

Inteligência artificial para predição do tempo de banho no leito em Unidades de Terapia Intensiva

Artificial intelligence to predict bed bath time in Intensive Care Units

Inteligencia artificial para predecir la hora del baño en cama en Unidades de Cuidados Intensivos

Luana Vieira Toledo^I

ORCID: 0000-0001-9527-7325

Leonardo Lopes Bhering^I

ORCID: 0000-0002-6072-0996

Flávia Falci Ercole^{II}

ORCID: 0000-0002-1356-0854

^IUniversidade Federal de Viçosa. Viçosa, Minas Gerais, Brasil.

^{II}Universidade Federal de Minas Gerais. Belo Horizonte, Minas Gerais, Brasil.

Como citar este artigo:

Toledo LV, Bhering LL, Ercole FF. Artificial intelligence to predict bed bath time in Intensive Care Units.

Rev Bras Enferm. 2024;77(1):e20230201.

<https://doi.org/10.1590/0034-7167-2023-0201pt>

Autor Correspondente:

Luana Vieira Toledo

E-mail: luana.toledo@ufv.br



EDITOR CHEFE: Dulce Barbosa
EDITOR ASSOCIADO: Mitzy Danski

Submissão: 04-07-2023

Aprovação: 18-10-2023

RESUMO

Objetivos: avaliar a *performance* preditiva de diferentes algoritmos de inteligência artificial para estimar o tempo de execução do banho no leito em pacientes críticos. **Métodos:** estudo metodológico, que utilizou algoritmos de inteligência artificial para prever o tempo de banho no leito em pacientes críticos. Foram analisados os resultados dos modelos de regressão múltipla, redes neurais *perceptron* multicamadas e função de base radial, árvore de decisão e *random forest*. **Resultados:** entre os modelos avaliados, o modelo de rede neural com função de base radial, contendo 13 neurônios na camada oculta, apresentou melhor *performance* preditiva para estimar o tempo de execução do banho no leito. Na validação dos dados, o quadrado da correlação entre os valores preditos e os valores originais foi de 62,3%. **Conclusões:** o modelo de rede neural com função de base radial apresentou melhor *performance* preditiva para estimar o tempo de execução do banho no leito em pacientes críticos.

Descritores: Enfermagem; Banhos; Inteligência Artificial; Redes Neurais de Computação; Unidades de Terapia Intensiva.

ABSTRACT

Objectives: to assess the predictive performance of different artificial intelligence algorithms to estimate bed bath execution time in critically ill patients. **Methods:** a methodological study, which used artificial intelligence algorithms to predict bed bath time in critically ill patients. The results of multiple regression models, multilayer perceptron neural networks and radial basis function, decision tree and random forest were analyzed. **Results:** among the models assessed, the neural network model with a radial basis function, containing 13 neurons in the hidden layer, presented the best predictive performance to estimate the bed bath execution time. In data validation, the squared correlation between the predicted values and the original values was 62.3%. **Conclusions:** the neural network model with radial basis function showed better predictive performance to estimate bed bath execution time in critically ill patients.

Descriptors: Nursing; Baths; Artificial Intelligence; Neural Networks, Computer; Intensive Care Units.

RESUMEN

Objetivos: evaluar el rendimiento predictivo de diferentes algoritmos de inteligencia artificial para estimar el tiempo de ejecución del baño en cama en pacientes críticos. **Métodos:** estudio metodológico, que utilizó algoritmos de inteligencia artificial para predecir el tiempo de baño en cama en pacientes críticos. Se analizaron los resultados de modelos de regresión múltiple, redes neuronales *perceptrón* multicapa y función de base radial, árbol de decisión y *random forest*. **Resultados:** entre los modelos evaluados, el modelo de red neuronal con función de base radial, que contiene 13 neuronas en la capa oculta, presentó el mejor desempeño predictivo para estimar el tiempo de ejecución del baño en cama. En la validación de datos, la correlación al cuadrado entre los valores predichos y los valores originales fue del 62,3%. **Conclusiones:** el modelo de red neuronal con función de base radial mostró mejor rendimiento predictivo para estimar el tiempo de ejecución del baño en cama en pacientes críticos.

