

# Avaliação do Uso de Aprendizagem de Máquina na Inferência de Perfis de Infusões Intravenosas

Fabício Ferreira, Felipe Gruendemann, Ricardo Araujo, Adenauer Yamin, Luciano Agostini

**Resumo**— Os procedimentos de infusão intravenosa são usuais em hospitais e têm uma alta incidência de eventos adversos. Apesar disto, esses procedimentos ainda têm a sua verificação realizada de forma não automatizada. Considerando esse cenário, este trabalho apresenta uma avaliação da Aprendizagem de Máquina, para inferir perfis de infusões intravenosas. O objetivo é empregar os resultados deste trabalho na concepção de um dispositivo biomédico capaz de acompanhar de forma autônoma a entrega de medicamento realizada. Após a avaliação dos diferentes modelos de Aprendizagem de Máquina, os Regressores apresentaram resultados mais promissores, particularmente o Regressor Perceptron Múltiplas-Camadas.

**Palavras-Chave**— Dispositivos Intravenosos, Modelo de Regressão, Processamento de Sinais Biomédicos.

**Abstract**— Intravenous infusion procedures are the most common in hospitals and have a high incidence of adverse events. Despite this, these procedures still have their verification performed in a non-automated way. In this sense, this paper presents an evaluation of Machine Learning models to infer profiles of intravenous infusions. The objective is to use the results of this work to design a biomedical device capable of autonomously monitoring medication delivery. After evaluating the different Machine Learning models, the Regressors showed more promising results, particularly the Perceptron Multiple-Layer Regressor.

**Keywords**— Intravenous Devices, Regression Models, Biomedical Signal Processing.

## I. INTRODUÇÃO

A administração de medicamentos por dispositivos biomédicos intravenosos é um processo em que as variações no espaço/tempo, das vazões de entrega praticadas, possuem elevado impacto nas concentrações da droga no sistema sanguíneo do paciente.

Considerando a relevância deste procedimento, esse artigo realiza uma comparação do desempenho de modelos de Aprendizagem de Máquina apresentados na literatura da área, com o objetivo de avaliar quais destes modelos são mais adequados para identificar, de forma autônoma, os diferentes perfis de infusões intravenosas de ambos dispositivos de infusões: gravitacionais e por bombas.

O perfil de infusão intravenosa indica a relação entre a quantidade de medicamento entregue pelo tempo transcorrido, caracterizando a taxa de escoamento da infusão praticada.

As análises realizadas consideram que o recipiente com o conteúdo da infusão está conectado a uma célula de carga (baseada em um sensor *Strain Gauge*) e que, assim, de

forma totalmente não invasiva, é possível correlacionar os resultados medidos dos sinais elétricos do sensor célula de carga (em *Volts*) com o volume do reservatório (em *mL*). Coletando esses sinais elétricos no tempo, formato de séries temporais, tem-se os perfis de infusões.

Naturalmente esse sinal elétrico do dispositivo biomédico, advindo da célula de carga, deve ser amostrado no tempo para ser considerado nas avaliações. A taxa de amostragem considerada neste trabalho é de uma amostra por segundo. Uma vez que as infusões podem ter horas de duração, a amostragem de 1 *Hz* praticada se mostra significativa. Por conta do volume dos sinais elétricos considerados, as abordagens com base em Aprendizado de Máquina se apresentam promissoras para inferir, a partir dos sinais do sensor célula de carga, o perfil de infusão.

O conjunto de dados explorado neste trabalho foi gerado por um simulador de perfis de infusão desenvolvidos em trabalhos anteriores dos autores, denominado *SPODi Infusion Profiler* [1]. O emprego do *SPODi Infusion Profiler* permite simular rapidamente diferentes condições operacionais dos procedimentos de infusão, sem a necessidade dos tempos de espera típicos de medições das infusões reais, que podem implicar em muitas horas para sua efetivação.

O *SPODi Infusion Profiler*, está disponível de forma pública [2], tendo sido modelado com o uso de 38 horas e 42 minutos de medições reais e validado em comparação com 22 medições que considerou um intervalo de confiança de 95 % quando da aplicação do teste estatístico *t Student* [1].

