MAPE = \frac{100\%}{N} \sum_{i=1}^{N} \frac{|\Delta_i|}{T_i},$$

onde $\Delta_i = \hat{T}_i - T_i \in N$ denota o número de intervalos (BRÜSER et al., 2015).

Após o estágio de detecção do ritmo cardíaco, o MAPE médio encontrado para os 59 pacientes foi de 4,5%. Este resultado representa uma melhora de 21,2% em relação ao MAPE médio encontrado por Furlani (2018), de 5,71%. Contudo, o MAPE médio pós correção, fusão e suavização foi de 2,17%, representando um aumento de 14,2% em relação ao resultado encontrado por Furlani (2018), de 1,9%.

5.6 RITMO RESPIRATÓRIO

Para avaliar o desempenho da estimativa do ritmo respiratório, optou-se por empregar o erro quadrático médio. Seja N o número de observações, X_i o ritmo respiratório real, extraído da base de dados conforme descrito na Seção 4.2.4, e x_i o ritmo respiratório estimado, o erro quadrático médio, *EQM*, pode ser calculado a partir da equação abaixo:

$$EQM = \sqrt{\frac{\sum_{i=1}^{N} (X_i - x_i)^2}{N}}.$$

Para o ritmo respiratório estimado, foi calculada a média do erro quadrático médio para os 59 pacientes, comparando-se o resultado aos valores encontrados por Piva (2018). Como descrito anteriormente, a janela de análise empregada foi de 12 s. Neste caso, o erro médio encontrado foi de 8,12%, maior do que o encontrado por Piva (2018) para uma janela de análise de 15 s. Um aumento no erro médio para o conjunto de pacientes já era esperado devido à diminuição da janela de análise (PIVA, 2018). No entanto, para que as amostras de ritmo respiratório estejam alinhadas temporalmente com as de ritmo cardíaco, é necessário que durante o processo de amostragem se empregue deslocamentos e janelas de análise iguais. Do contrário, poderia incorrer-se em erros ao classificar os períodos de vigília e sono. Além disso, valores de ritmo respiratório (ou cardíaco) que estiverem fora de uma faixa aceitável não influenciaram na extração das características, como explicado anteriormente.

5.7 DETECÇÃO DE SONO

Para avaliar o desempenho do sistema de detecção do sono serão empregadas 3 métricas: acurácia, sensitividade e especificidade. Estas medidas são amplamente usadas em trabalhos envolvendo detecção do sono, em especial, a sensitividade e a especificidade (AUSTIN et al., 2012; GUERRERO-MORA, 2012; KORTELAINEN et al., 2010; SAMY et al., 2014; VANDEKERCKHOVE et al., 2014; WALSH et al., 2014; POUYAN et al., 2015; YANG et al., 2016).

Devido ao pequeno número de pacientes, utilizou-se o método *leave-one-subject-out cross validation* (LOSOCV) para treinar o classificador e calcular as métricas de desempenho. Neste método, os dados de um sujeito são deixado de lado enquanto que os dados dos demais sujeitos são utilizados para treinar o classificador. Em seguida, o classificador é avaliado no sujeito deixado de lado. Este procedimento repete-se para cada um dos pacientes, garantindo que o classificador treine e teste toda a base de dados. Este método também tem a propriedade de reduzir a variabilidade do resultado (DUDA et al., 2000). Além disso, há uma garantia de independência do classificador para com os pacientes monitorados, pois o modelo obtido não estaria relacionado a um grupo de pessoas, mesmo que estas fossem escolhidas aleatoriamente.

Os resultados estimados sobre os 59 pacientes mostraram que existe uma preferência do classificador pela classe sono. Uma hipótese para a ocorrência deste problema foi o desbalanceamento entre as classes ou seja, uma das classes possui mais amostras que a outra. A classe que representa o paciente acordado (menos amostras) corresponde em média 1,7% do total do número de amostras, enquanto a classe paciente dormindo (mais amostras), 98,3%.

Com objetivo de dirimir o problema de classes desbalanceadas optou-se por realizar experimentos utilizando a técnica de amostragem aleatória simples. Neste processo, cada amostra é escolhida aleatoriamente, de modo que cada uma tenha a mesma probabilidade de ser escolhida durante o processo de amostragem. Formam-se então subconjuntos de amostras a partir de um conjunto maior (YATES et al., 2002). O conjunto de treinamento formado com

base nesta técnica de amostragem possui para cada classe (paciente acordado e paciente dormindo) o mesmo número de amostras, sendo que a classe de referência foi a que representa o paciente acordado por possuir um menor número de amostras. Esperava-se que a sensitividade pudesse aumentar com essa abordagem, o que não ocorreu. Após treinar o classificador usando a LOSOCV e com conjuntos de treinamento equalizados não houve alteração no desempenho, com o sistema detectando apenas quando o paciente estava dormindo. Uma outra hipótese para este problema continuar foi com relação às características empregadas.