Descriptorios: Enfermería; Baños; Inteligencia Artificial; Redes Neuronales de la Computación; Unidades de Cuidados Intensivos.

INTRODUÇÃO

A inteligência artificial (IA) é um ramo da ciência da computação aliado à ciência cognitiva, em que se desenvolvem sistemas computacionais para a realização de tarefas que exigiriam a inteligência humana. Para tal, são utilizadas diferentes técnicas e modelos, destacando-se o *machine learning*⁽¹⁾.

A utilização das ferramentas de IA tem sido potencializada pela necessidade de obter melhores resultados para os pacientes com custos mais baixos a partir de maior número de dados⁽²⁻³⁾. Métodos de predição baseados em regressões logísticas ou lineares múltiplas têm sido empregados em diferentes pesquisas, no entanto os modelos de *machine learning* oferecem a possibilidade adicional de melhorar a previsão com base na detecção de padrões de muitas variáveis simultaneamente⁽⁴⁾. Acredita-se que, com os avanços da evolução técnico científica, a IA transformará fundamentalmente a assistência em saúde e em enfermagem.

Para a enfermagem, as ferramentas da IA oferecem uma grande promessa para a otimização da assistência, ao passo que possibilitam que a tomada de decisões e a realização de intervenções de enfermagem sejam guiadas pelo uso aplicável de dados, informações e conhecimento, proporcionando maior assertividade⁽⁵⁾. Resultados promissores têm sido obtidos na predição de lesões por pressão⁽⁶⁾ e de readmissões precoces em Unidade de Terapia Intensiva (UTI)⁽⁷⁾.

Além disso, observa-se um importante papel da IA para a gestão de materiais e recursos humanos para a assistência aos pacientes⁽⁴⁾. Essa aplicabilidade pode ser útil para o dimensionamento de pessoal de enfermagem, sobretudo em unidades de alta demanda de cuidados, como as UTIs, onde a sobrecarga de trabalho é uma queixa frequentemente relatada pela equipe e pode causar maior absenteísmo⁽⁸⁾.

Considerando as atividades desempenhadas pela equipe de enfermagem nas UTIs, evidencia-se que o banho no leito é uma das intervenções realizadas rotineiramente que exige dos profissionais conhecimento científico e habilidade técnica⁽⁹⁾. Não está isento de riscos⁽¹⁰⁾, e apresenta expressiva influência na carga de trabalho da equipe de enfermagem⁽⁸⁾. Estudos evidenciam que o banho no leito pode ser influenciado por características individuais, sobretudo em relação à utilização de dispositivos invasivos, bem como aspectos ligados à infraestrutura e aos recursos humanos e materiais^(8,10-11).

Nesse contexto, tendo em vista que múltiplos banhos podem ser executados por um mesmo profissional durante a sua jornada de trabalho e que o tempo de execução pode variar de acordo com as características dos pacientes, evidencia-se a relevância de estudos que avaliem a temática, sobretudo direcionado à construção de modelos de predição do tempo de execução do banho. Acredita-se que um modelo acurado poderá ser utilizado para a construção de uma ferramenta gerencial útil para instrumentalizar os profissionais de enfermagem no planejamento e execução da assistência, de forma a tornar a divisão do trabalho mais equânime, minimizando os riscos para quem executa e quem recebe. O processo de trabalho nas UTIs poderá ser facilitado a partir da possibilidade de prever antecipadamente quanto tempo será requerido por cada paciente durante o seu banho, considerando a influência de sua condição clínica. Ressalta-se que,

até o momento, não existem estudos utilizando algoritmos de IA para prever o tempo de banho no leito em cuidados críticos, justificando, assim, o caráter inovador deste estudo.

