

**Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**

---

## Reconhecimento de Apneia através de Redes Neurais

Cristina Zaniol<sup>1</sup>

Programa de Pós Graduação em Matemática Aplicada, UFRGS, Porto Alegre, RS

Maria Cristina Varriale<sup>2</sup>

Programa de Pós Graduação em Matemática Aplicada, UFRGS, Porto Alegre, RS

Evandro Manica<sup>3</sup>

Instituto de Matemática e Estatística, UFRGS, Porto Alegre, RS

**Resumo.** A apneia é um distúrbio do sono caracterizado pela interrupção ou redução do fluxo de ar por pelo menos 10 segundos, cuja severidade é dada pelo AHI (*Apnea Hypopnea Index*). Em geral, o diagnóstico da apneia é feita com base na Polissonografia, exame no qual são extraídos sinais que fornecem informações como Eletrocardiograma (ECG), Eletroencefalograma (EEG), saturação do oxigênio no sangue (SpO<sub>2</sub>), entre outros. Outras alternativas tem sido desenvolvidas para verificar quais os sinais dentre aqueles que compõem a Polissonografia poderiam ser utilizados prioritariamente no diagnóstico, proporcionando uma redução de custos e, também, o aumento do conforto do paciente. Neste trabalho utilizou-se os dados da saturação do oxigênio, para a extração de parâmetros, e as Redes Neurais, para o reconhecimento de padrões da apneia, na análise de 25 pacientes presentes no banco de dados da UCDDDB, do *St. Vincent's Hospital*, em Dublin. Ainda que promissores, os resultados obtidos não permitem a classificação efetiva dos pacientes.

**Palavras-chave.** Redes Neurais, Doenças do Sono, Apneia

## 1 Introdução

Ao longo das últimas décadas, a evolução da instrumentação médica e dos sistemas computacionais propiciaram uma melhoria no processo de diagnóstico; por outro lado, acarretaram no acréscimo da quantidade de dados a serem processados [2, 6]. Ainda, estudos mostram indícios de *informações escondidas* que não podem ser definidas visualmente ou através de métodos de avaliação tradicionais [6].

A apneia do sono é uma doença com grandes impactos para o indivíduo e para a saúde pública, caracterizada pela interrupção ou redução do fluxo de ar por pelo menos 10 segundos, e é associada com outras enfermidades, como depressão, doenças cardíacas, diabetes *mellitus*, e obesidade. Estima-se que, nos Estados Unidos, 13% dos homens e 6% das mulheres sofrem com o distúrbio [4]. No Brasil ainda há poucos estudos epidemiológicos sobre a apneia. Entre eles, Lemos *et al.* aborda a incidência de apneia em motoristas de

---

<sup>1</sup>criszaniol@gmail.com

<sup>2</sup>cris@mat.ufrgs.br

<sup>3</sup>evandro.manica@ufrgs.br

São Paulo, dos quais 11,5% dos 209 entrevistados apresentavam indícios de apneia [8]; Tufik *et al.* estudaram 1042 voluntários de São Paulo, dos quais 16,9% apresentavam apneia moderada ou severa [11].

A grande dificuldade de determinar a incidência da doença está relacionada com o diagnóstico, realizado através da Polissonografia. Neste, o paciente passa a noite em uma clínica, conectado a uma série de eletrodos, o que gera uma grande quantidade de dados, muitas vezes repletos de ruídos [1, 3]. Visto que a maioria dos dados coletados ainda passa apenas por análise visual de profissionais da área da saúde, estes podem ser subutilizados, além de incorrer em maiores chances de erros de diagnóstico decorrente da subjetividade. Os primeiros avanços no reconhecimento automático da apneia foram possíveis apenas a partir de 2000, impulsionados pelo evento *Challenge from PhysioNet and Computers in Cardiology 2000*, verificando a possibilidade de utilizar ECG no diagnóstico da apneia [6, 10]. Percebe-se que, a fim de gerar informações relevantes de maneira eficiente, são necessárias novas abordagens estatísticas e computacionais para a análise dos dados, como algoritmos de aprendizagem, dos quais se destacam as Redes Neurais.