Foram identificados trabalhos na literatura que exploram o uso de Aprendizagem de Máquina no gerenciamento da administração de medicamentos por via intravenosa. Dentre estes trabalhos, destacaríamos dois, considerando sua proximidade com o foco de pesquisa contemplado neste artigo. O trabalho apresentado em [3] faz o uso de Aprendizado Profundo, explorando Redes de Memória de Curta e Longo Prazo, para o controle da concentração do índice Bispectral durante a anestesia intravenosa com infusão de Propofol e Remifentanil. O trabalho [4], por sua vez, faz uso do algoritmo de Máquina de Vetores de Suporte para prever alterações nas infusões das soluções salinas, explorando a contagem de gotas.

Mesmo próximos quanto ao tema de pesquisa, estes trabalhos contemplam informações oriundas de outras fontes, e não tem a perspectiva de avaliar quais métodos se mostram mais oportunos para o cenário da infusão intravenosa.

## II. MODELAGEM POR APRENDIZAGEM DE MÁQUINA

O Aprendizado de Máquina tem apresentado resultados promissores em diversos setores de aplicação, particularmente

nos problemas que envolvem volumes de dados significativos.

Neste trabalho, os atributos que compõem os dados dos dispositivos intravenosos a serem inferidos possuem rótulos que os identificam: (i) o volume de medicamento entregue; (ii) a velocidade da taxa de escoamento; (iii) o tipo de dispositivo médico; e (iv) a informação temporal da coleta.

#### A. Algoritmos de Aprendizado de Máquina Avaliados

Os dados dos dispositivos biomédicos intravenosos são numéricos e rotulados, assim, os Regressos são os modelos de Aprendizagem de Máquina entendidos como oportunos para uso com os sinais elétricos dos dispositivos biomédicos intravenosos, empregando o método supervisionado [5].

A seguir, são apresentados os seis regressores considerados neste trabalho. Estes modelos são indicados pela literatura como um possível potencial para tratar os experimentos semelhantes aos dados de séries temporais que caracteriza os perfis dos dispositivos biomédicos intravenosos [6], [5], [7], [8].

**Regressão Linear:** este o método considera um modelo linear que é ajustado pelos coeficientes de modo a minimizar a soma quadrática dos resíduos entre os alvos observados no conjunto de dados e os alvos previstos pela aproximação linear [6].

**Regressão Bayesiana:** este método de regressão pode ser usado para incluir parâmetros de regularização no procedimento de estimativa, onde cada parâmetro de regularização é definido de forma sintonizada com os dados disponíveis [5].

**Regressão por Vetores de Suporte:** este método usa apenas um subconjunto dos dados de treinamento, porque a função de custo para a construção do modelo ignora todos os dados de treinamento próximos à previsão do modelo, fornecendo mais flexibilidade na escolha de funções e também com penalidades maiores, sendo mais eficiente quando um grande número de amostras é considerado [6], [9].

**AdaBoost:** este método é baseado em uma árvore de decisão, que é um método de aprendizado supervisionado não paramétrico usado para classificação e regressão. O objetivo é criar um modelo que prediga o valor de uma variável de destino, aprendendo regras simples de decisão inferidas a partir dos recursos de dados [6].

**Perceptron Múltiplas-Camadas:** este método consiste de uma rede neural com uma ou mais camadas ocultas com um número indeterminado de neurônios. A rede é treinada iterativamente, pois a cada etapa as derivadas parciais da função de perda com relação aos parâmetros do modelo são calculadas para atualizar os parâmetros, sendo capaz de expressar inferências não-lineares [6], [8].

**Redes Neurais Recorrentes:** este método considera um modelo de aprendizado profundo (*Deep Learning*). Esse tipo de modelo foi desenvolvido para explorar dados que possuem dependências seriais e esse modelo tem potencial de obter bons resultados quando existe algum tipo de relação na sequência em que os dados se apresentam [5], [10].

#### B. Sinais Elétricos Explorados

Os sinais elétricos oriundos da célula de carga que registra as variações no peso do reservatório, constituem os dados

dos perfis das entregas de medicamento. Estes dados foram obtidos pelo uso do simulador SPODi *Infusion Profiler*, que foi configurado para gerar escoamentos com volumes de 125, 250, 500 e 1000 mL, para os dois dispositivos de infusão considerados neste trabalho: infusões gravitacionais e bombas de infusão.