OBJETIVOS

Avaliar a *performance* preditiva de diferentes algoritmos de IA para estimar o tempo de execução do banho no leito em pacientes críticos.

MÉTODOS

Aspectos éticos

O estudo foi conduzido de acordo com as diretrizes de ética nacionais e internacionais referente à pesquisa com seres humanos, sendo aprovado pelo Comitê de Ética em Pesquisa da instituição proponente.

O Termo de Consentimento Livre e Esclarecido foi obtido de todos os familiares dos pacientes críticos envolvidos no estudo por meio da assinatura no momento da admissão da UTI.

Desenho, período e local de estudo

Trata-se de estudo metodológico que utilizou algoritmos de IA para prever o tempo de execução do banho no leito em pacientes críticos. A predição do tempo de banho foi realizada a partir das variáveis clínicas coletadas em ensaio clínico randomizado⁽¹²⁾.

Os dados foram analisados pelos algoritmos de IA no período de junho a outubro de 2022. O referido estudo clínico que deu origem ao conjunto de dados foi realizado em uma UTI, que dispõe de seis leitos direcionados ao atendimento de pacientes críticos decorrentes de condições clínicas e cirúrgicas. A equipe assistencial é composta por enfermeiros, médicos, técnicos de enfermagem, fisioterapeutas e nutricionistas.

Amostra; critérios de inclusão e exclusão

Neste estudo, foram utilizadas as informações de todos os 50 pacientes críticos adultos que estiveram internados na UTI e receberam a intervenção de banho no leito durante o estudo clínico.

Protocolo do estudo

No estudo clínico, os pacientes foram admitidos na UTI e receberam o banho no leito pelo método tradicional, utilizando-se bacia com água e sabão. O banho foi realizado por dois enfermeiros de forma ininterrupta, no sentido céfalo-podal, não sendo realizada a higiene bucal. Durante a realização do banho, um terceiro pesquisador avaliou as variáveis sociodemográficas e clínicas dos pacientes, e registrou o tempo de execução do procedimento.

O conjunto de dados utilizado para a análise e construção dos modelos preditivos incluiu o tempo de execução do banho no leito (em minutos), considerado como desfecho, além das variáveis predictoras: idade (em anos); sexo (masculino/feminino); comorbidades (sim/não); uso de drogas vasoativas (sim/não); sedativos (sim/não); oxigenoterapia (sim/não); tubo orotraqueal/traqueostomia (sim/não); cateter venoso central

(sim/não); cateter venoso periférico (não/sim); cateter vesical de demora (sim/não); cateter nasointestinal/nasogástrico (sim/não); dispositivos de monitorização hemodinâmica (sim/não); drenos (sim/não); e ostomias (sim/não). Os dados relacionados ao tempo de execução do banho no leito e às características dos pacientes foram coletados por outro pesquisador que não participou da intervenção.

Análise dos resultados e estatística

Os dados foram analisados no *software* Rbio[®], versão 170⁽¹³⁾. Realizou-se a análise descritiva dos dados, apresentando as frequências absoluta e relativa das variáveis categóricas e média e desvio padrão das variáveis contínuas. Para a predição do tempo de execução do banho no leito, foram avaliados os resultados obtidos pela regressão múltipla, redes neurais *perceptron* multicamadas e função de base radial, árvore de decisão e *random forest*.

Inicialmente, os dados foram divididos em 70% (n = 35), para treinamento dos algoritmos, e 30% (n = 15), para validação da *performance* preditiva dos modelos ajustados (teste), sendo repetido 10 vezes. O quadrado da correlação dos dados preditos e dos dados originais de validação foi sumarizado pelo valor do coeficiente de determinação R². Com exceção da regressão múltipla, para a avaliação dos demais modelos, também foram utilizados os valores de Raiz do Erro Quadrático Médio (RMSE) e Erro Médio Absoluto (MAE).

