

Carga de trabalho de enfermagem: uso de inteligência artificial para o desenvolvimento de modelo classificador*

Ninon Girardon da Rosa^{1,2}

 <https://orcid.org/0000-0001-5701-0494>

Tiago Andres Vaz³

 <https://orcid.org/0000-0003-3125-0662>

Amália de Fátima Lucena^{1,4,5}

 <https://orcid.org/0000-0002-9068-7189>

Destaques: **(1)** Desenvolvimento de modelo classificador preditivo da carga de trabalho de enfermagem. **(2)** Identificação das principais variáveis que geram carga de trabalho de enfermagem. **(3)** Possibilidade de automatização da avaliação da carga de trabalho de enfermagem. **(4)** Qualificação da gestão assistencial. **(5)** Contribuição nos estudos de dimensionamento de pessoal.

Objetivo: descrever o desenvolvimento de um modelo classificador preditivo da carga de trabalho de enfermagem, utilizando inteligência artificial. **Método:** estudo observacional retrospectivo, em fontes secundárias de registros eletrônicos de pacientes, com uso de aprendizado de máquina. A amostra por conveniência constituiu-se de 43.871 avaliações realizadas por enfermeiras assistenciais com o Sistema de Classificação de Pacientes de Perroca, as quais serviram como padrão ouro, e os dados clínicos do prontuário eletrônico de 11.774 pacientes, que constituíram as variáveis. Para a organização dos dados e a realização das análises, utilizou-se a plataforma de ciência de dados Dataiku®. A análise dos dados ocorreu de forma exploratória, descritiva e preditiva. Estudo aprovado pelo Comitê de Ética e Pesquisa da instituição campo do estudo. **Resultados:** o uso de inteligência artificial possibilitou o desenvolvimento do modelo classificador de avaliação da carga de trabalho de enfermagem, identificando as variáveis que mais contribuíram para a sua predição. O algoritmo classificou corretamente 72% das variáveis e a área sob a curva *Receiver Operating Characteristic* foi de 82%. **Conclusão:** houve o desenvolvimento de um modelo preditivo, demonstrando que é possível treinar algoritmos com dados do prontuário eletrônico do paciente para prever a carga de trabalho de enfermagem e que as ferramentas da inteligência artificial podem ser efetivas para a automatização desta atividade.

Descritores: Enfermagem; Carga de Trabalho; Informática em Enfermagem; Registros Eletrônicos em Saúde; Inteligência Artificial; Aprendizado de Máquina.

* A publicação deste artigo na Série Temática "Saúde digital: contribuições da enfermagem" se insere na atividade 2.2 do Termo de Referência 2 do Plano de Trabalho do Centro Colaborador da OPAS/OMS para o Desenvolvimento da Pesquisa em Enfermagem, Brasil. Artigo extraído da tese de doutorado "Modelo classificador preditivo para avaliação de carga de trabalho de enfermagem: uma análise secundária de Big Data", apresentada à Universidade Federal do Rio Grande do Sul, Escola de Enfermagem, Porto Alegre, RS, Brasil.

¹ Universidade Federal do Rio Grande do Sul, Escola de Enfermagem, Porto Alegre, RS, Brasil.

² Hospital de Clínicas de Porto Alegre, Diretoria de Enfermagem, Porto Alegre, RS, Brasil.

³ University Medical Center Utrecht, Data Science and Bioestatistic, Utrecht, Holanda.

⁴ Hospital de Clínicas de Porto Alegre, Comissão do Processo de Enfermagem, Porto Alegre, RS, Brasil.

⁵ Bolsista do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Brasil.