Como as medidas que caracterizam os sinais de ritmo cardíaco, respiratório e movimentos possuem magnitudes diferentes, alguma característica pode dominar as demais, influenciando na obtenção do classificador (WEBB & COPSEY, 2011). Em função disto, optou-se por realizar a normalização das variáveis do conjunto de treinamento empregando a técnica *z-score* (WEBB & COPSEY, 2011). O *z-score z* pode ser obtido pela relação

$$z = \frac{x - \mu}{\sigma}.$$

Na equação acima x é a amostra e, μ e σ a média e o desvio padrão das amostras, respectivamente, do conjunto de características. Vandekerckhove et al. (2014) utilizam *z-score* na normalização de características de sinais cardiorrespiratórios e movimentos, obtidas a partir de épocas de 60 s. Após treinar o classificador usando a LOSOCV não se verificou alteração no desempenho. O sistema continuou detectando apenas quando o paciente estava dormindo.

Com o objetivo de verificar se o problema era com as características, foram realizados alguns experimentos para determinar se era possível melhorar o desempenho do sistema. Neste sentido, para cada um dos pacientes, foi realizada uma inspeção visual no espaço de características em 2-D, verificando os pacientes cujas características possuíam maior dissimilaridade entre as classes³². Na Figura 29 é apresentado o conjunto de características para o paciente monitorado no dia 28/01/2011. É possível verificar as características uma maior dissimilaridade entre as classes acordado e dormindo, diferentemente do que ocorre para o paciente do dia 01/02/2011 (Figura 30). Os pacientes escolhidos de forma arbitrária formaram o conjunto de treinamento, sobre o qual foi aplicada a técnica LOSOCV com as classes equalizadas. Após o processo, verificou-se que houve uma melhora no desempenho do sistema

³² Essa inspeção visual não garante que os melhores pacientes serão escolhidos pois o mapeamento das características em uma dimensão maior pode separá-las melhor.

pois o classificador começou a detectar os momentos em que o paciente estava acordado também, aumentando a sensitividade.

85 80 75 70					and the second s				-1
900 800 700									
7000 6000 5000	and the second sec								
85 80 75 70	and the second s								100 - 25 A
85 80 75 70	and the second			and the second sec					
3 2 1								- Contraction of the State of t	
10 5						-		- Contraction ()	
0.2 0.1						and the second		<u>fhl</u>	
15 10 5 0									
	65 70 75 80 85	700 800 900	5000 6000 7000	65 70 75 80 85	70 80	0 1 2 3	0 5 10	0 0.1 0.2	0 5 10 15

Figura 29 - Conjunto de características representado em 2-D para o paciente monitorado no dia 28/01/2011. É possível verificar que há uma dissimilaridade maior entre as classes para a maioria das características.

FONTE: Elaborado pelo autor.





FONTE: Elaborado pelo autor.

Ainda que o processo de escolha do conjunto de treinamento foi feito de forma arbitrária, apenas com base nos pacientes cujas características eram mais dissimilares em 2-D, foi possível observar uma melhora no desempenho do sistema. Para validar o processo de escolha dos melhores pacientes que integrariam o conjunto de treinamento, bem como as características usadas para detecção de sono, foram realizados experimentos onde os próprios dados do paciente eram usados no treinamento e teste do classificador. Os pacientes foram

ranqueados com base nas seguintes métricas: especificidade, sensitividade, precisão, média entre a especificidade e sensitividade, e média entre a especificidade, sensitividade e precisão.

Foram selecionados conjuntos com 10, 15 e 20 pacientes com os melhores resultados para cada métrica. Com as classes equalizadas e usando LOSOCV para avaliação, o conjunto com 20 pacientes ranqueados com base na média entre a especificidade e sensitividade foi o que apresentou melhores resultados (acurácia, sensitividade, especificidade) (Figura 31). O conjunto de teste foi composto por 39 pacientes restantes. Sobre cada paciente do conjunto de teste foram estimadas as métricas de desempenho, sendo o desempenho geral do sistema calculado a partir da média de cada uma dessas medidas para o conjunto de pacientes.



Figura 31 - Desempenho médio dos pacientes selecionados com base na média entre a especificidade e a sensitividade. É possível verificar o aumento na sensitividade, à medida que o conjunto de treinamento é formado por mais pacientes. O melhor desempenho se deu para um conjunto de treinamento com 20 pacientes.

FONTE: Elaborado pelo autor.