A RMSE calcula a magnitude da média do erro pela raiz quadrada da média dos quadrados dos erros. Desse modo, atribui um peso maior aos erros de maior magnitude e peso menor aos erros de menor magnitude. É obtido na mesma unidade da variável em análise⁽¹⁴⁾.

O MAE calcula a média das diferenças absolutas entre o valor previsto e o valor real. O MAE não leva em consideração se o erro é para mais ou para menos, e às diferenças absolutas não é atribuído peso⁽¹⁴⁾.

Na regressão múltipla, a função que relaciona os preditores à resposta de interesse está restrita a formas lineares. Nas redes neurais, aplicam-se transformações não lineares às combinações lineares dos preditores, dando origem às unidades latentes⁽¹⁵⁾. As redes têm a capacidade de armazenar conhecimento baseado nos dados utilizados para treinamento e, posteriormente, reproduzi-los conforme o objetivo da análise⁽¹⁶⁾. Neste estudo, foram utilizadas redes neurais do tipo *perceptron* multicamadas com dois tipos de algoritmos de treinamento, tais como *resilient backpropagation* com retrocesso de pesos (*perceptron 1*) e sem retrocesso de pesos (*perceptron 2*). Em ambos os modelos, foi utilizada a função de ativação logística, e foram testadas as possíveis combinações de até duas camadas ocultas com até 20 neurônios cada. A rede neural com função de base radial compreende apenas uma camada oculta, com função de ativação radialmente simétrica (gaussiana). Nesse modelo, foi testada a camada oculta com até 20 neurônios. A árvore de decisão objetiva combina predições de um conjunto de classificadores com taxa de erro ligeiramente inferior à de uma classificação aleatória, gerando uma árvore de decisão com poucas divisões. Neste estudo, a árvore utilizada continha até seis nós. O último método avaliado foi o *random forest*, em que foram amostradas 500 árvores para obtenção dos resultados.

RESULTADOS

A média de idade dos pacientes que receberam o banho no leito e serviram de base para a construção dos algoritmos de IA foi de 68,6 anos (±19,0 anos). Houve predomínio de pacientes do sexo masculino 28 (56,0%) e portadores de comorbidades 42 (84,0%), conforme disposto na Tabela 1.

Tabela 1 - Características dos pacientes críticos que receberam o banho no leito e serviram de base para a construção dos algoritmos de inteligência artificial (N=50)

Variáveis	Parâmetros
Idade m (±dp)	68,6 (±19,0)
Sexo n (%)	
Masculino	28 (56,0)
Feminino	22 (44,0)
Comorbidades n (%)	
Não	8 (16,0)
Sim	42 (84,0)
Medicamentos n (%)	
Sedativos	10 (20,0)
Vasoativos	11 (22,0)
Dispositivos n (%)	
Bomba de infusão contínua	47 (94,0)
Cateter Nasointestinal	19 (38,0)
Cateter Venoso Central	8 (16,0)
Cateter Venoso Periférico	45 (90,0)
Cateter Vesical de Demora	27 (54,0)
Drenos	6 (12,0)
Monitorização hemodinâmica invasiva	4 (8,0)
Oxigenoterapia	28 (56,0)
Ostomias	2 (4,0)
Tubo endotraqueal	12 (24,0)

Durante o estudo clínico, o tempo médio de execução do banho no leito foi de 26,45 minutos (I.C. 95% 25,07 – 27,82). A partir da análise das métricas dos algoritmos de IA, evidenciou-se que o modelo de rede neural com função de base radial contendo 13 neurônios na camada oculta apresentou maior correlação entre os valores preditos e os valores originais (R²= 62,3%; RMSE = 0,7 e MAE =1,9). Ressalta-se que a rede neural *perceptron 1* também pode ser considerada uma opção para a predição do tempo de banho, tendo em vista que apresentou menor RMSE (0,5) e menor MAE (1,4), demonstrando que as previsões traçadas por esse algoritmo estão próximas dos valores reais (Tabela 2).