Como citar este artigo

Rosa NG, Vaz TA, Lucena AF. Nursing workload: use of artificial intelligence to develop a classifier model. Rev. Latino-Am. Enfermagem. 2024;32:e4239 [cited ____/____/____]. Available from: _____
https://doi.org/10.1590/1518-8345.7131.4239

Introdução

A carga de trabalho em enfermagem caracteriza-se pela demanda de trabalho requerida dos profissionais de enfermagem nas atividades de cuidado ao paciente⁽¹⁾. Existem sistemas de classificação que categorizam os pacientes de acordo com a quantidade, complexidade e tempo despendido para o cuidado. Diversos sistemas de classificação são utilizados no mundo, não havendo base científica para que um sistema tenha preferência sobre o outro, mas todos visam estimar a carga de trabalho, proporcionando parâmetros para o planejamento dos recursos assistenciais necessários⁽²⁾.

No Brasil, o Sistema de Classificação de Pacientes (SCP) de Perroca é utilizado para pacientes adultos hospitalizados em unidades de internação. São consideradas nove áreas de cuidado na avaliação: planejamento e coordenação do processo de cuidar; investigação e monitoramento; cuidado corporal e eliminações; cuidados com pele e mucosas; nutrição e hidratação; locomoção e atividade; terapêutica; suporte emocional e educação à saúde. Cada indicador possui uma graduação de 1 a 4, indicando a complexidade crescente do cuidado. Esses valores somados levam à classificação em uma das quatro categorias de cuidados: mínimos, intermediários, semi-intensivos e intensivos, os quais determinam o grau de dependência do paciente em relação aos cuidados de enfermagem⁽³⁾.

A avaliação contínua da carga de trabalho traz implicações positivas ao gerenciamento do processo de trabalho dos enfermeiros, embora tenha um grau de subjetividade e exija tempo dedicado para a aplicação dos instrumentos, em meio a tantas atribuições assistenciais e gerenciais desenvolvidas⁽⁴⁾. Tal contexto demonstra a importância do aprimoramento desse processo, pois a avaliação da carga de trabalho fornece parâmetros para o dimensionamento de pessoal das instituições brasileiras de saúde⁽⁵⁾. Um quadro de pessoal equilibrado proporciona a realização de cuidados essenciais aos pacientes, a prevenção de eventos adversos, além de segurança aos profissionais e satisfação no trabalho⁽²⁾.

Nos hospitais, o investimento crescente no Prontuário Eletrônico do Paciente (PEP) possibilita a sistematização dos dados oriundos dos registros dos atendimentos dos profissionais e a utilização de técnicas inovadoras de processamento ágil de grandes volumes de dados clínicos e análises preditivas, além do desenvolvimento de ferramentas que automatizam atividades⁽⁶⁾.

Assim, a aproximação dos enfermeiros com a ciência de dados amplia as possibilidades de desenvolver soluções inovadoras, com informações úteis, extraídas dos bancos de dados⁽⁷⁾, principalmente nas instituições

em que há um ambiente favorável à informatização de todas as etapas do Processo de Enfermagem (PE), o que promove a sistematização de dados e uso de linguagem padronizada, tais como os Diagnósticos de Enfermagem (DEs) da NANDA Internacional (NANDA-I)⁽⁸⁾ e as intervenções e atividades da Classificação das Intervenções de Enfermagem (NIC)⁽⁹⁾.

Os bancos de dados analíticos introduzem os conceitos relacionados a volumes de dados, velocidade, variedade, veracidade e valor, que caracterizam a definição de *Big Data*, demonstrando identidade com o contexto dinâmico dos hospitais, que estão se beneficiando do desenvolvimento de sistemas inteligentes⁽⁷⁾.

A Inteligência Artificial (IA) pode desenvolver atividades com algum grau de autonomia para alcançar objetivos específicos, por isso o seu uso na enfermagem pode oferecer assertividade de dados e redução no tempo de trabalho⁽¹⁰⁾.

As técnicas de IA, como o aprendizado de máquina, auxiliam nas respostas dos problemas de enfermagem, assim, os enfermeiros engajados nessa discussão mundial elevam a qualidade da prática e da gestão assistencial e têm muito a contribuir no desenvolvimento de sistemas informatizados e desenvolvimento de modelos preditivos⁽¹⁰⁾.