Foram simulados perfis de infusão com intervalo de separação da velocidade do escoamento em 1 mL/h para o volume de 125 mL, e um escoamento de 2 mL/h para os volumes de 250 e 500 mL e um escoamento de 5 mL/h para o volume de 1000 mL.

No total, foram simuladas 4.966 horas de infusões, tendo sido gerados 2.420 tipos de infusões com velocidades de escoamento diferentes. Na Tabela I são especificadas as quantidades de infusões que compõem o conjunto de dados, organizados pelo volume do reservatório de medicamento.

TABELA I  
INFORMAÇÕES DO CONJUNTO DE DADOS DAS INFUSÕES

Volume do Reservatório	Números de Infusões		Duração Total das Infusões
	Gravitacional	Bombas	
125 mL	374	374	1.116 Horas
250 mL	138	138	350 Horas
500 mL	322	322	1.303 Horas
1000 mL	376	376	2.197 Horas

A Tabela II, apresenta uma visão parcial das informações dos Atributos (*Features*) e Alvos (*Targets*), dos dados, para os modelos de regressão, considerando para cada tipo de dispositivo de infusão. Os Atributos são registros do sensoriamento de sinais elétricos que representam o comportamento do perfil da infusão para uma sequência de janelas temporais de 60 segundos na obtenção do modelo de regressão.

Os rótulos das colunas do Atributos são, o  $t_0$ , que indica o início da janela temporal, e o  $t_{59}$  que indica o seu fim. Os demais rótulos ( $t_1$  a  $t_{58}$ ) foram omitidos para simplificar a apresentação. É importante observar que estes dados estão representados em *Volts*, pois os dados gerados pelo SPODi *Infusion Profiler* são relativos ao sensor de célula de carga, como já explicado. O Alvo na Tabela II é representada pela coluna *Taxa*, que corresponde à velocidade do perfil de escoamento da infusão em mL/h, para os diferentes registros dos Atributos.

Também na Tabela II, é apresentada uma coluna “Especificação”, que informa o volume do medicamento com a caracterização das quantidades nominais e o que foi realmente entregue. Essas diferenças entre os volumes de medicamentos são típicas dos dispositivos intravenosos [11]. A coluna “Especificação” não foi considerada como um Atributo para a construção da modelagem.

A Figura 1 apresenta a visualização gráfica dos perfis de infusão de ambos dispositivos intravenosos, gerados pelo SPODi *Infusion Profiler*. Os perfis de infusão apresentados possuem uma taxa de escoamento de 22 mL/h, com uma entrega total de 125 mL de medicamento. A infusão teve uma duração aproximada de 5 horas e 50 minutos.

Também na Figura 1 é apresentada uma visão ampliada do perfil de infusão, cujo tamanho da amostra é igual à janela temporal, portanto, com um intervalo de duração igual a 60

TABELA II  
VISÃO PARCIAL DOS ATRIBUTOS E ALVO CONSIDERADOS

Infusão Gravitacional			Bombas de Infusão			Especificação	
Atributos [Volts]		Alvo [mL/h]	Atributos [Volts]		Alvo [mL/h]	Volume [mL]	
$t_0$	$t_{59}$	Taxa	$t_0$	$t_{59}$	Taxa	Entregue	Nominal
0,83451	0,83221	22,0	0,83531	0,83666	22,0	124,6	125,0
0,83157	0,83157	22,0	0,83570	0,83542	22,0	124,6	125,0
0,83140	0,83021	22,0	0,83416	0,83570	22,0	124,6	125,0

segundos. Assim é possível perceber as variações nos sinais elétricos simulados do sensor célula de carga.

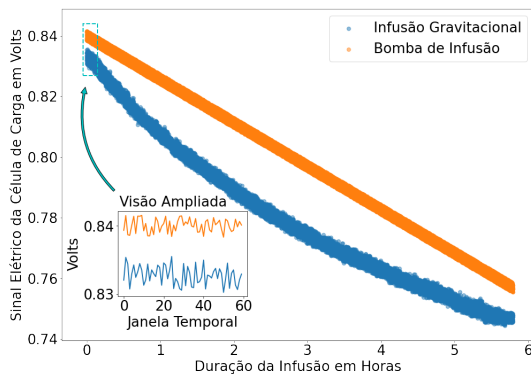


Fig. 1. Perfis de Infusão (Taxa: 22 mL/h e Volume Entregue: 125 mL)

Na Figura 1 o eixo Y corresponde ao sinal elétrico em *Volts* produzido pela célula de carga conectado ao reservatório de medicamento, enquanto que o eixo X indica o avanço do tempo, em horas de infusão. No detalhe da Figura 1, Visão Ampliada da janela temporal, a unidade de tempo no eixo X está em segundos.