Tabela 2 - Resultado das análises dos algoritmos de inteligência artificial para predição do tempo de execução do banho no leito

Método	R ² (%)	RMSE	MAE
Regressão múltipla	23,5	-	-
Rede neural <i>perceptron 1</i>	55,3	0,5	1,4
Rede neural <i>perceptron 2</i>	44,5	0,9	2,5
Rede neural com função de base radial	62,3	0,7	1,9
Árvore de decisão	7,4	4,7	4,1
<i>Random forest</i>	20,3	4,0	3,7

R² - Quadrado da correlação dos dados preditos com os dados originais; RMSE- Raiz do Erro Quadrático Médio; MAE - Erro Médio Absoluto.

DISCUSSÃO

O bom desempenho da *performance* preditiva das análises de IA encontradas neste estudo, especialmente da rede neural com função de base radial, pode ser considerado promissor para o avanço técnico-científico na enfermagem. A utilização desses algoritmos permite analisar os dados de forma mais robusta e eficiente do que os métodos estatísticos tradicionais baseados em modelos de regressão, o que possibilita maior assertividade⁽¹⁷⁾. Os algoritmos de IA oferecem a possibilidade adicional de melhorar a previsão dos desfechos com base na detecção de padrões de muitas variáveis simultaneamente⁽⁴⁾.

Na área da saúde, sua utilização pode ser realizada com vistas a melhoria do tratamento e resultados, promoção da eficiência e eficácia dos processos assistenciais, bem como avaliação do padrão de comportamento do paciente⁽²⁾. Na epidemiologia, modelos de redes neurais têm sido utilizados para classificar os municípios com base na vulnerabilidade social com elevada precisão, destacando os que possuem extrema vulnerabilidade daqueles que detêm os melhores indicadores sociais⁽¹⁸⁾. Durante a pandemia de COVID-19, pesquisadores utilizaram os algoritmos de IA para a definição de grupos populacionais prioritários para vacinação a partir do maior risco de morte intra-hospitalar⁽¹⁹⁾. Especificamente na enfermagem, poucos são os estudos sobre a temática, destacando-se a aplicabilidade da IA para avaliação de emoções dos estudantes durante a simulação clínica, a partir das expressões faciais⁽²⁰⁾, e para a detecção de casos de sepse⁽²¹⁾.

Este estudo buscou integrar os conhecimentos oriundos da IA com o conhecimento da enfermagem fundamental, aprofundando-se na análise de predição do tempo de execução de uma importante intervenção rotineira da enfermagem direcionada à promoção de higiene e ao conforto dos pacientes críticos⁽²²⁾, cuja realização impacta tanto os pacientes quanto os profissionais. Para os pacientes, durante o banho no leito, há riscos de infecção, deslocamento de dispositivos, quedas do leito⁽²³⁾, além de alterações oxi-hemodinâmicas^(10,12). Para os profissionais de enfermagem, menos tempo empregado no banho representa menor sobrecarga de trabalho e menos desgaste físico^(8,24).

Compete aos enfermeiros a tomada de decisão sobre quando e como ministrar o banho no leito, além da definição de quais estratégias e recursos foram utilizados, tendo por referência a utilização de protocolos validados⁽²⁵⁾. De acordo com a Lei do Exercício Profissional 7.498/86, os cuidados de enfermagem direcionado aos pacientes críticos são considerados como atividade privativa dos enfermeiros⁽²⁶⁾. Todavia, observa-se que, em grande parte das UTIs brasileiras, o banho no leito é executado pelo técnico de enfermagem, sem qualquer participação do profissional de nível superior⁽⁸⁾. Assim, com base nos resultados deste trabalho e, transcendendo a teoria, é possível analisarmos criticamente o cenário idealizado pela legislação e o cenário real vivenciado. Faz-se necessária uma reflexão sobre o impacto da utilização da predição do tempo de banho no leito dos pacientes para o processo de trabalho da enfermagem, ao passo que, a partir da predição, torna-se possível diferenciar aqueles que requerem maior tempo de assistência daqueles que demandam menos tempo da equipe de enfermagem. A partir desta reflexão, é possível pensar na

diversidade de condições apresentadas pelos pacientes críticos e se, por ventura, os pacientes com menor complexidade podem ter o seu banho delegado de forma regulamentar aos profissionais de nível técnico, mantendo-se a necessidade da supervisão direta de um enfermeiro, o que, muitas vezes, já ocorre na prática.