Esses avanços têm sido impulsionados por estudos multidisciplinares com profissionais da saúde e cientistas de dados, que buscam desenvolver modelos que atendam à complexidade do ambiente hospitalar^(7,10-11).

Embora os hospitais brasileiros necessitem enfrentar desafios relacionados à infraestrutura tecnológica, sistematização de dados e interoperabilidade entre sistemas para a utilização das ferramentas de IA, a liderança dos enfermeiros tem um papel fundamental na busca de inovações e no desenvolvimento de competências, para que os profissionais da área possam estar preparados para um mundo cada vez mais informatizado⁽¹¹⁾.

A aplicação da IA em ambientes de cuidado de enfermagem é recente e tem sido explorada principalmente nos hospitais, em processamento de imagens e sinais, em classificação de atividades de enfermagem, na comunicação de cuidados e na detecção de quedas. A identificação de outras áreas de aplicação desta técnica pode gerar importantes contribuições para o ensino, para a pesquisa e para a prática de enfermagem⁽¹²⁾.

No que tange à avaliação de carga de trabalho de enfermagem, em revisão da literatura, não foram encontrados estudos brasileiros que aplicam IA para a realização dessa mensuração. Escassas publicações internacionais abordam a utilização de instrumentos automatizados⁽¹³⁻¹⁵⁾, no entanto, não há menção

sobre o uso de dados gerados pelo PE, que é uma metodologia de referência à organização da assistência e dos registros de enfermagem⁽¹⁶⁾.

A Associação Norte Americana de Enfermagem (ANA) estimula o desenvolvimento de sistemas de avaliação de carga de trabalho de enfermagem automatizados, destacando a importância do embasamento científico e da capacidade de integração com as plataformas institucionais. A ANA ressalta que os instrumentos devem ser simples e eficientes, para traduzir a realidade de cada local e não gerar carga de trabalho adicional aos enfermeiros, mas precisam ser validados e seus resultados monitorados a fim de oferecerem predições corretas sobre as necessidades das equipes e dos pacientes⁽¹⁷⁾. A operacionalização das recomendações depende do desenvolvimento de pesquisas conjuntas entre profissionais da saúde e cientistas de dados, de forma a superar a lacuna de conhecimentos e as eventuais fragilidades no uso de dados secundários e IA⁽¹⁷⁾.

Baseando-se nessas ideias e na carência de pesquisas sobre o tema, este artigo tem como objetivo descrever o desenvolvimento de um modelo classificador preditivo da carga de trabalho de enfermagem, utilizando IA.

Método

Tipo de estudo

Trata-se de um estudo observacional retrospectivo, em fontes secundárias de registros eletrônicos de pacientes, com elaboração de modelo classificador preditivo com técnicas supervisionadas de Aprendizado de Máquina (AM)⁽¹⁸⁾.

Cenário do estudo

O estudo ocorreu de 2021 a 2023, em um hospital público universitário de grande porte, com atendimento a pacientes de alta complexidade. A instituição é acreditada internacionalmente em padrões de qualidade e segurança e tem como pilares a assistência, o ensino, a pesquisa de excelência e a inovação. O hospital desenvolveu um sistema informatizado próprio na década de 80, o qual vem sendo aprimorado desde então. O PE e os instrumentos de avaliação de carga de trabalho já estão incorporados, mas não possuem interoperabilidade entre si.

Logística dos dados

Os pesquisadores utilizaram as etapas do processo de *Knowledge Discovery in Databases* (KDD)⁽¹⁸⁾ como roteiro na logística dos dados: seleção, pré-processamento,

transformação e mineração dos dados e interpretação de resultados. O KDD⁽¹⁹⁾ é um processo para identificar padrões consistentes em grande quantidade de dados e descobrir informações relevantes para apoiar decisões estratégicas.

