

Equipamento eletromédico intravenoso: uma proposta para qualificação da geração de alertas utilizando Naive Bayes

Felipe Camargo Gruendemann
Fabrício N. Ferreira, Luciano Agostini, Adenauer Yamin

¹Laboratory of Ubiquitous and Parallel Systems – UFPEL
Pelotas, RS - Brasil

{fcgruendemann, fferreira, agostini, adenauer}
@inf.ufpel.edu.br

Resumo. *As bombas de infusão são eletromédicos utilizados em larga escala e possuem alto índice de alarmes falsos positivos. Esse trabalho explora o método Naive Bayes na classificação de um dataset gerado a partir de ensaios que simulam a operação de uma bomba de infusão. O objetivo dos testes foi validar o modelo proposto na qualificação da geração de alertas. Os testes apontaram uma acurácia elevada para as situações normais sem oclusão.*

1. Introdução

Os equipamentos eletromédicos intravenosos têm a função de administrar o escoamento de substâncias diretamente na corrente sanguínea do paciente. A medicação intravenosa é essencial para o tratamento de pacientes no âmbito hospitalar. Contudo, prover esse tratamento é algo complexo e erros de administração do medicamento são comuns [Blandford et al. 2016]. Esses fatores são preocupantes pois terapias intravenosas inapropriadas são uma causa importante de mortalidade [Bhavaasar et al. 2016].

As bombas de infusão, por sua vez, estão entre os equipamentos eletromédicos mais utilizados em hospitais. Esse tipo de equipamento tem a função de regular a vazão dos fluidos entregues pela via intravenosa. Uma bomba de infusão é capaz de monitorar e controlar o escoamento em pressões geradas pelo próprio equipamento e superiores à pressão sanguínea humana [Canelas et al. 2003]. Dessa forma, o dispositivo consegue realizar o escoamento desejado do volume da medicação, ao longo de um tempo determinado, ou seja, garantir que a taxa de infusão seja atingida.

Os equipamentos eletromédicos possuem alarmes que indicam uma situação potencialmente anormal. Quando uma bomba de infusão se encontra em uma situação que comprometa sua capacidade de manutenção da vazão, um alerta deve ser gerado. Porém, se o gerenciamento autônomo de alertas falhar ou possuir pouca precisão, muitos alarmes falsos positivos podem ser emitidos. Esses alarmes desnecessários podem estressar a equipe profissional, que pode, inclusive, acabar silenciando o equipamento.

A aprendizagem Bayesiana é um tipo de aprendizagem de máquina supervisionada. Esse tipo de abordagem utiliza-se do sub-problema de criar hipóteses baseadas nos dados, para que assim, resolva o principal problema: realizar previsões. Esse método é comumente utilizado para classificações que consideram incertezas, visto que utilizam modelos baseados em probabilidades condicionais.

Tendo a motivação de que as bombas de infusão estão entre os equipamentos eletromédicos que possuem maior índice de falsos alertas [ECRI 2017], esse trabalho tem o objetivo central de explorar alternativas para qualificação da emissão destes alertas. Dessa forma, objetiva também revisar os principais erros nas bombas de infusão e explorar a Aprendizagem Bayesiana para qualificação nos alertas desse tipo de equipamento.

2. Trabalhos Relacionados

Ao ser feita uma revisão de literatura foram identificados trabalhos que, semelhantemente, se preocupam com a confiabilidade operacional de equipamentos eletromédicos. O principal trabalho relacionado é denominado *Intravenous Electromedical Equipment: A Proposal to Improve Accuracy in Generating Alerts* [Ferreira et al. 2018], onde é apresentada uma proposta que explora Redes Bayesianas para minimizar a ocorrência de falsos alertas de oclusão nas bombas de infusão.

Nesse trabalho foram realizados ensaios para simular a operação de uma bomba de infusão em diferentes situações. Com os dados obtidos por um sensor não invasivo nesses ensaios, foi gerado um conjunto de dados para treinamento e testes. Os testes foram realizados para encontrar o intervalo de tempo de cálculo da taxa de pressão no equipo e o conjunto de probabilidades que obtivessem melhor acurácia em um modelo de Rede Bayesiana. Os resultados dos testes demonstraram que as Redes Bayesianas são uma abordagem com potencial para redução da incidência de falsos alertas positivos e negativos em bombas de infusão.

Este trabalho possui a utilização de uma biblioteca Python conhecida e um classificador Gaussiano como as principais diferenças em relação ao trabalho relacionado.

3. Trabalho Desenvolvido

O desenvolvimento deste trabalho foi baseado nos resultados obtidos em [Ferreira et al. 2018], extraindo desse trabalho: o melhor intervalo de tempo para cálculo da taxa de acréscimo da pressão, o conjunto de probabilidades definidos para cada evento, e também o conjunto de dados dos ensaios com a bomba de infusão.