### III. CENÁRIO DE AVALIAÇÃO

Na implementação dos Regressores foram utilizadas ferramentas para Aprendizagem de Máquina, das bibliotecas Scikit-Learn, Keras e Pytorch [5], [7], [8], [12]. A escolha destas ferramentas foi motivada por: (i) serem amplamente utilizadas em pesquisas acadêmicas; (ii) possuírem a implementação dos métodos explorados; e (iii) serem *open-source*.

Os dados com os perfis das infusões intravenosas foram organizados em três partes para a construção da modelagem, sendo elas: Treinamento, Validação e Teste.

A fase de Aprendizagem incluiu as fases de Treinamento e de Validação dos seis Regressores, totalizando 4.616 horas de infusão de três diferentes volumes: 125, 500 e 1000 mL para cada Regressor. A fase de Teste considerou um total de 350 horas de infusão por Regressor, entretanto para um volume de 250 mL. É importante ressaltar que os dados da fase de Teste em nenhum momento foram utilizados na fase de Aprendizagem e a separação por volume teve o objetivo de garantir o não cruzamento de perfis para um mesmo volume, evitando, assim um sobre-ajuste (*Overfitting*) [5].

A Tabela III apresenta o detalhamento das quantidades dos perfis de infusão explorados em cada Regressor na fase de Aprendizagem, com diferentes velocidades de escoamento, organizadas por volume de medicamento e a distribuição dos

dados entre Treinamento e Validação. Os dados da fase de Teste contêm 528 ensaios de perfis de infusões diferentes para cada Regressor, para o volume de 250 mL. As quantidades apresentadas para as fases de Aprendizagem e Teste, refletem a soma dos ensaios de ambos os dispositivos médicos de infusão intravenosa.

TABELA III  
ORGANIZAÇÃO DOS ENSAIOS DE INFUSÃO NA FASE DE APRENDIZADO

Volume do Reservatório	Quantidade de Ensaios de Infusão	
	Treinamento	Validação
125 mL	600	148
500 mL	516	128
1000 mL	602	150

Para avaliar o comportamento do aprendizado de cada Regressor, foi utilizada a técnica de Validação Cruzada (do Inglês *Cross Validation* (CV)). Esta técnica permite avaliar as métricas com uma variação aleatória entre os conjuntos de dados participantes das etapas de Treinamento e Validação. A variação foi ajustada para 10 sorteios ( $CV = 10$ ), pois normalmente esse é o valor do fator da validação cruzada explorado na literatura [7].

Neste sentido, quanto menor for as flutuações das médias da métrica de avaliação, no momento da exploração da CV, maior será o potencial de generalidade do modelo concebido.

Após a fase de Aprendizagem e após terem sido obtidos os resultados das médias e de desvio padrão da métrica usada na CV, os regressores foram novamente treinados, considerando o agrupamento dos dados das etapas Treinamento e Validação. Os modelos do novo treinamento dos regressores, foram avaliados com os dados de Teste, que foram utilizados somente nesta etapa.

### IV. RESULTADOS DAS AVALIAÇÕES DOS REGRESSORES

Foram avaliados os seis modelos discutidos na Seção II-A. Particularmente, para os modelos de aprendizado por redes neurais recorrentes, foram usados 25 neurônios e três camadas ocultas. Todos os demais parâmetros usados nos modelos dos regressores são os recomendados pelas bibliotecas Scikit-Learn, Keras e Pytorch. Essa decisão foi tomada com o objetivo de identificar, a priori, quais são os regressores com maior potencial de uso na identificação de perfis de infusão.

Em trabalhos futuros, serão exploradas técnicas de otimização por buscas de melhores métricas nos regressores selecionados com o objetivo de ampliar a precisão dos resultados gerados.

A métrica adotada nesta avaliação dos seis regressores foi a Média do Erro Absoluto (do Inglês *Mean Absolute*

*Error (MAE)*) [7], que é amplamente usada em empregos modelagens por regressores [6]. A MAE foi calculada entre os resultados gerados pelos regressores e os resultados originais gerados pelo SPODi *Infusion Profiler* e, quanto menor o valor da MAE, mais preciso é o resultado encontrado.