Estruturação do banco de dados analítico

A estruturação do banco de dados analítico envolve seleção, pré-processamento e transformação dos dados⁽¹⁹⁾.

Na etapa de seleção ocorreu a definição das informações do estudo, organizadas em dois conjuntos, seguida da coleta de dados e da sua importação para a plataforma de ciência de dados Dataiku®, associada ao *software* de processamento de *Big Data* PostgreSQL®, o qual permitiu o gerenciamento do banco de dados e o relacionamento de dados complexos entre si.

O primeiro conjunto foi organizado a partir de 107.507 avaliações de pacientes realizadas por enfermeiras assistenciais de doze unidades de internação clínico-cirúrgicas, no período de 2015 a 2019, utilizando o SCP de Perroca⁽³⁾. Esses dados correspondem aos escores dos pacientes e às respectivas classificações nas categorias de cuidados mínimos, intermediários, semi-intensivos e intensivos. As planilhas continham o número do leito do paciente e a data da avaliação. Os dados foram coletados pelos pesquisadores diretamente das planilhas informatizadas do sistema da instituição e foram organizados em planilha única para serem usados como padrão ouro.

O segundo conjunto foi organizado a partir de dados extraídos do PEP de pacientes internados nas mesmas unidades, no mesmo período do primeiro conjunto de dados. A solicitação de consulta aos prontuários (*query*) foi planejada em reuniões com a analista de Tecnologia da Informação (TI) que realiza essa atividade na instituição, considerando as variáveis em estudo. Assim, em cada *query* foi solicitada uma variável representativa da carga de trabalho de enfermagem, com base nas nove áreas de cuidado do SCP de Perroca⁽³⁾, quais sejam: cuidados de enfermagem; diagnósticos de enfermagem; registros dos sinais vitais; prescrições de dieta; prescrição de medicamentos; prescrição de soluções; prescrição de hemoterapia; prescrição de oxigenoterapia; solicitações de exames coletados pela enfermagem; solicitações de consultorias por especialistas e existência de condutas educativas a pacientes e familiares.

Em todas as *queries* também foram solicitadas as variáveis idade, sexo, escolaridade, data da internação e os identificadores número do leito e do prontuário. Assim, o estudo contemplou 15 diferentes variáveis que se ampliaram considerando suas estratificações,

como por exemplo: os cuidados de enfermagem totalizaram 846 e os diagnósticos de enfermagem totalizaram 189 variáveis. Os dados disponibilizados em tabelas foram referentes a 58.888 pacientes internados. Dentre eles, foram selecionados aqueles que estavam cadastrados no mesmo leito e na mesma data de internação dos pacientes do primeiro conjunto de dados, o que resultou em 11.774 pacientes.

Não foram incluídos, no modelo, os dados anteriores a 2015, por não haver registros sistematizados de avaliação dos pacientes com o SCP de Perroca e dados posteriores a 2019, porque os processos assistenciais foram alterados durante a pandemia causada pelo coronavírus.

Na etapa de pré-processamento, os pesquisadores realizaram revisão e limpeza para garantir a qualidade dos dados.

Para o primeiro conjunto de dados, os critérios de exclusão adotados foram: pacientes diferentes que tinham avaliações com SCP de Perroca⁽³⁾ no mesmo dia e estavam cadastrados no mesmo leito, considerando a possibilidade de dúvida se a avaliação registrada era do paciente que saiu ou do paciente que entrou no leito; pacientes com duas avaliações diferentes no mesmo dia e que estavam cadastrados no mesmo leito também foram excluídos, devido à possibilidade de erro ao registrar o leito do paciente ou pela possibilidade de ser um segundo registro relativo ao mesmo paciente para corrigir um equívoco de avaliação, ao invés da correção ter sido efetuada no primeiro registro; pacientes com menos de 48 horas de internação no momento da avaliação, pois inferiu-se que esses pacientes teriam menos chances de se exporem às variáveis estabelecidas para a análise. Após a aplicação desses critérios, no conjunto de 107.507 avaliações, obteve-se 43.871 avaliações para o estudo.