Em um primeiro momento, a avaliação do sistema foi feita com base nos resultados da classificação de conjuntos de teste com dados relativos ao vetor de características com 9 dimensões (vide Seção 4.3). Neste caso, obteve-se o melhor desempenho com uma acurácia de 49,0%, sensitividade de 50,1% e especificidade de 53,1% (Figura 32). É possível verificar também o desempenho do sistema para outras combinações de características dos sinais ou seja, características de ritmo cardíaco e respiratório, ritmo respiratório e movimentos, etc. Porém, avaliando a sensitividade e a especificidade, o melhor resultado ainda continua sendo a combinação de características dos sinais de ritmo cardíaco, respiratório e movimento.



Figura 32 - Desempenho do sistema após classificação

FONTE: Elaborado pelo autor.

Com vistas a melhorar o desempenho do sistema, foi feito um pós-processamento com a aplicação de um filtro mediana de tamanho ímpar sobre o sinal advindo da classificação. Como resultado, a sensitividade ficou em 51,5%, que representa um aumento de 2,8%, enquanto a especificidade ficou em 54,8%, um aumento de 3,2%. Neste caso, foram empregadas características dos sinais de ritmo cardíaco, respiratório e movimentos (Figura 33). Para as demais combinações de características, em geral, verifica-se que o desempenho melhorou. Diferentes tamanhos de filtro foram usados, sendo que o que melhor resultado proporcionou foi o filtro mediana de tamanho 13.



Figura 33 - Desempenho do sistema após aplicação do filtro mediana

FONTE: Elaborado pelo autor.

Os resultados encontrados foram comparados a alguns trabalhos. Kortelainen et al. (2010) obtiveram uma sensitividade de 48%, representando um desempenho de 6,8% inferior ao que foi encontrado no presente trabalho. Sinais de VFC e movimentos foram adquiridos a de um grupo com 9 pacientes do sexo feminino. Destes sinais, foram extraídas características a partir de épocas de 30 s, sendo usada a técnica LOSOCV para treinamento do classificador. Em outro trabalho, Samy et al. (2014) obtiveram uma sensitividade de 56,9% usando características extraídas de épocas de 30 s, sobre dados sobre a postura e orientação do corpo, empregando o classificador KNN. Ao usar SVMs, a sensitividade do sistema aumentou para 68,6%, 33,2% maior em relação ao que se encontrou. Nos trabalhos relacionados foi realizada a detecção de estágios do sono (REM e NREM), não sendo possível neste caso comparar resultados de especificidade (paciente dormindo).

Contudo, Walsh et al. (2017) avaliam um sistema de detecção de sono, para os estados acordado ou dormindo, onde os dados são advindos de um sensor de pressão colocado sob o colchão dos pacientes monitorados. Ao todo, foram coletados dados de 30 pacientes. Os autores obtiveram uma especificidade de 53,2% (paciente acordado) e uma sensitividade de 95,5% (paciente dormindo). Foram obtidas características estatísticas, espaciais e temporais de sinais de movimento, além do ritmo respiratório, a partir de sinais derivados do sensor de pressão, usando épocas de 30 s. O vetor de características possuía um total de 13 dimensões, sendo empregado um classificador LDA. Embora para a classe acordado o desempenho obtido pelos autores represente uma diferença de 3,3% em relação ao que foi obtido no presente trabalho para a classe dormindo a diferença fica em torno de 74%.

Ainda foi aplicado um processo de decisão por voto no qual baseou-se na escolha da classe que mais se repete, para diferentes classificações. Neste caso, o modelo SVM treinou sob diferentes combinações de características (ritmo cardíaco e respiratório, ritmo respiratório e movimentos, etc), algo semelhante ao que foi feito para avaliar os resultados da fusão. O conjunto de teste também possui as mesmas características empregadas para treinar a SVM. Cada combinação de características produziu uma predição, sendo o resultado dado pela classe que mais vezes resultar nas predições, para uma determinada amostra de teste. Não foi possível verificar melhora de desempenho comparado ao que foi obtido após aplicação do filtro mediana.

6 CONSIDERAÇÕES FINAIS

A qualidade do sono possui efeitos físicos e metabólicos, tais como alterações cognitivas, fadiga, sonolência diurna, além de estar relacionada ao desenvolvimento de obesidade, diabetes e infarto. Dentre os distúrbios que afetam a qualidade do sono estão a insônia, relacionada a dificuldades de iniciar, ou manter o sono, e a apneia obstrutiva do sono, que consiste na obstrução total ou parcial das vias aéreas durante o sono. A polissonografia é o padrão-ouro para diagnóstico destes distúrbios, bem como ao monitoramento do sono, sendo amplamente empregado por clínicas especializadas. Entretanto, o método apresenta algumas deficiências quando utilizado para o monitoramento contínuo e a longo prazo, além da técnica ser desconfortável ao paciente.