Na Tabela IV são apresentados os resultados das avaliações da Validação Cruzada na fase de Aprendizado (Treinamento e Validação), organizadas considerando os volumes de medicamento entregue. Nesta Tabela são apresentados os resultados de média (M) e de desvio padrão (DP) para os resultados de MAE encontrados para os diferentes perfis comparados para cada volume de medicamento e para cada Regressor. Os regressores estão representados por siglas: Regressão Linear (RL), Regressão Bayesiana (RB), Regressão por Vetores de Suporte (RVS), AdaBoost (AB), Perceptron Múltiplas-Camadas (PMC) e Redes Neurais Recorrentes (RNR).

Considerando os ensaios da fase de Aprendizado, é possível observar que os regressores com os melhores resultados são o AdaBoost, para infusões gravitacionais e o Perceptron Múltiplas-Camadas, para bombas de infusão.

Além disso, observando os resultados na Tabela IV, é possível perceber que o desvio padrão cresce com o crescimento do volume infundido quando ocorrem infusões gravitacionais, mas esse comportamento não se repete para as infusões com bombas. Isso é esperado, já que as bombas de infusão existem exatamente para garantir uma precisão mais elevada na entrega do medicamento pelo tempo. Também é possível perceber na Tabela IV o menor desempenho das redes neurais recorrentes, considerando a configuração proposta, uma vez que este método atingiu os piores resultados quanto a métrica MAE entre todos os modelos investigados. A regressão por vetores de suporte também foi um destaque negativo, ficando sempre com o segundo pior resultado entre todos os modelos investigados.

Na Tabela V são apresentados os resultados da métrica MAE obtidos na fase de Teste, usando o volume de 250 mL. Estes resultados indicam o comportamento do desempenho dos regressores dos métodos propostos, já que o conjunto de perfis de teste não foi usado na construção dos modelos na fase de Aprendizado. Novamente, os regressores estão representados por suas siglas, do mesmo modo que na Tabela IV.

As avaliações realizadas na fase de Teste indicam que os regressores com os melhores resultados na inferência dos perfis de infusão, foram, Regressão Linear, Regressão Bayesiana e Perceptron Múltiplas-Camadas, para ambos dispositivos de infusão. Para infusão gravitacional, a Regressão Linear e a Regressão Bayesiana ficaram empatadas em primeiro lugar, com Perceptron Múltiplas-Camadas com resultado muito próximo. Para bombas de infusão, o Perceptron Múltiplas-Camadas ficou em primeiro lugar com larga vantagem sobre os demais.

Outra conclusão importante quando observados os dados da Tabela V é que todos os modelos avaliados tiveram um desempenho muito superior quando aplicados às infusões com bombas de infusão do que quando aplicados a infusões gravitacionais.

Considerando o conjunto de dados avaliados na fase de Teste, a regressão com o Perceptron Múltiplas-Camadas ap-

resenta o maior potencial para inferir com precisão perfis de infusão tanto de bombas de infusão quanto de infusões gravitacionais. Então se apenas um regressor for usado para modelar os perfis de infusão com os dois tipos de dispositivos, certamente o Perceptron Múltiplas-Camadas deve ser usado.

Nas Figuras 2 e 3 são apresentados os resultados visuais sobre as inferências geradas pelo regressor Perceptron Múltiplas-Camadas, considerando os dados de teste. Na Figura 2, as partes (a) e (b), comparam as taxas de escoamento das infusões simuladas com relação às inferidas. Por sua vez, Na Figura 3, as partes (a) e (b), apresentam os gráficos de dispersão das taxas de escoamentos das infusões simuladas e inferidas. Nos gráficos das partes (a) e (b) da Figura 2 o eixo Y apresenta a velocidade da taxa de escoamento e o eixo X apresenta a quantidade de perfis de infusão avaliados para ambos os dispositivos intravenosos. As partes (a) e (b) da Figura 3 apresentam, no eixo Y, o valor da taxa de infusão simulada e, no eixo X, o valor da taxa de infusão inferida pelo regressor.

