


UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
GRADUAÇÃO EM ENGENHARIA DA COMPUTAÇÃO



Redução de alarmes falsos em UTIs para diagnósticos de arritmias cardíacas utilizando redes neurais convolucionais

PROPOSTA DE TRABALHO DE GRADUAÇÃO

Aluno: Gabriel Bezerra Lima (gbl@cin.ufpe.br)
Orientador: Germano Crispim Vasconcelos (gcv@cin.ufpe.br)
Área: Deep Learning

21 de Setembro de 2018

Resumo

Milhões de pessoas passam pelas UTIs todos os anos. Em uma UTI pacientes em estado grave ou de alto risco passam por monitoramento constante através de diferentes tipos de equipamentos. Esses equipamentos de monitoramento, além de ajudarem no acompanhamento dos pacientes pela equipe médica, tem o potencial de gerar alarmes quando detectam algum tipo de distúrbio. Porém esses alarmes podem causar vários problemas nos pacientes e na própria equipe, dificultando a recuperação dos pacientes devido ao barulho, privação de sono, entre outros fatores. O objetivo deste trabalho é reduzir a quantidade de alarmes falsos de taquicardia através de uma análise automatizada de sinais oriundos desses equipamentos de monitoramento, utilizando redes neurais convolucionais.

Introdução

Anualmente milhões de pessoas passam pelas UTIs (Unidades de Terapia Intensiva). Segundo o CREMESP [9] (Conselho Regional de Medicina do Estado de São Paulo) essas unidades se caracterizam pelo acompanhamento através de monitoramento constante à pacientes graves ou de alto risco com possibilidade de recuperação. Uma característica comum desses sistemas de monitoramento são a geração de alarmes, segundo Chambrin MC [2] é possível encontrar mais de 40 fontes diferentes de alarmes em UTIs vindos de equipamentos como eletrocardiogramas, medidores de pressão arterial e respiração, entre outras fontes. Porém, apesar desses alarmes terem um potencial alto de salvar vidas, estudos indicam que o contato constante com eles podem trazer sérios problemas na recuperação dos pacientes e no dia-a-dia da equipe médica. Um alarme geralmente produz sons acima de 80 dB, mesmo valor encontrado em fábricas e o dobro do encontrado em um quarto (Parthasarathy S et al. [12]). Uma consequência direta é a privação de sono que pode dificultar a recuperação de todos os pacientes afetados pelo barulho. Outra consequência é a dessensibilização da equipe médica, de acordo com (Chambrin MC, 2001; Imhoff, 2006) após um certo tempo alguns médicos aumentaram bastante os limites dos equipamentos de tal forma que mesmo problemas sérios não seriam detectados pelo alarme, além disso alguns enfermeiros começaram a atrasar o atendimento ao paciente tentando reconhecer se o alarme era verdadeiro ou falso apenas pelos sons (mesmo enfermeiros experientes tinham uma taxa de acerto de 38%). Para agravar ainda mais a situação, cerca de 90% dos alarmes em uma UTI são falsos positivos (quando um alarme indica um problema que não está ocorrendo) (Imhoff, 2006). Esse tipo de alarme geralmente é gerado por ruídos a partir do movimento dos pacientes, problemas na medição do equipamento e até conexões mal feitas.

O diagnóstico de um paciente em UTIs é feito majoritariamente através de inspeção visual do paciente e/ou dos equipamentos que o monitoram. Porém essa análise dos equipamentos tem um alto fator interpretativo aumentando a probabilidade de erros na identificação desses alarmes falsos. Por isso muitos trabalhos têm surgido com o objetivo de minimizar a presença desses alarmes falsos.