O uso do Oxímetro para estimar a saturação do oxigênio no sangue ( $SpO_2$ ) seria uma alternativa para o reconhecimento automático da apneia [1, 3, 4]. A proposta deste estudo é verificar a precisão da classificação da apneia utilizando a  $SpO_2$  do banco de dados UCDDDB [12], que será apresentado na Seção 5. Este trabalho está dividido em: Seção 2, uma breve descrição da Rede Neural; Seção 3, a descrição dos dados utilizados; Seção 4, os parâmetros para a caracterização do  $SpO_2$ ; Seção 5, os resultados do estudo; e a Seção 6, algumas considerações finais.

## 2 Rede Neural

As Redes Neurais são algoritmos com habilidade de aprendizagem, generalizando padrões que podem ser utilizado na classificação [7]. Cada neurônio  $k$  da Rede Neural pode ser matematicamente representado por

$$u_k = \sum_{j=1}^m w_{kj} x_j, \quad (1)$$

onde  $w_{kj}$  é o peso utilizado pelo neurônio  $k$  para um sinal de entrada  $x_j$ . A saída da Rede Neural produzida pelo  $k$ -ésimo neurônio,  $y_k$ , é dada por

$$y_k = \sigma(v_k), \quad (2)$$

onde

$$v_k = u_k + b_k, \quad (3)$$

com o erro  $b_k$ , cuja finalidade é de aumentar ou diminuir a saída do neurônio, permitindo o ajuste dos dados com a saída esperada, isto é, melhorando a eficiência do treinamento; e  $\sigma(\cdot)$  função de ativação, cuja função é análoga às sinapses: inibir ou excitar a transmissão da informação quando é ultrapassado determinado limiar. A função de ativação adotada

é a sigmoide logística, a saber

$$\sigma(v_k) = \frac{1}{1 + e^{-\lambda v_k}}, \quad (4)$$

onde  $\lambda$  é um fator de declividade. Como um único neurônio não é capaz de aprender todos os conjuntos de treinos eficientemente, é necessário considerar uma estrutura com interconexões entre neurônios a fim de aumentar a quantidade de tarefas que possam ser executadas.

Neste trabalho foi utilizada aprendizagem supervisionada, com topologia  $6-N-2$ , onde  $N$  é o número de neurônios utilizados pela Rede Neural na camada escondida e que varia entre 5 e 50. O algoritmo de aprendizagem adotado foi o SCG (*Scaled Conjugate Gradient*), com *MSE-reg* (Erro Quadrático Médio Regularizado) [9]. Para avaliar o resultado do treinamento, é utilizado o método de validação cruzada *leave-one-out*: do total de 25 pacientes, 24 são utilizados para o treinamento e realiza-se a avaliação com o restante. Para determinar uma medida de precisão para a classificação dos pacientes são adotadas a sensibilidade, a especificidade e a acurácia, que medem respectivamente a proporção de: classificações corretas de apneia, de não apneia e classificações corretas totais de apneia e não apneia. Essas medidas são dadas por [3]

$$\boxed{\text{Sensibilidade}} = \frac{TP}{TP + FN}, \quad (5)$$

$$\boxed{\text{Especificidade}} = \frac{TN}{TN + FP}, \quad (6)$$

$$\boxed{\text{Acurácia}} = \frac{TP + TN}{TP + FP + TN + FN}, \quad (7)$$

onde  $TP$  e  $TN$  descrevem o diagnóstico correto da apneia e da não apneia, respectivamente; por sua vez,  $FP$  e  $FN$ , o incorreto da apneia e da não apneia.

### 3 Os Dados

O banco de dados, composto por 25 Polissonografias, cujos indivíduos eram pacientes do *St Vincent's University Hospital*, Dublin, com suspeita de Distúrbio Respiratório do Sono [6, 12]. Os pacientes que integram o banco de dados possuem entre 28 e 68 anos, sendo 4 mulheres e 21 homens e, em média, acima do peso ideal. As informações são sintetizadas na Tabela 1. Além disso, nenhum dos pacientes possuem doenças cardíacas conhecidas, disfunção autonômica, que causa redução do fluxo sanguíneo nos tecidos muscular e conjuntivo, e também não é administrado medicamento que interfira na frequência cardíaca.

Tabela 1: Idade, IMC e AHI das Polissonografias analisadas.

Idade			IMC			AHI		
Média	Mínimo	Máximo	Média	Mínimo	Máximo	Média	Mínimo	Máximo
50	28	68	31,6	25,1	42,5	24,24	2	91

As Polissonografias foram realizadas no período da noite e com duração entre 5 e 8 horas, obtidas utilizando o sistema Jaeger-Roennies, e registrando: EEG, EOG, EMG, ECG, fluxo respiratório nasal, esforço abdominal e da caixa torácica, saturação do oxigênio ( $SpO_2$ ), ronco e posição corporal. No presente trabalho utilizou-se apenas a saturação do oxigênio,  $SpO_2$ , para extração de parâmetros.