A inconveniência e o alto custo do polissonograma influenciou o estudo e desenvolvimento de outros métodos para acompanhamento do sono. Esses estudos podem ser separados conforme o objetivo do monitoramento como, por exemplo, a detecção de movimentos, a extração de informações cardíacas e a detecção de estágios do sono. Dentre algumas tecnologias não intrusivas, cujo estudo tem sido considerado promissor ao monitoramento do sono, estão as células de carga. E aliado a esta tecnologia, técnicas de aprendizado de máquina têm sido propostas como uma abordagem alternativa à construção de sistemas de detecção do sono a partir de sinais fisiológicos. Estes sistemas caracterizam-se por serem mais confortáveis ao paciente e eficazes na detecção de distúrbios do sono.

Com base no objetivo deste trabalho, foi implementado o sistema de detecção de sono, baseado em aprendizado de máquina, a partir de sinais advindos de células de carga. Inicialmente, o sistema detectava apenas períodos onde o paciente estava dormindo, o que indicava algum problema relacionado ao número de amostras para cada classe ou às características empregadas. Neste caso, foi necessário o uso de algumas técnicas, além da realização de experimentos, visando melhorar o desempenho do sistema. O uso da técnica de amostragem aleatória simples combinada à seleção dos pacientes com melhor desempenho individual (média entre especificidade e sensitividade) foram responsáveis por uma melhora significativa no desempenho do sistema, fazendo com que o sistema detectasse também períodos onde o paciente estava acordado. Como complemento, realizou-se o pósprocessamento o sinal predito advindo do classificador usando um filtro mediana. Como resultado, obteve-se uma especificidade de 54,8% e uma sensitividade de 51,5%, quando empregadas características de ritmo cardíaco, respiratório e movimentos. Estes resultados representaram o melhor desempenho do sistema durante a análise experimental, sendo comparados a alguns trabalhos relacionados à detecção do sono.

Como melhorias futuras, é indicado investir na obtenção da variabilidade de ritmo cardíaco, ao invés de usar características do ritmo cardíaco na detecção do sono. Foi possível observar em todos os trabalhos utilizados como referencial à elaboração deste, que quando é empregado o sinal do coração para avaliar o sono, utilizam-se características estimadas da variabilidade do ritmo cardíaco (do inglês comumente conhecida por, *Heart Rate Variability*, HRV) (KORTELAINEN et al., 2010; MENDEZ et al., 2017; MATAR et al., 2018; MIGLIORINI et al., 2010; VANDEKERCKHOVE et al., 2014; YANG et al., 2016). Esperase que com estas mudanças haja uma melhora no desempenho do sistema.

REFERÊNCIAS

ANDERSEN, M. L.; BITTENCOURT, L. R. A. Fisiologia do sono. In: TUFIK, Sergio. **Medicina e biologia do sono.** São Paulo: Manole, 2008. Cap. 5, p. 48 - 58.

ADAMI, A.m. et al. Detection and Classification of Movements in Bed using Load Cells. **2005 IEEE Engineering In Medicine And Biology 27th Annual Conference**, [s.l.], p.7881-7884, 2005. IEEE.

ADAMI, A. M. Assessment and classification of movements in bed using unobtrusive sensors. 2006. Tese Doutorado — Oregon Health & Science University, 2006.

ADAMI, A. M. et al. A system for unobtrusive monitoring of mobility in bed. 11th IEEE International Conference on Computational Science and Engineering - Workshops, [S.I.], p. 13–18, July 2008.

ADAMI, A.m. et al. Detection of Movement in Bed Using Unobtrusive Load Cell Sensors. **IEEE Transactions On Information Technology In Biomedicine**, [s.l.], v. 14, n. 2, p.481-490, mar. 2010. Institute of Electrical and Electronics Engineers (IEEE).

ADAMI, A. M. et al. Gaussian model for movement detection during Sleep. **2012** Annual International Conference of The IEEE Engineering in Medicine And Biology Society, [s.l.], p.1-10, ago. 2012. IEEE.

ALMONDES, Katie Moraes de e ARAUJO, John Fontenele de. **Padrão do ciclo sono-vigília** e sua relação com a ansiedade em estudantes universitários. *Estud. psicol. (Natal)* [online]. 2003, vol.8, n.1, pp.37-43. ISSN 1678-4669.

ARAÚJO, Márcio Flávio Moura de et al. Health indicators associated with poor sleep quality among university students. **Revista da Escola de Enfermagem da Usp**, [s.l.], v. 48, n. 6, p.1085-1092, dez. 2014. FapUNIFESP (SciELO).