Muitos autores consideraram a abordagem de extração de características dos sinais estudados (Li, 2012; Aboukhalil, 2008; Borowski, 2011; Li, 2014). Essa abordagem consiste em extrair valores derivados dos dados originais (e.g. Quantidade de batidas em um sinal de eletrocardiograma) para facilitar o processo de classificação dos sinais. Em Aboukhalil [10] e Borowski [11] as características são extraídas para construção de filtros que detectam se os alarmes gerados pelos equipamentos são verdadeiros ou falsos. No primeiro, é criado um filtro posterior que analisa sinais de pressão sanguínea arterial [ABP] e eletrocardiogramas [ECG] para 5 tipos de problemas cardíacos diferentes. Já no segundo é desenvolvido um novo algoritmo para aplicação

em equipamentos de eletrocardiograma. Em Li [8, 13] as características extraídas alimentam algoritmos de *machine learning* para atingir o objetivo dos problemas. Em Li [8] é feita a análise de fotopletismografias (PPG) para classificação de qualidade dos sinais usando *Multilayer Perceptrons* (MLP). O mesmo autor em [13] extrai 14 características diferentes para análise de ECGs utilizando *Support Vector Machines* (SVMs).

A extração de características em séries temporais (conjunto de dados associados a tempo) é um grande desafio por uma série de motivos como ruído, alta dimensionalidade dos dados, características variantes ao longo do tempo (como média, variância) como mencionado em Långkvist [1]. Devido à isso, trabalhos mais recentes têm usado *deep learning* para realizar as tarefas que propõem (Acharya, 2017; Rajpurkar, 2017; Pyakillya, 2017). A principal vantagem do uso de *deep learning* é a capacidade de extrair essas características automaticamente dos dados, reduzindo os custos associados a extração e permitindo até encontrar características relevantes que um ser humano não seja capaz de encontrar. Nesses trabalhos são usadas diferentes arquiteturas de Redes Neurais Convolucionais (CNNs - *Convolutional Neural Networks*). Uma rede neural convolucional é um tipo de algoritmo de *machine learning* especializada em processamento de dados em grade (i.e. séries temporais, imagens, vídeos, entre outros). Em Acharya [4] são utilizados dados de 12 eletrodos de eletrocardiograma (de 200 pacientes) para detecção automática de infarto no miocárdio. Em Rajpurkar [5] são utilizados 64121 gravações de ECGs para classificação de 12 tipos de arritmias cardíacas. Finalmente em Pyakillya [7] são utilizadas 8528 gravações para identificação do ritmo cardíaco dos pacientes.

A dificuldade no uso de algoritmos de *deep learning* é encontrar uma arquitetura apropriada para se atingir uma boa precisão. Além disso esse tipo de abordagem necessita de uma grande quantidade de dados, muitas vezes não disponíveis, principalmente quando dependem de revisão de pessoas. Porém, ultrapassado esses objetivos é possível atingir ótimos resultados.

Objetivos

O objetivo deste trabalho é comparar diferentes abordagens de Redes Neurais Convolucionais na identificação de alarmes falsos em 5 tipos de arritmia cardíacas são elas: Asístole, Bradicardia Extrema, Taquicardia Extrema, Taquicardia Ventricular e Flutter/Fibrilação ventricular em UTIs através da análise de sinais de 5 tipos de equipamentos diferentes (Eletrocardiograma, Fotopletismografias, Pressão Sanguínea Arterial e Respiratórios). Para isso foram utilizados dados provenientes de 375 gravações de 3 dos maiores fabricantes de equipamentos de gravação do mundo. Esses dados foram providos por Goldberger AL [6] através do desafio “Reducing False Arrhythmia Alarms in the ICU: the PhysioNet/Computing in Cardiology Challenge 2015”




Figura 01 - Arquitetura geral de uma Rede Neural Convolucional (Fonte:Mathworks)



Figura 02 - Exemplo de um sinal de Eletrocardiograma

Metodologia

Na etapa de análise bibliográfica, será feita a análise do banco de dados providos por Goldberger AL [6] através do desafio “Reducing False Arrhythmia Alarms in the ICU: the PhysioNet/Computing in Cardiology Challenge 2015”. Serão estudadas formas de abordagem para extrair o máximo possível de informações relevantes para a aplicação nas redes neurais convolucionais. Ainda nesta etapa será feito o estudo das redes neurais convolucionais, bem como suas arquiteturas mais famosas. Por fim serão estudados trabalhos relacionados recentes de aplicação desse tipo de algoritmo em análise de séries temporais, equipamentos médicos e problemas cardíacos.