Em relação ao segundo conjunto de dados, a etapa de pré-processamento exigiu bastante tempo e dedicação dos pesquisadores na revisão, no entanto a reorganização de tabelas não implicou em alteração do número de pacientes, corroborando os 11.774 pacientes.

Os dados dos dois conjuntos foram importados para a plataforma de ciência de dados Dataiku® à medida que foram sendo disponibilizados.

Na etapa de transformação, os dados brutos foram processados para terem uniformidade e serem minerados com técnicas de AM, em busca de padrões e relações no grande conjunto de dados (*Big Data*).

Mineração dos dados

Mineração de dados é o processo de analisar grandes conjuntos para identificar padrões e extrair informações que geram conhecimentos e apoiam decisões⁽¹⁹⁾.

Na mineração de dados, são usados algoritmos de AM, que definem a sequência dos procedimentos por meio de instruções matemáticas automatizadas⁽¹⁸⁾. Este estudo foi desenvolvido na linguagem *Python*, com o módulo de algoritmos de classificação do pacote *Scikit-learn*⁽²⁰⁾. O algoritmo aplicado foi o *Random Forest* (RF), caracterizado por uma combinação de preditores que se desenvolvem em forma de árvores de decisão e se distribuem nas classes conforme o grau de pureza e de homogeneidade⁽²¹⁾.

No desenvolvimento do modelo preditivo foi utilizada a técnica de validação cruzada *k-fold* ($k=5$), com divisão do banco de dados analítico em k partições para o modelo ser treinado em $k-1$ partições e validado na partição restante. Esse procedimento foi repetido, alternando a partição dos dados de treino⁽²²⁾, buscando acertar a classe de cuidados dos pacientes (mínimo, intermediário, intensivo, semi-intensivo).

O processo incluiu estratégias para garantir a qualidade das etapas: aprimoramentos nos parâmetros do algoritmo RF, os quais atingiram uma composição final de 1000 árvores, com seis camadas de profundidade⁽²¹⁾, e checagens para evitar *overfitting* (ajuste excessivo que ocorre quando o modelo de aprendizado de máquina fornece previsões precisas apenas para dados de treinamento, como se o modelo não fosse capaz de generalizar para os outros dados não vistos) e vazamento de dados (compartilhamento de dados entre as fases de treinamento e validação). Esses ajustes elevaram a acurácia até o ponto de saturação de desempenho das métricas do modelo⁽²²⁾.

As métricas avaliadas resultaram da matriz de confusão (acurácia, sensibilidade, *F1 score* e precisão) e do desempenho da curva ROC (*Receiver Operating Characteristic*) e da AUC-ROC (*Area Under The ROC Curve*)⁽²²⁾.

A importância de cada variável para a classificação final da carga de trabalho de enfermagem foi conhecida na fase de predição do modelo⁽²³⁾.

Análise dos dados

Para a análise, utilizou-se a plataforma de ciência de dados Dataiku® e o *software* de processamento de *Big Data* PostgreSQL®. A análise exploratória foi realizada em todas as etapas da pesquisa para a compreensão dos dados e das relações entre as variáveis⁽¹⁹⁾. A análise descritiva foi utilizada para detalhar as características dos conjuntos de dados e os resultados das variáveis foram apresentados em frequência relativa. A análise preditiva ocorreu na fase de interpretação dos resultados, possibilitando explorar as relações entre variáveis de eventos anteriores e variáveis

previstas no modelo desenvolvido, além de conhecer o desempenho das métricas correspondentes⁽¹⁸⁾.

Aspectos éticos

O estudo foi aprovado pelo Comitê de Ética e Pesquisa institucional (2021-0521) e cadastrado na Plataforma Brasil (55207921.50000.5327). As recomendações do Termo de Compromisso de Utilização de Dados foram adotadas pelos pesquisadores e houve dispensa de uso do Termo de Consentimento Livre e Esclarecido.