ASERINSKY, Eugene; KLEITMAN, Nathaniel. Regularly Occurring Periods of Eye Motility, and Concomitant Phenomena, During Sleep1. **The Journal Of Neuropsychiatry And Clinical Neurosciences**, [s.l.], v. 15, n. 4, p.454-455, nov. 2003. American Psychiatric Publishing.

AUSTIN, D. et al. Unobtrusive classification of sleep and wakefulness using load cells under the bed. **2012 Annual International Conference Of The IEEE Engineering In Medicine And Biology Society**, [s.l.], p.1-10, ago. 2012. IEEE.

BEATTIE, Z. T. Unobtrusive detection of breathing using load cells and the application to sleep apnea detection. 2013. Tese Doutorado — Oregon Health & Science University, 2013.

BENEDITO-SILVA, A. A. Cronobiologia do ciclo vigília-sono. In: TUFIK, S. et al. **Medicina** e Biologia do Sono. Barueri: Manole, 2008. p. 24 - 33.

BIANCHI, A M; MENDEZ, M O. Automatic detection of sleep macrostructure based on a sensorized T-shirt. **2010 Annual International Conference Of The IEEE Engineering In Medicine And Biology**, [s.l.], p.3606-3609, ago. 2010. IEEE.

BIN, Yu Sun. Is Sleep Quality More Important than Sleep Duration for Public Health? **Sleep**, [s.l.], v. 39, n. 9, p.1629-1630, set. 2016. Oxford University Press.

BITTENCOURT, L. R. A.; PALOMBINI, L. Síndrome da Apnéia e Hipopnéia Obstrutiva do Sono (SAHOS): Fisiopatologia. In: TUFIK, S. et al. Medicina e Biologia do Sono. Barueri: Manole, 2008. p. 240 - 247.

BRINK, M.; MÜLLER, C. H.; SCHIERZ, C. Contact-free measurement of heart rate, respiration rate, and body movements during sleep. Behavior research methods, [S.l.], v. 38, n. 3, p. 511–521, 2006.

BRÜSER, C. et al. Adaptive beat-to-beat heart rate estimation in ballistocardiograms. IEEE Transactions on Information Technology in Biomedicine, [S.l.], v. 15, n. 5, p. 778–786, Sept 2011.

BUYSSE, Daniel J.. Sleep Health: Can We Define It? Does It Matter?. **Sleep**, [s.l.], v. 37, n. 1, p.9-17, jan. 2014. Oxford University Press.

CHELLAPPA, Sarah Laxhmi. **Sonolência excessiva diurna e depressão: causas, implicações clínicas e manejo terapêutico.** *Rev. psiquiatr. Rio Gd. Sul* [online]. 2009, vol.31, n.3, suppl...

CHERVIN RD. Use of clinical tools and tests insleep medicine. In: Kryger MH, Roth T, Dement WC, editors. Principles and practice of sleep medicine. 3rd ed. Philadelphia: WB. Saunders; 2000. p. 535-8.

CHOI, B. H. et al. Slow-wave sleep estimation on a load-cell-installed bed: a non-constrained method. Physiological measurement, [S.l.], v. 30, n. 11, p. 1163, 2009.

CHUNG, Gih Sung et al. Noninvasive Heart Rate Variability Analysis Using Loadcell-Installed Bed During Sleep. **2007 29th Annual International Conference Of The IEEE Engineering In Medicine And Biology Society**, [s.l.], p.2357-2360, ago. 2007. IEEE.

Cover, T.M. Geometrical and Statistical properties of systems of linear inequalities with applications in pattern recognition. IEEE Transactions on Electronic Computers. p.326-334, jun. 1965. IEEE.

DEVOT, Sandrine; DRATWA, Reimund; NAUJOKAT, Elke. Sleep/wake detection based on cardiorespiratory signals and actigraphy. **2010 Annual International Conference Of The IEEE Engineering In Medicine And Biology**, [s.l.], p.5089-5092, ago. 2010. IEEE.

DUDA, Richard O.; HART, Peter E.; STORK, David G. Pattern Classification. 2. ed. New York, N.y: John Wiley & Sons, 2001. 738 p.

EL-MANZALAWY, Yasser; BUXTON, Orfeu; HONAVAR, Vasant. Sleep/wake state prediction and sleep parameter estimation using unsupervised classification via clustering. **2017 IEEE International Conference On Bioinformatics And Biomedicine (BIBM)**, [s.l.], p.718-723, nov. 2017. IEEE.

FIALHO, Arivelto Bustamante. Instrumentação Industrial: Conceitos, Aplicações e Análises. 7a ed. São Paulo: Érica, 2010.