Ademais, na prática clínica, recomenda-se que o banho no leito seja realizado por mais de um profissional, a fim de promover uma assistência mais segura, com menor esforço e maior agilidade⁽⁸⁾. No entanto, evidencia-se a carência de profissionais, o que reforça a importância de uma ferramenta que subsidie o enfermeiro no gerenciamento de recursos humanos, a partir da previsão do tempo que cada profissional deverá destinar à realização dos banhos de cada paciente, levando-se em consideração as características individuais. Contudo, ressalta-se que, ainda que os modelos apresentem boa *performance* preditiva, eles podem gerar previsões imprecisas. Assim, para maior eficácia, sua utilização não deve ser de conduzida de forma isolada, mas associada ao julgamento clínico realizado pelos profissionais, que poderá se traduzir em melhores cuidados⁽²⁷⁾.

Limitações do estudo

Os resultados desta investigação devem ser interpretados com cautela, pois os dados que deram origem ao modelo foram provenientes de uma única UTI, cujos banhos foram sempre realizados por duas pessoas. Contudo, apesar de ser uma amostra pequena, não apresenta viés de seleção e é representativa da população de pacientes críticos.

Contribuições para a área da enfermagem, saúde, ou políticas públicas

Acredita-se que o modelo construído pela análise de IA com boa capacidade preditiva poderá originar uma ferramenta útil para instrumentalizar os profissionais no planejamento e na execução da assistência de enfermagem durante o banho no leito. A partir da predição do tempo de execução do banho, o enfermeiro poderá distribuir o cuidado de maneira mais equânime entre os membros da equipe, minimizando a sobrecarga de trabalho e os riscos inerentes a essa intervenção. Espera-se que a possibilidade de prever o tempo de banho no leito dos pacientes antes de sua execução possa auxiliar no processo de trabalho da equipe de enfermagem em UTIs, de forma a contribuir para a economia de tempo e melhoria assistencial, direcionando de forma equitativa os pacientes de acordo com a sua demanda assistencial.

CONCLUSÕES

Conclui-se que, entre os métodos analíticos utilizados, o modelo de rede neural com função de base radial apresentou melhor *performance* preditiva para estimar o tempo de execução do banho no leito em pacientes críticos, seguido do modelo de rede neural *perceptron* 1. Assim, evidencia-se que a IA pode ser útil para a construção de uma ferramenta que possa orientar a prática da enfermagem relacionada ao banho no leito, auxiliando a tomada de decisão dos profissionais durante o planejamento e

execução dessa intervenção, com vistas a melhorar o dimensionamento de recursos humanos e otimizar o processo de trabalho.

Universal - APQ-01568-22, e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa de pós-doutorado à LVT - Bolsista (CAPES/BRASIL).

DISPONIBILIDADE DE DADOS E MATERIAL

<https://doi.org/10.48331/scielodata.HLY7DQ>

FOMENTO

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pelo financiamento do projeto no edital da Demanda

CONTRIBUIÇÕES

Toledo LV, Bhering LL e Ercole FF contribuíram com a concepção ou desenho do estudo/pesquisa. Toledo LV, Bhering LL e Ercole FF contribuíram com a análise e/ou interpretação dos dados. Toledo LV, Bhering LL e Ercole FF contribuíram com a revisão final com participação crítica e intelectual no manuscrito.