Resultados

Caracterização das avaliações dos pacientes realizadas por enfermeiras com o SCP de Perroca, referente ao primeiro conjunto de dados

As avaliações realizadas pelas enfermeiras compreenderam 43.871 registros. A maioria dos pacientes está na classe de cuidados semi-intensivos (50,61%), seguida da classe de cuidados intermediários (31,25%). A idade média é de 61 anos [Desvio-Padrão (DP)±16,4],

50,08% são do sexo masculino e 52,77% possuem o ensino fundamental.

Caracterização dos pacientes dos quais foram extraídos dados dos prontuários eletrônicos para compor as variáveis do segundo conjunto de dados

Os pacientes internados nas unidades clínico-cirúrgicas caracterizaram-se por 11.774 pessoas, com idade média de 61,6 anos (DP ±16,7), 50,95%, do sexo masculino e 54,39% tem ensino fundamental.

Importância das variáveis no modelo preditor de avaliação da carga de trabalho de enfermagem

O algoritmo RF foi treinado para classificar as variáveis nas quatro classes de cuidados do SCP de Perroca⁽³⁾. O número total de variáveis que compõem cada classe é diferente: 574 para mínimos, 701 para intermediários, 731 para semi-intensivos e 692 para intensivos. Neste artigo, apresenta-se as 15 variáveis mais importantes para cada classe, segundo o grau de importância no modelo, conforme as Figuras 1, 2, 3 e 4.



*SNE = Sonda Nasoenteral

Figura 1 - Descrição da importância das variáveis na classe de cuidados mínimos do modelo preditor de avaliação da carga de trabalho de enfermagem (n = 574). Porto Alegre, RS, Brasil, 2023



*SNE = Sonda Nasoenteral

Figura 2 - Descrição da importância das variáveis na classe de cuidados intermediários do modelo preditor de avaliação da carga de trabalho de enfermagem (n = 701). Porto Alegre, RS, Brasil, 2023

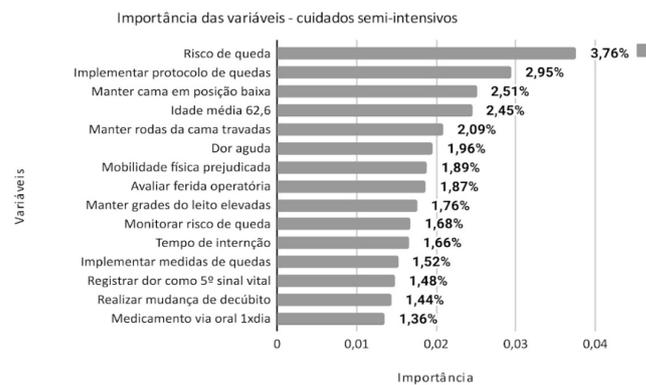
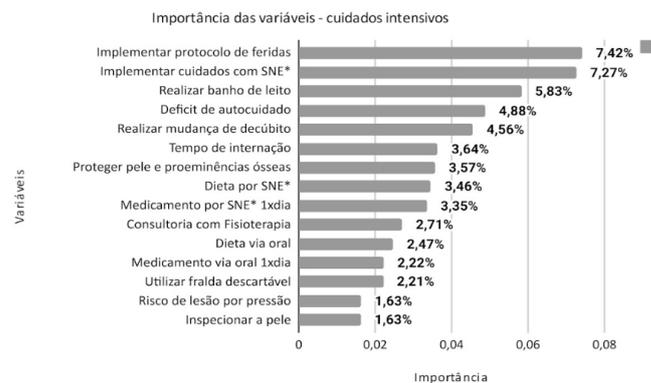


Figura 3 - Descrição da importância das variáveis na classe de cuidados semi-intensivos do modelo preditor de avaliação da carga de trabalho de enfermagem (n = 731). Porto Alegre, RS, Brasil, 2023



*SNE = Sonda Nasoenteral

Figura 4 - Descrição da importância das variáveis na classe de cuidados intensivos no modelo preditor de avaliação da carga de trabalho de enfermagem (n = 692). Porto Alegre, RS, Brasil, 2023

Métricas de avaliação do desempenho do modelo classificador

A partir das classificações das variáveis, o modelo buscou identificar as previsões positivas corretas. Os resultados das métricas estão demonstrados na Tabela 1.