FLETCHER EC, LUCKETT RA. The effect of positive reinforcement on hourly compliance in nasal continuous positive airway pressure users with obstructive sleep apnea. Am Rev Respir Dis. 1991;143(5 Pt 1):936-41.

FRANCHI, Claiton Moro. Instrumentação de Processos Industriais – Princípios e Aplicações. 1a ed. São Paulo : Érica, 2015.

FUKUNAGA, Keinosuke. **Introduction to Statistical Pattern Recognition.** 2. ed. San Diego, Ca: Academic Press, 1990. 616 p.

FURLANI, Alisson Lopes. **Monitoramento não-intrusivo do ritmo cardíaco durante o sono**. Caxias do Sul, 2018. 47 p. Trabalho de Conclusão de Curso – Bacharelado em Engenharia de Controle e Automação, Universidade de Caxias do Sul, 2018.

GOLDSHTEIN, e; A TARASIUK,; ZIGEL, y. Automatic Detection of Obstructive Sleep Apnea Using Speech Signals. **IEEE Transactions On Biomedical Engineering**, [s.l.], v. 58, n. 5, p.1373-1382, maio 2011. Institute of Electrical and Electronics Engineers (IEEE).

GORESTEIN C, TAVARES S, ALÓE F. Questionários de auto-avaliação de sono. In: Gorestein C, Andrade LHS, Zuard AW. Escalas de avaliação clínica em psiquiatria e psicofarmacologia. São Paulo: Lemos; 2000. p. 423-34.

GUERRERO-MORA, G. et al. Sleep-wake detection based on respiratory signal acquired through a Pressure Bed Sensor. **2012 Annual International Conference Of The IEEE Engineering In Medicine And Biology Society**, [s.l.], p.3452-3455, ago. 2012. IEEE.

HACHEM, A., AYACHE, M., KHANSA, L.E., & JEZZINI, A. (2015). ECG classification for Sleep Apnea detection. 2016 3rd Middle East Conference on Biomedical Engineering (MECBME), 38-41.

HAYKIN, Simon. Redes Neurais: Princípios e prática. Porto Alegre RS: Bookman, 2001.

HIPÓLIDE, D. C. Bases Neurais do Ciclo de Vigília e Sono. In: TUFIK, Sergio. Medicina e biologia do sono. São Paulo: Manole, 2008. Cap. 4, p. 34 - 47.

HORNE JA, OSTBERG O. A self assessment questionnaire to determine morningnesseveningness in human circadian rhythms. Int J Chronobiol. 1976;4(2):97-110.

HOSHINO, Katsumasa. Aspectos Filogenéticos do Sono. In: TUFIK, S. et al. Medicina e Biologia do Sono. Barueri: Manole, 2008. p. 7 - 23.

HUANG L, ZHOU G, LIU Z, DANG X, YANG Z, KONG X-Z, et al. (2016) A Multi-Atlas Labeling Approach for Identifying Subject-Specific Functional Regions of Interest. PLoS ONE 11(1): e0146868.

JEZZINI, Ali et al. ECG classification for sleep apnea detection. **2015 International Conference On Advances In Biomedical Engineering (ICABME)**, [s.l.], p.301-304, set. 2015. IEEE..

JOHNS MW. A new method for measuring daytime sleepiness: the Epworth sleepiness scale. Sleep. 1991;14(6):540-5.

JORDAN, Amy S; MCSHARRY, David G; MALHOTRA, Atul. Adult obstructive sleep apnoea. **The Lancet**, [s.l.], v. 383, n. 9918, p.736-747, fev. 2014. Elsevier BV.

JÚNIOR, L. R. P. Insônia. In: TUFIK, S. et al. **Medicina e Biologia do Sono.** Barueri: Manole, 2008. p. 205 - 217.

JÚNIOR, L. R. P.; SILVA, R. S. Polissonografia Normal e nos Principais Distúrbios do Sono. In: TUFIK, S. et al. **Medicina e Biologia do Sono.** Barueri: Manole, 2008. p. 161 - 180. KAY, Daniel B. et al. Sleep-Wake Differences in Relative Regional Cerebral Metabolic Rate for Glucose among Patients with Insomnia Compared with Good Sleepers. **Sleep**, [s.l.], v. 39, n. 10, p.1779-1794, out. 2016. Oxford University Press.

KEMPFNER, Jacob et al. Automatic SLEEP staging: From young aduslts to elderly patients using multi-class support vector machine. **2013 35th Annual International Conference Of The IEEE Engineering In Medicine And Biology Society (embc)**, [s.l.], p.5777-5780, jul. 2013. IEEE.