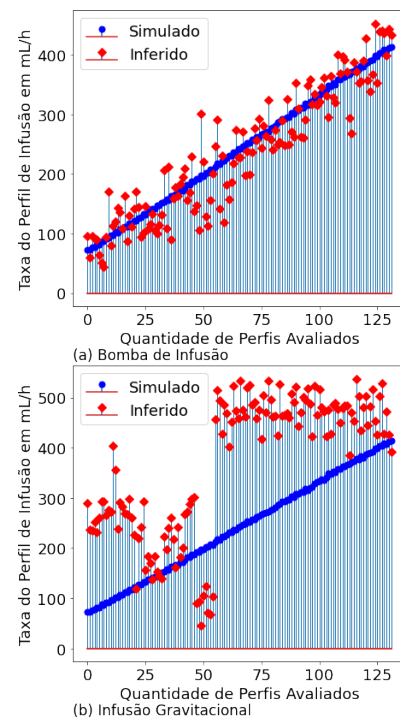


Fig. 2. Comparações das Inferências Gerada pelo Regressor PMC.

As Figuras 2 e 3 confirmam os resultados apresentados na Tabela V, indicando que o regressor PMC atingiu bons resultados ao modelar o comportamento das bombas de infusão. Por outro lado, a modelagem de infusões gravitacionais com o regressor PMC alcançou um resultado pior. Isso ocorre devido ao regime de fluidos líquidos, que caracteriza o comportamento do perfil de administração de drogas por infusões gravitacionais. As infusões gravitacionais têm um fluxo semelhante aos modelos de funções polinomiais [13], dificultando uma modelagem mais precisa.

## V. CONCLUSÕES

A avaliação realizada neste trabalho considerou dados de perfis de entrega de medicamentos intravenosos de ambos

TABELA IV  
 AVALIAÇÃO DOS REGRESSORES NA FASE DE APRENDIZADO

	MAE [mL/h] - Infusão Gravitacional						MAE [mL/h] - Bombas de Infusão					
	125 mL		500 mL		1000 mL		125 mL		500 mL		1000 mL	
	M	DP	M	DP	M	DP	M	DP	M	DP	M	DP
RL	30,5	0,6	76,9	3,3	96,0	5,1	22,1	0,5	31,2	0,2	34,7	0,3
RB	30,5	0,6	76,9	3,3	96,0	5,1	22,1	0,5	31,2	0,2	34,7	0,3
RVS	38,7	2,4	160,7	15,8	208,6	18,6	36,3	3,5	180,4	24,3	189,7	15,2
AB	11,3	0,8	56,3	3,9	63,7	5,5	25,9	1,7	47,9	3,7	55,5	2,3
PMC	28,9	0,7	71,5	3,8	91,4	4,5	20,3	0,7	29,2	1,4	32,5	1,6
RNR	42,0	1,6	182,5	27,7	241,2	25,8	43,2	4,4	202,5	31,8	243,7	23,3

TABELA V  
 AVALIAÇÃO DOS REGRESSORES NA FASE TESTE

	MAE [mL/h]	
	Infusão Gravitacional	Bombas de Infusão
RL	60,6	28,0
RB	60,6	28,0
RVS	99,0	83,7
AB	73,8	39,4
PMC	60,8	27,0
RNR	98,8	98,0

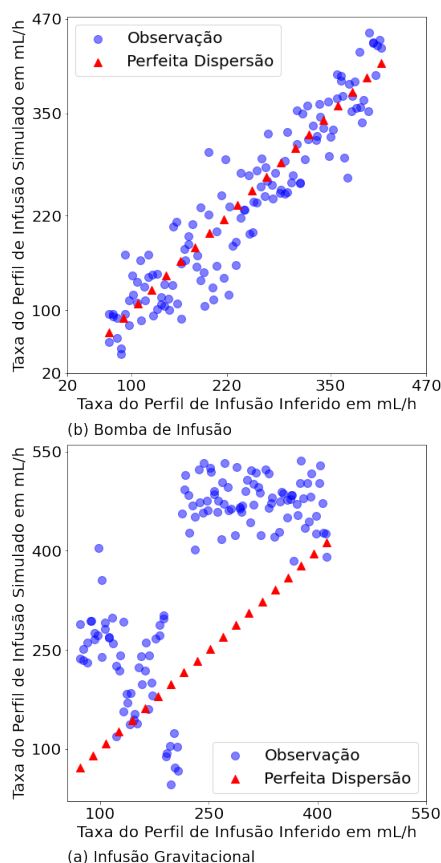


Fig. 3. Dispersões das Inferências Gerada pelo Regressor PMC.