Todas as métricas tiveram excelentes desempenhos na classe de cuidados intermediários (0,962), seguida

da classe de cuidados mínimos (0,917). Isso significa que o algoritmo fez uma boa distinção dos cuidados requeridos para os pacientes dessas duas classes. As classes de cuidados semi-intensivos (0,759) e intensivos (0,791) tiveram menores resultados. Os modelos com desempenho entre $0,8 < 0,9$ são considerados bons e aqueles com desempenho $\geq 0,9$ são excelentes⁽²¹⁾.

Tabela 1 - Métricas de avaliação do desempenho do modelo classificador preditivo da carga de trabalho de enfermagem, segundo a classificação em cuidados mínimos, intermediários, semi-intensivos e intensivos do SCP* de Perroca. Porto Alegre, RS, Brasil, 2023

SCP* Perroca	Acurácia	Sensibilidade	Precisão	F1 Score†	AUC- ROC‡
Mínimos	0,990	0,715	0,849	0,776	0,917
Intermediários	0,952	0,929	0,917	0,923	0,962
Semi-intensivos	0,691	0,965	0,625	0,759	0,759
Intensivos	0,824	0,463	0,459	0,461	0,791
Modelo final	0,72	0,66	0,67	0,64	0,82

*SCP Perroca = Sistema de Classificação de Pacientes de Perroca; †F1 Score = Function 1 Score; ‡AUC-ROC = Area Under The Receiver Operating Characteristic Curve

Os valores do modelo final têm base na abordagem *Multiclass Area Under the Curve*, que classificou as quatro classes ao mesmo tempo e apresentou DP de $\pm 0,036^{(21-24)}$.

De forma global, o algoritmo RF classificou corretamente 72% das variáveis do modelo e a AUC-ROC indicou que o modelo teve um desempenho de 82% na classificação geral dos pacientes nas diferentes categorias de cuidados⁽²¹⁾.

Discussão

Observa-se que a maioria dos pacientes avaliados com o SCP de Perroca⁽³⁾ são pessoas idosas, com ensino fundamental e fazem parte da classe de cuidados semi-intensivos. Identifica-se também que, na classificação dos registros do PEP, o algoritmo RF selecionou variáveis semelhantes para compor as classes de cuidados, no entanto atribuiu a elas diferentes graus de importância. Os cuidados de enfermagem foram as variáveis mais expressivas em todas as classes, reforçando o fenômeno pesquisado: a classificação da carga de trabalho de enfermagem, cuja essência é a caracterização da demanda de trabalho requerida desses profissionais nas atividades diárias de cuidado ao paciente⁽¹⁾.

Na prática clínica da instituição em estudo, os cuidados prescritos decorrem dos diagnósticos realizados pelos enfermeiros, os quais se baseiam no sistema de linguagem padronizada da NANDA-I⁽⁸⁾ e se relacionam com o construto do SCP de Perroca, fundamentado na identificação das necessidades de cuidados aos pacientes⁽³⁾. Um estudo comparativo entre os DEs e as áreas de cuidado do SCP de Perroca, no mesmo cenário, constatou correspondência entre ambos em pelo menos uma área de cuidado do instrumento, demonstrando que os DEs podem indicar, além das necessidades de cuidado, o grau da complexidade demandado e a dependência da equipe de enfermagem, sendo guias importantes na gestão do cuidado⁽²⁵⁾.