KORTELAINEN, Juha M et al. Sleep Staging Based on Signals Acquired Through Bed Sensor. **IEEE Transactions On Information Technology In Biomedicine**, [s.l.], v. 14, n. 3, p.776-785, maio 2010. Institute of Electrical and Electronics Engineers (IEEE).

KORTELAINEN, J., GILS, M.V., & PARKKA, J. (2012). Multichannel bed pressure sensor for sleep monitoring. 2012 Computing in Cardiology, 313-316.

ISASI, I. et al. Monitoring the heart rate in cerebral oximetry signals. In: COMPUTING IN CARDIOLOGY CONFERENCE (CINC), 2016., 2016. Anais. . . [S.l.: s.n.], 2016. p. 1121–1124.

MALAEKAH, Emad; PATTI, Chanakya Reddy; CVETKOVIC, Dean. Automatic sleep-wake detection using electrooculogram signals. **2014 IEEE Conference On Biomedical Engineering And Sciences (iecbes)**, [s.1.], p.724-728, dez. 2014. IEEE.

MANUEL, Ari; HARDINGE, Maxine. Obstructive sleep apnoea. **Medicine**, [s.l.], v. 44, n. 6, p.336-341, jun. 2016. Elsevier BV.

MARCHI N. S. A; BORGES M. A. Polissonografia. In: REIMÃO, Rubens. Temas de Medicina do Sono. São Paulo: Lemos Editorial, 2008, p. 24 - 32.

MARTINEZ, D. Prática da medicina do sono. São Paulo: BYK, 1999.

MARTINEZ, D. Insônia na prática clínica. Porto Alegre: Artmed, 2005.

MELLO, M. T.; ESTEVES, A. M. Distúrbios de Movimento – Movimentos Periódicos de Pernas (MPP/PLM) e Síndrome das Pernas Inquietas (SPI/RLS). In: TUFIK, Sergio. **Medicina e biologia do sono.** São Paulo: Manole, 2008. Cap. 5, p. 306 - 317.

MENDEZ, M.o. et al. Automatic detection of sleep macrostructure based on bed sensors. **2009 Annual International Conference Of The IEEE Engineering In Medicine And Biology Society**, [s.l.], p.5555-5558, set. 2009. IEEE.

MENDEZ, Martin O. et al. Detection of the Sleep Stages Throughout Non-Obtrusive Measures of Inter-Beat Fluctuations and Motion: Night and Day Sleep of Female Shift Workers. **Fluctuation And Noise Letters**, [s.l.], v. 16, n. 04, p.1-16, dez. 2017. World Scientific Pub Co Pte Lt.

MIGLIORINI, M et al. Automatic sleep staging based on ballistocardiographic signals recorded through bed sensors. **2010 Annual International Conference Of The IEEE Engineering In Medicine And Biology**, [s.l.], p.3273-3276, ago. 2010. IEEE.

MUHAMMAD G., Extended average magnitude difference function based pitch detection. **The International Arab Journal of Information Technology**, vol. 8, no. 2, pp. 197-203, April 2011.

NICOLELIS, Miguel. Muito Além do Nosso Eu: A nova neurociência que une cérebro e máquinas e como ela pode mudar nossas vidas. São Paulo: Planeta, 2017.

OHAYON, Maurice et al. National Sleep Foundation's sleep quality recommendations: first report. **Sleep Health**, [s.l.], v. 3, n. 1, p.6-19, fev. 2017. Elsevier BV.

ORELLANA, G. et al. A balanced sleep/wakefulness classification method based on actigraphic data in adolescents. **2014 36th Annual International Conference Of The IEEE** Engineering In Medicine And Biology Society, [s.l.], p.4188-4191, ago. 2014. IEEE.

PAALASMAA, J. et al. Monitoring sleep with force sensor measurement. Department of Computer Science Series of Publications A, [S.I.], 2014.

PARK, Kwang Suk; HWANG, Su Hwan; JUNG, da Woon. Ballistocardiography for nonintrusive sleep structure estimation. **2014 36th Annual International Conference Of The IEEE Engineering In Medicine And Biology Society**, [s.l.], p.5184-5187, ago. 2014. IEEE.

PARTINEN M, GISLASON T. Basic Nordic Sleep Questionnaire (BNSQ): a quantitated measure of subjective sleep complaints. J Sleep Res. 1995;4(S 1):150-5.

PEEVER, John; FULLER, Patrick m.. Neuroscience: A Distributed Neural Network Controls REM Sleep. **Current Biology**, [s.l.], v. 26, n. 1, p.1-24, jan. 2016. Elsevier BV.

PILLAI, Vivek; ROTH, Thomas; DRAKE, Christopher L.. The Nature of Stable Insomnia Phenotypes. **Sleep**, [s.l.], v. 38, n. 1, p.127-138, jan. 2015. Oxford University Press (OUP).