## 4 Extração de Parâmetros

O oxímetro é um dispositivo externo que é preso ao dedo, e estima a saturação de oxigênio nas hemoglobinas do paciente. Os valores padrão para a oximetria são superiores a 90% , podendo chegar a níveis inferiores a 70% em eventos de apneia, onde há decréscimo de pelo menos 2% no nível de oxigenação [5]. O pré-processamento envolve a exclusão de dados resultantes de falhas na obtenção do sinal através de filtros de média.

Para a extração dos parâmetros, o sinal foi segmentado em intervalos de 60 segundos e foram extraídos os seguintes parâmetros: média, valor mínimo, número de  $SpO_2 < 92\%$ , média da variação e a variação da saturação em relação a média do sinal [1]. Estes parâmetros são utilizados como dados de entrada para a Rede Neural.

## 5 Resultados

Na Figura 1 são dados os valores da acurácia no diagrama de caixas para  $N = 5, 10, 15, 20, 25, 30, 35, 40, 45$  e 50 neurônios na camada escondida, onde os pontos no diagrama de caixas representam o resultado obtido para cada um dos testes. Foram realizados 25 testes no total, onde em cada um deles foi utilizado os dados de 24 pacientes para o treinamento e classificação do arquivo não utilizado no treinamento.

Observe que a acurácia ficou entre 80 e 85%, apresentando o melhor resultado com 40 neurônios, aproximadamente 83%. Além disso, não há presença de *outliers*, com acurácia mínima obtida em cerca de 65%.




Figura 1: Acurácia do teste *leave-one-out* para  $SpO_2$ .

Outros resultados são apresentados na Tabela 2, onde pode ser visto que a especificidade média manteve-se superior aos 90%. Além disso, a sensibilidade média permaneceu acima dos 30% para todos os números de neurônios da camada escondida,  $N$ , chegando ao ápice com 38,63% para 15 neurônios.

Tabela 2: Resultado médio da classificação com parâmetros  $SpO_2$  (valores em %).

Neurônios	05	10	15	20	25	30	35	40	45	50
Sensibilidade	33,12	35,32	38,63	37,48	37,92	36,16	37,48	36,75	37,99	38,06
Especificidade	94,06	93,90	92,80	92,56	92,76	92,67	92,75	92,66	93,26	91,99
Acurácia	81,55	82,20	82,19	82,62	81,99	82,33	82,44	82,82	82,28	82,28
Erro de classificação	18,48	17,88	17,93	17,46	18,13	17,79	17,68	17,30	17,84	17,84

Na Tabela 3 é realizado um comparativo entre os resultados obtidos (valores mínimos e máximos para a acurácia) com [1] e [3]. Em [1], a classificação da apneia é realizado com o mesmo banco de dados [12], com o mesmo conjunto de características e classificado com Função Discriminante Logística; e em [3], a partir de um banco de dados de 21 Polissonografias de crianças do *Sleep Study Center* do *Clinical Hospital of Catholic University of Chile*, são utilizadas extrações de características com a Transformada Wavelet e classificação com Redes Neurais em um outro banco de dados. Em comparação com [1], os resultados da sensibilidade, em média, foram um pouco inferiores; entretanto, para a especificidade, foi possível obter um resultado melhor. Observa-se que a Rede Neural apresentou melhores resultados para a especificidade que a Função Discriminante Logística [1]. Já em comparação com [3], que utilizou outras características para a avaliação do sinal da saturação do oxigênio, há uma melhora significativa tanto em relação a sensibilidade, como a especificidade, cuja acurácia difere em pelo menos 29%. Portanto, o método obteve resultados melhores para acurácia que [1] e [3].

Tabela 3: Comparação dos resultados com [1] e [3] para  $SpO_2$  (valores em %).

	Mínimo	Máximo	de Chazal <i>et al.</i> , 2015	Erazo e Riós, 2014
Sensibilidade	33,12	38,63	37,50	19,67
Especificidade	91,99	94,06	79,00	77,69
Acurácia	81,55	82,82	70,60	52,46

Ainda que a acurácia seja superior a 80%, é a especificidade que serve de indicativo para a possibilidade do uso deste método como ferramenta de auxílio do diagnóstico. Desta forma, é sugerido que o modelo de classificação proposto seja utilizado apenas para o descarte do diagnóstico da apneia em determinados pacientes, sendo necessária análise de outros sinais da Polissonografia a fim de confirmar diagnósticos e a respectiva severidade.