REFERÊNCIAS

1. Sichman JS. Artificial Intelligence and society: advances and risks. *Estud Av.* 2021;35(101):37-50. <https://doi.org/10.1590/s0103-4014.2021.35101.004>
2. McGrow K. Artificial intelligence: essentials for nursing. *Nurs.* 2019;49(9):46-9. <https://doi.org/10.1097/01.NURSE.0000577716.57052.8d>
3. Buchanan C, Howitt ML, Wilson R, Booth RG, Risling T, Bamford M. Predicted influences of artificial intelligence on nursing education: scoping review. *JMIR Nurs.* 2021;4(1):e23933. <https://doi.org/10.2196/23933>
4. Selya A, Anshutz D, Griese E, Weber TL, Hsu B, Ward C. Predicting unplanned medical visits among patients with diabetes: translation from machine learning to clinical implementation. *BMC Med Inform Decis Mak.* 2021;21(111). <https://doi.org/10.1186/s12911-021-01474-1>
5. Cato KD, McGrow K, Rossetti SC. Transforming clinical data into wisdom: artificial intelligence implications for nurse leaders. *Nurs Manage.* 2020;51(11):24-30. <https://doi.org/10.1097/01.NUMA.0000719396.83518.d6>
6. Jiang M, Ma Y, Guo S, Jin L, Lv L, Han L, et al. Using machine learning technologies in pressure injury management: systematic review. *JMIR Med Inform.* 2021;9(3):e25704. <https://doi.org/10.2196/25704>
7. González-Nóvoa JA, Campanioni S, Busto L, Fariña J, Rodríguez-Andina JJ, Vila D, et al. Improving intensive care unit early readmission prediction using optimized and explainable machine learning. *Int J Environ Res Public Health.* 2023;20(4):3455. <https://doi.org/10.3390/ijerph20043455>
8. Bastos SRB, Gonçalves FAF, Bueno BRM, Silva GS, Riberio KRA, Brasil VV. Bed-Bath: the Care-Omitting Behavior of the Nursing Team. *Rev Pesqui Cuid Fundam.* 2019;11(3):627-33. <https://doi.org/10.9789/2175-5361.2019.v11i3.627-633>
9. Lopes JL, Baptista RCN, Domingues TAM, Ohl RIB, Barros ALBL. Development and validation of a video on bed baths. *Rev Latino-Am Enfermagem.* 2020;28:e3329. <https://doi.org/10.1590/1518-8345.3655.3329>
10. Lima DVM, Lacerda RA. Repercussões oxí-hemodinâmicas do banho no paciente em estado crítico adulto hospitalizado: revisão sistemática. *Acta Paul Enferm.* 2010;23(2):278-85. <https://doi.org/10.1590/S0103-21002010000200020>
11. Toledo LV, Santos BX, Salgado PO, Souza LM, Brinati LM, Januário CF, et al. Changes in body temperature of critically ill patients submitted to bed bathing: a crossover clinical trial. *Rev Bras Enferm.* 2021;74(2). <https://doi.org/10.1590/0034-7167-2020-0969>
12. Toledo LV, Salgado PO, Boscarol GT, Januário CF, Brinati LM, Ercole FF. Oxy-hemodynamic effects of different bed baths: a randomized crossover clinical trial. *Acta Paul Enferm.* 2022;35:eAPE02116. <https://doi.org/10.37689/acta-ape/2022AO021166>
13. Bhering LL. Rbio: a tool for biometric and statistical analysis using The R Platform. *Crop Breed Appl Biotechnol.* 2017;17:187-90. <https://doi.org/10.1590/1984-70332017v17n2s29>
14. Marinho FP, Rocha PAC, Silva MEV, Lima RJP, Araujo Neto JP. Preliminary results of short-term solar irradiation prediction by combining image processing with machine learning algorithms. *Rev Bras Energia Solar [Internet].* 2021[cited 2023 May 20];12(2):105-12. Available from: <https://rbens.org.br/rbens/article/download/357/256>
15. Santos HG, Nascimento CF, Izbicki R, Duarte YAO, Chiavegatto Filho ADP. Machine learning for predictive analyses in health: an example of an application to predict death in the elderly in São Paulo, Brazil. *Cad Saúde Pública.* 2019;35(7):e00050818. <https://doi.org/10.1590/0102-311X00050818>
16. Silva AX, Campello OS, Gonçalves ARF. A proposal of an android application prototype for nursing diagnoses using artificial neural networks. *Rev Cubana Enferm [Internet].* 2020[cited 2023 May 20];36(2):e3252. Available from: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0864-03192020000200013&lng=es
17. Gardner J. Artificial intelligence and machine learning algorithms for informing the diagnostic process of mild cognitive impairment and dementia. *Arch Clin Neuropsychol.* 2019;34(6):838. <https://doi.org/10.1093/arclin/acz035.06>
18. Wingerter DG, Santos EGO, Barbosa IR. The use of artificial neural networks to classify the social vulnerability of municipalities in Rio Grande do Norte State, Brazil. *Cad Saúde Pública.* 2020;36(8):e00038319. <https://doi.org/10.1590/0102-311X00038319>