dispositivos biomédicos mais utilizados em hospitais: gravitacionais e bombas de infusão. Dentre os diversos modelos de Aprendizagem de Máquina, os resultados indicaram que o Regressor Perceptron Múltiplas-Camadas foi o aquele que apresentou a melhor métrica MAE, quando da inferência dos perfis de infusão praticados. Os dados empregados constituem

valores que simulam o comportamento de uma célula de carga, a qual produz sinais elétricos correspondes a flutuação do peso do líquido sendo infundido.

A partir deste resultado, destaca-se como trabalho futuro, um esforço de pesquisa para otimização da arquitetura da Rede Neural Artificial empregada no Regressor PMC e dos seus hiper-parâmetros, com a finalidade de atingir resultados ainda mais interessantes.

Com a otimização do regressor a ser utilizado, se torna viável a concepção de um dispositivo biomédico que possa realizar um efetivo acompanhamento autônomo dos processos da entrega de medicamentos intravenosos, o qual constitui o objetivo final deste esforço de pesquisa em desenvolvimento.

## REFERÊNCIAS

- [1] F. Ferreira, J. Barbosa, F. Gruendemann, R. Machado, A. Yamin, and L. Agostini, "Spodi: Simulador do perfil operacional de dispositivos intravenosos para auxílio à tomada de decisões médicas," in *Anais do XIX Simpósio Brasileiro de Computação Aplicada à Saúde*. Porto Alegre, RS, Brasil: SBC, 2019, pp. 34–45.
- [2] F. Ferreira, "Infusion profiler," <https://wp.ufpel.edu.br/IDDOP>, 10 2019.
- [3] H.-C. Lee, H.-G. Ryu, E.-J. Chung, and C.-W. Jung, "Prediction of Bispectral Index during Target-controlled Infusion of Propofol and Remifentanyl," *Anesthesiology*, vol. 128, no. 3, pp. 492–501, mar 2018.
- [4] K. Dinesh *et al.*, "A Novel System Design for Intravenous Infusion System Monitoring for Betterment of Health Monitoring System using ML- AI," *International Journal of Innovative Technology and Exploring Engineering*, vol. 9, no. 3, pp. 2649–2655, jan 2020.
- [5] J. Hao and T. K. Ho, "Machine Learning Made Easy: A Review of Scikit-learn Package in Python Programming Language," *Journal of Educational and Behavioral Statistics*, vol. 44, no. 3, pp. 348–361, jun 2019.
- [6] Y. Ren, L. Zhang, and P. N. Suganthan, "Ensemble Classification and Regression— Recent Developments, Applications and Future Directions," no. February, pp. 41–53, 2016.
- [7] F. Pedregosa *et al.*, "Scikit-learn: Machine learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [8] F. Chollet *et al.*, "Keras," <https://keras.io>, 2015.
- [9] A. Ferreira, V. Vieira, and B. Macchiavello, "Detecção Automática de Arcus Senilis no Olho Humano," in *Anais de XXXVI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*. Campina Grande, PB: Sociedade Brasileira de Telecomunicações, 2018, pp. 1–2.
- [10] M. Fonseca, E. Souza, A. Conceição, and E. Filho, "Classificador de Gestos por Redes Neurais Artificiais utilizando Sinais Mielétricos," in *Anais de XXXVI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*. Campina Grande, PB: Sociedade Brasileira de Telecomunicações, 2018, pp. 16–19.
- [11] D. J. Chambers, "Principles of intravenous drug infusion," *Anaesthesia & Intensive Care Medicine*, vol. 20, no. 1, pp. 61–64, jan 2019.
- [12] A. Paszke *et al.*, "Pytorch: An imperative style, high-performance deep learning library," in *Advances in Neural Information Processing Systems 32*. Curran Associates, Inc., 2019, pp. 8024–8035.
- [13] M. A. Lovich and R. A. Peterfreund, "Drug Flow Through Clinical Infusion Systems: How Modeling of the Common-volume Helps Explain Clinical Events," *Pharmaceutical Technology in Hospital Pharmacy*, vol. 2, no. 2, pp. 49–62, aug 2017.