Após isso será feita a geração das entradas para os algoritmos estudados na análise bibliográfica. O objetivo dessa fase é gerar as imagens correspondentes aos alarmes verdadeiros e falsos para utilização posterior pelas redes neurais convolucionais.

Por fim, será feita a implementação de alguns dos algoritmos escolhidos na análise bibliográfica para avaliá-los quanto ao seus desempenhos na classificação de alarmes falsos presentes em UTIs.

Cronograma

	Período															
Atividade	Agosto		Setembro				Outubro				Novembro				Dezembro	
Revisão bibliográfica	X															
Implementação			X	X	X											
Estudo do algoritmo	X	X														
Experimentos					X	X	X									
Avaliação dos resultados								X	X							
Escrita do TG					X	X	X	X	X	X	X	X				
Preparação da apresentação													X	X		

Referências

- [1] Långkvist, M., Karlsson, L., & Loutfi, A. (2014). A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 42, 11-24.
- [2] Chambrin MC. Review: Alarms in the intensive care unit: how can the number of false alarms be reduced? *Critical Care*. 2001 Aug; 5(4):184-8. Epub 2001 May 23.
- [3] Imhoff M, Kuhls S. Alarm algorithms in critical care monitoring. *Anesth Analg.*, 2006 May; 102(5):1525-37.
- [4] Acharya, U. R., Fujita, H., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adam, M. (2017). Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals. *Information Sciences*, 415, 190-198.
- [5] Rajpurkar, P., Hannun, A. Y., Haghpanahi, M., Bourn, C., & Ng, A. Y. (2017). Cardiologist-level arrhythmia detection with convolutional neural networks. *arXiv preprint arXiv:1707.01836*.
- [6] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng CK, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/content/101/23/e215.full>]; 2000 (June 13). PMID: 10851218; doi: 10.1161/01.CIR.101.23.e215
- [7] Pyakillya, B., Kazachenko, N., & Mikhailovsky, N. (2017, October). Deep Learning for ECG Classification. In *Journal of Physics: Conference Series* (Vol. 913, No. 1, p. 012004). IOP Publishing.
- [8] Li, Q., & Clifford, G. D. (2012). Dynamic time warping and machine learning for signal quality assessment of pulsatile signals. *Physiological measurement*, 33(9), 1491.
- [9] Resolução CREMESP Nº 71, de 08 de Novembro de 1995. Define e regulamenta as atividades das Unidades de Terapia Intensiva. *Diário Oficial do Estado; Poder Executivo*, São Paulo, SP, n. 217, 14 nov. 1995. Seção 1
- [10] Aboukhalil, A., Nielsen, L., Saeed, M., Mark, R. G., & Clifford, G. D. (2008). Reducing false alarm rates for critical arrhythmias using the arterial blood pressure waveform. *Journal of biomedical informatics*, 41(3), 442-451.
- [11] Borowski M, Siebig S, Wrede C, Imhoff M. Reducing false alarms of intensive care online-monitoring systems: an evaluation of two signal extraction algorithms. *Comput Methods Programs Biomed* 2011,
- [12] Parthasarathy S, Tobin MJ. Sleep in the intensive care unit. *Intensive Care Med*. 2004 Feb; 30(2), 197-206.
- [13] Li, Q., Rajagopalan, C., & Clifford, G. D. (2014). Ventricular fibrillation and tachycardia classification using a machine learning approach. *IEEE Transactions on Biomedical Engineering*, 61(6), 1607-1613.

Possíveis Avaliadores

Prof. Ricardo Prudêncio

Prof. Adriano Lorena

Assinaturas

Recife, ____ de _____ de _____

Gabriel Bezerra Lima

(Aluno)

Germano Crispim Vasconcelos

(Orientador)