19. Couto RC, Pedrosa TMG, Seara LM, Couto CS, Couto VS, Giacomini K, et al. Covid-19 vaccination priorities defined on machine learning. *Rev Saúde Pública*. 2022;56(11). <https://doi.org/10.11606/s1518-8787.2022056004045>
 20. Ponce de Leon CGRM, Mano LY, Fernandes DS, Paula RAP, Brasil GC, Ribeiro LM. Artificial intelligence in the analysis of emotions of nursing students undergoing clinical simulation. *Rev Bras Enferm*. 2023;76(Suppl 4):e20210909. <https://doi.org/10.1590/0034-7167-2021-0909>
 21. Gonçalves LS, Amaro MLM, Romero ALM, Schamne FK, Fressatto JL, Bezerra CW. Implementation of an Artificial Intelligence Algorithm for sepsis detection. *Rev Bras Enferm*. 2020;73(3):e20180421. <https://doi.org/10.1590/0034-7167-2018-0421>
 22. Paulela DC, Bocchi SCM, Mondelli AL, Martin LC, Regina Sobrinho A. Effectiveness of bag bath on microbial load: clinical trial. *Acta Paul Enferm*. 2018;31(1):7-16. <https://doi.org/10.1590/1982-0194201800003>
 23. Möller G, Magalhães AMM. Bed baths: nursing staff workload and patient safety. *Texto Contexto Enferm*. 2015;24(4):1044-52. <https://doi.org/10.1590/0104-0707201500003110014>
 24. Groven FM, Zwakhalen SM, Odekerken-Schröder G, Tan F, Hamers JP. Comfort during the bed bath: a randomised crossover trial on the effect of washing without water versus water and soap in nursing students. *J Clin Nurs*. 2021;30(15-16):2234-45. <https://doi.org/10.1111/jocn.15610>
 25. Stadler GP, Lunardi VL, Leal SMC, Mancia JR, Alves PRV, Viegas K. Sistematização da assistência de enfermagem em unidade de terapia intensiva: implementação de protocolo de banho no leito para pacientes adultos críticos. *Enferm Foco* [Internet]. 2019[cited 2023 May 20];10(7):109-114. Available from: <http://revista.cofen.gov.br/index.php/enfermagem/article/view/2809/558>
 26. Presidência da República (BR). Lei nº 7.498/86, de 25 de junho de 1986. Dispõe sobre a regulamentação do exercício da enfermagem, e dá outras providências [Internet]. 1986 [cited 2023 May 20]. Available from: http://www.planalto.gov.br/ccivil_03/leis/L7498.htm
 27. Ribeiro AL, Oliveira GMM. Toward a Patient-Centered, Data-Driven Cardiology. *Arq Bras Cardiol*. 2019;112(4):371-3. <https://doi.org/10.5935/abc.20190069>
-