PIVA, Guilhermo Offmaister. **Sistema de avaliação do ritmo respiratório baseado em células de carga**. Bento Gonçalves, 2018. 45 p. Trabalho de Conclusão de Curso – Bacharelado em Engenharia Eletrônica, Universidade de Caxias do Sul, 2018.

PHILLIPS, A.j.k.; ROBINSON, P.a.; KLERMAN, E.b.. Arousal state feedback as a potential physiological generator of the ultradian REM/NREM sleep cycle. Journal Of Theoretical Biology, [s.l.], v. 319, p.75-87, fev. 2013. Elsevier BV.

POUYAN, M. Baran; NOURANI, M.; POMPEO, M. Sleep state classification using pressure sensor mats. **2015 37th Annual International Conference Of The IEEE Engineering In Medicine And Biology Society (embc)**, [s.l.], p.1207-1210, ago. 2015. IEEE.

REIMÃO, R., Temas de Medicina do Sono. São Paulo: Lemos Editorial, 2000.

RAUDYS S.J., JAIN A.K. Small size effects in statistical pattern recognition: Recommendations for practitioners. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 13, n. 3, p. 252–264, 1991.

ROGERS VE et al. Periodic limb movements and disrupted sleep in children with sickle cell disease. *Sleep*. 2011;34(7):899-908. Published 2011 Jul 1.

ROSINHA, M. U. Fisiologia do sono: Atualizações. In: REIMÃO, Rubens. **Temas de Medicina do Sono.** São Paulo: Lemos Editorial, 2008, p. 17 - 22.

ROSS, M. et al. Average magnitude difference function pitch extractor. IEEE Transactions on Acoustics, Speech, and Signal Processing, [S.l.], v. 22, n. 5, p. 353–362, Oct 1974.

SAMY, Lauren et al. Unobtrusive Sleep Stage Identification Using a Pressure-Sensitive Bed Sheet. **IEEE Sensors Journal**, [s.l.], v. 14, n. 7, p.2092-2101, jul. 2014. Institute of Electrical and Electronics Engineers (IEEE).

SHORT, Nicole A. et al. Sleep and affective functioning: Examining the association between sleep quality and distress tolerance among veterans. **Personality And Individual Differences**, [s.l.], v. 90, p.247-253, fev. 2016. Elsevier BV.

TATARAIDZE, Alexander et al. Sleep stage classification based on respiratory signal. 2015 37th Annual International Conference Of The IEEE Engineering In Medicine And Biology Society (embc), [s.l.], p.358-361, ago. 2015. IEEE.

THEODORIDIS, Sergios; KOUTROUMBAS, Konstantinos. **Pattern Recognition.** 4. ed. Burlington, Mass: Elsevier, 2009.

THOMAZINI, Daniel e ALBUQUERQUE, Pedro Urbano Braga de. Sensores industriais: fundamentos e aplicações. 8. ed. rev. e atual. São Paulo: Érica, 2011.

TOGEIRO, Sônia Maria Guimarães Pereira e SMITH, Anna Karla. **Métodos diagnósticos nos distúrbios do sono.** *Rev. Bras. Psiquiatr.*[online]. 2005, vol.27, suppl.1, pp.8-15. ISSN 1516-4446.

VARELLA, M. Insônia atinge 73 milhões de brasileiros. 2018. Disponível em: https://drauziovarella.uol.com.br/neurologia/insonia-2/. Acesso em: 20 Ago. 2018.

WALSH, Lorcan et al. Noncontact Pressure-Based Sleep/Wake Discrimination. **IEEE Transactions On Biomedical Engineering**, [s.l.], v. 64, n. 8, p.1750-1760, ago. 2017. Institute of Electrical and Electronics Engineers (IEEE).

WEBB, Andrew R.; COPSEY, Keith D.. **Statistical Pattern Recognition**. 3. ed. New York, N.y: John Wiley & Sons, 2011. 668 p.

WILLEMEN, T. et al. An Evaluation of Cardiorespiratory and Movement Features With Respect to Sleep-Stage Classification. **IEEE Journal Of Biomedical And Health Informatics**, [s.l.], v. 18, n. 2, p.661-669, mar. 2014. Institute of Electrical and Electronics Engineers (IEEE).

YANG, Jialei et al. Sleep stage recognition using respiration signal. **2016 38th Annual International Conference Of The IEEE Engineering In Medicine And Biology Society** (embc), [s.l.], p.1-4, ago. 2016. IEEE.

YATES, D. S., STARNES, D. S. and MOORE, D. S.. *The practice of statistics*.: W H Freeman & Co, 2002.