## 6 Considerações Finais

Os resultados obtidos neste trabalho indicam que, tal como utilizado, o modelo possibilita auxiliar no diagnóstico, uma vez que serve de suporte para a exclusão de pacientes que possuem graus leves de apneia. Mais estudos são necessário para determinar outros parâmetros que possam aumentar a precisão, assim como a investigação de outras topologias para as Redes Neurais. Estudos futuros incluem a aplicação deste algoritmo em banco de dados maiores, com pacientes da Região Sul do Brasil, possibilitando um número maior de padrões para aprendizagem e, possivelmente, uma acurácia maior na classificação automática da apneia.

## Agradecimentos

À CAPES, pelo apoio financeiro.

## Referências

- [1] P. de Chazal, N. Sadr, N., M. Jayawardhana, An ECG oximetry system for identifying obstructive and central apnoea events. *Engineering in Medicine and Biology Society (EMBC)*, 2015 37th Annual International Conference of the IEEE, p. 7671-7674. IEEE, 2015. DOI: 10.1109/EMBC.2015.7320169.
- [2] I. Dimitrovski, D. Kocev, I. Kitanovski, S. Loskovska, S. Döeroski. Improved medical image modality classification using a combination of visual and textual features. *Computerized Medical Imaging and Graphics*, v. 39, p. 14-26, 2015. DOI: <http://dx.doi.org/10.1016/j.compmedimag.2014.06.005>.
- [3] L. Erazo, S. A. Riós, A benchmark on automatic obstructive sleep apnea screening algorithms in children. *Procedia Computer Science*, v. 35, p.739-746, 2014. DOI: 10.1016/j.procs.2014.08.156.
- [4] H. Espiritu, V. Metsis, Automated detection of sleep disorder-related events from polysomnographic data. *Healthcare Informatics (ICHI)*, 2015 International Conference on, p. 562-569. IEEE, 2015. DOI: 10.1109/ICHI.2015.105.
- [5] W. W. Flemons, W. T. McNicholas, Clinical prediction of the sleep apnea syndrome. *Sleep medicine reviews*, v. 1, n. 1, p. 19-32, 1997. DOI: 10.1016/S1087-0792(97)90003-4.
- [6] A. L. Goldberger, L. A. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C. K. Peng, H. E. Stanley. Physiobank, physiotoolkit, and physionet components of a new research resource for complex physiologic signals. *Circulation*, v. 101, n. 23, e215-e220, 2000. DOI: 10.1161/01.CIR.101.23.e215.
- [7] S. Haykin. *Neural Networks and Learning Machines*, vol.10, Prentice Hall, 2009.

- [8] L. C. Lemos E. C. Marqueze, F. Sachi, G. Lorenzi-Filho, C. R. de C. Moreno. Síndrome da apnéia obstrutiva do sono em motoristas de caminhão. *J Bras Pneumol*, v. 35, n. 6, p. 500-506, 2009. DOI: 10.1590/S1806-37132009000600002.
- [9] M. F. Møller. A scaled conjugate gradient algorithm for fast supervised learning. *Neural networks*, v. 6, n. 4, p. 525-533, 1993. DOI: 10.1016/S0893-6080(05)80056-5.
- [10] T. Penzel, J. McNames, P. De Chazal, B. Raymond, A. Murray, G. Moody. Systematic comparison of different algorithms for apnoea detection based on electrocardiogram recordings. *Medical and Biological Engineering and Computing*, v. 40, n. 4, p. 402-407, 2002. DOI: 10.1007/BF02345072.
- [11] S. Tufik, R. Santos-Silva, J. A. Taddei, L. R. A. Bittencourt. Obstructive Sleep Apnea Syndrome in the Sao Paulo Epidemiologic Sleep Study. *Sleep Medicine*, v. 11, n. 5, p. 1389-9457, 2010. DOI: 10.1016/j.sleep.2009.10.005.
- [12] UCDDDB. St. Vincent's University Hospital/University College Dublin Sleep Apnea Database, 2008. Url: <http://physionet.org/physiobank/database/ucddb/>.