Os testes tiveram por finalidade classificar a situação de uma bomba de infusão baseada nos dados dos sensores. Sendo as classes possíveis:

1. **Sem Oclusão:** a linha de infusão não está sob pressão que influencie no escoamento do líquido;
2. **Oclusão Parcial:** existe uma pressão constante sobre o tubo do equipo, a qual deve ser vencida pelo escoamento de líquido da bomba de infusão, sem comprometer a taxa de infusão desejada;
3. **Oclusão Total:** ao iniciar a infusão, já é detectada uma obstrução total da via, comprometendo a taxa de infusão;

O conjunto de dados extraídos dos ensaios contam com a medição da pressão por um sensor não-invasivo no equipo. A Taxa de Acréscimo da Pressão (TAP) foi calculada utilizando o valor inicial (V_o) e valor final (V_i) do sensor de pressão para cada intervalo de 3,5min (210s). Sendo:

$$TAP = \frac{V_i - V_o}{210}$$

Tabela 1. Distribuição das probabilidades

Conjunto de Probabilidades						
Hipótese	1	2	3	4	5	6
Probabilidade	30%	50%	60%	80%	90%	99%

Tabela 2. Tempo dos ensaios e divisão dos conjuntos de dados.

Ensaio	Sem oclusão	Oclusão Parcial	Oclusão Total
Tempo Total	30h	30h	19h
Tempo para Treino	18h	18h	13h30min
Tempo para Teste	12h	12h	5h30min

Além da *TAP* foi utilizado um conjunto de distribuição de probabilidades para as análises das hipóteses, abrangendo no total seis. Como mostrado na Tabela 1. Esse conjunto representa a distribuição da probabilidade de oclusão ao longo do tempo. Já a *TAP* determina um valor que representa a mudança da pressão nos intervalos de tempo.

A divisão do conjunto de dados para treinamento e testes foi feita de acordo com o tempo de cada ensaio, como mostrado na Tabela 2. Dessa forma o modelo foi treinado utilizando a *TAP* calculada em todo o tempo de treino dos três ensaios, juntamente com o conjunto de probabilidades estabelecido e, posteriormente, foi testado utilizando a *TAP* de todo tempo de teste concatenada com as probabilidades. Dessa forma o conjunto de dados tanto de treino quanto de teste resultou no formato: "TAP; Probabilidade; Classificação". Sendo a classificação dada pelo próprio tipo do ensaio.

O classificador *Naive Bayes* utilizado foi o classificador *Gaussian Naive Bayes*, disponível na biblioteca de *Machine Learning* ScikitLearn [Pedregosa et al. 2011] na linguagem Python.

4. Resultados Obtidos

Os resultados obtidos nos testes realizados apontaram uma acurácia de 99,09% para a classificação da situação da bomba de infusão como Sem Oclusão, Oclusão Parcial e Oclusão Total. Contudo, a classificação da situação de Oclusão Total, em específico, obteve uma acurácia menor, de 76,04%. Porém apenas uma situação de oclusão total foi classificada como Sem Oclusão, e outras 22 situações foram erroneamente classificadas como Oclusão Parcial (resultado mais próximo da Oclusão Total), como apresentado na matriz de confusão da Tabela 3.

Tabela 3. Matriz de confusão das predições realizadas

	Oclusão Parcial	Sem Oclusão	Oclusão Total
Oclusão Parcial	2248	0	0
Sem Oclusão	2	202	0
Oclusão Total	22	1	73

5. Considerações Finais

A principal contribuição desse trabalho foi analisar o emprego classificador *Gaussian Naive Bayes* de uma biblioteca conhecida para a classificação da situação de uma bomba de infusão. Portanto, servindo como proposta para qualificação da geração de alertas no equipamento eletromédico.

A utilização do método proposto no contexto analisado apresentou acurácias elevadas para as situações consideradas normais no equipamento - oclusão parcial e sem oclusão. Contudo a acurácia na classificação da situação anormal de oclusão total foi menor que a do trabalho relacionado apresentado.

Como trabalhos futuros, pretende-se utilizar um *dataset* com mais dados de situação de oclusão total, com a perspectiva de uma melhora da acurácia. Além disso também se pretende explorar outros classificadores Bayesianos na qualificação do perfil operacional de equipamentos eletromédicos.

Referências

- Bhavaasar, M. K., Nithya, M., Praveena, R., Bhuvaneswari, N., and Kalaiselvi, T. (2016). Automated intravenous fluid monitoring and alerting system. In *2016 IEEE Technological Innovations in ICT for Agriculture and Rural Development (TIAR)*, number Tiar, pages 77–80, Chennai, India. IEEE.
- Blandford, A., Furniss, D., Lyons, I., Chumbley, G., Iacovides, I., Wei, L., Cox, A., Mayer, A., Schnock, K., Bates, D. W., Dykes, P. C., Bell, H., and Franklin, B. D. (2016). Exploring the Current Landscape of Intravenous Infusion Practices and Errors (ECLIPSE): protocol for a mixed-methods observational study. *BMJ Open*, 6(3):e009777.
- Canelas, D. O., Hermeni, A. H., and Cliquet Jr, A. (2003). Metodologia para avaliação de desempenho essencial de bombas de infusão. *Metrologia*.
- ECRI, I. (2017). Top 10 Health Technology Hazards for Top 10 Health Technology Hazards for 2017. Technical report, ECRI Institute Patient Safety Organization, Massachusetts, USA, Massachusetts, USA.
- Ferreira, F. N., João, L., Lopes, J. L. B., Yamin, A. C., and Agostini, L. V. (2018). Intravenous Electromedical Equipment: A Proposal to Improve Accuracy in Generating Alerts. In *XLIV Conferência Latino-americana de Informática*, São Paulo, BR.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.