Outro aspecto relevante a ser ressaltado é a característica dos pacientes do estudo, quando comparada à definição de cada classe de cuidado do SCP de Perroca, pois, em todas elas há variáveis próprias de pacientes dependentes da enfermagem, provavelmente devido à predominância de pessoas idosas, o que reforça a importância dos cuidados de enfermagem em atenção às necessidades humanas básicas. Este referencial, preconizado em estudos sobre PE no Brasil, também alicerçou o SCP de Perroca, visto que as necessidades humanas básicas são fenômenos vitais aos seres humanos e, portanto, definidas como entes concretos da Ciência de Enfermagem⁽²⁶⁻²⁷⁾.

Na classe de cuidados mínimos, em que, conceitualmente, os pacientes estão estáveis do ponto de vista clínico e fisicamente autossuficientes quanto às suas necessidades humanas básicas⁽³⁾, o tempo de internação (período entre a data da internação na unidade até a data da sua avaliação com o SCP de Perroca) foi a variável mais importante (4,72%), sugerindo que, mesmo para pacientes que teoricamente exigem menos cuidados, o aumento do tempo de hospitalização pode gerar carga de trabalho para a equipe de enfermagem.

Chama atenção que a variável consultoria ao serviço social também se destaca, confirmando um perfil de pacientes que, para além de cuidados diretos de enfermagem, possuem problemas que demandam abordagens da equipe multiprofissional, com intervenções que facilitem a interface entre o sistema de cuidados à saúde com o paciente e a família. Isso requer uma organização que se relaciona diretamente com o tempo de internação do paciente⁽⁹⁾.

Um outro estudo norte-americano, que desenvolveu um modelo de AM para melhorar o processo de alta hospitalar, identificou como principais barreiras potenciais à alta: o paciente que não tem dieta oral regular, a indisponibilidade de serviços de visita domiciliar e a falta de apoio social⁽²⁸⁾. Além disso, um estudo europeu sobre causas de atraso na alta hospitalar refere, entre os múltiplos fatores contribuintes, as dificuldades na transição de cuidados do hospital para o domicílio ou para instituições de longa permanência⁽²⁹⁾.

Outras variáveis surgiram nessa classe de cuidados, mas as características dos pacientes não traduzem a definição de Perroca⁽³⁾ porque são diagnósticos e cuidados de enfermagem típicos de pacientes dependentes e, embora eles tenham sido classificados como pertencentes a classe de cuidados mínimos, as variáveis se repetem nas demais classes de cuidados. Exemplos disso são o Diagnóstico de Enfermagem (DE) déficit para o autocuidado⁽⁸⁾, indicando incapacidade para realizar as atividades de rotina da vida diária, tais como alimentação e banho; os cuidados de enfermagem relacionados aos domínios fisiológico básico⁽⁹⁾ (realizar banho de leito, implementar cuidados com sonda nasointestinal) e fisiológico complexo⁽⁹⁾ (implementar protocolo de prevenção de tratamento de feridas); além da consultoria com a fisioterapia.

O DE risco de quedas⁽⁸⁾, junto com os cuidados do domínio segurança dos pacientes⁽⁹⁾ (manter grades do leito elevadas, implementar protocolo de prevenção de quedas, manter cama em posição baixa, manter rodas da cama travadas), representam intervenções de proteção contra a ocorrência de danos, que em menor

ou maior grau fazem parte de cuidados universais aos pacientes hospitalizados.

A classe de cuidados intermediários constitui-se de pacientes estáveis sob o ponto de vista clínico e de enfermagem, com parcial dependência das ações de enfermagem para o atendimento das necessidades humanas básicas⁽³⁾. Nessa classe, a variável que se mostrou mais importante foi o cuidado de enfermagem ao realizar banho de leito (8,34%), que, associado com os cuidados realizar higiene após evacuação e utilizar fralda descartável, compõem cuidados de higiene corporal que demandam esforço físico para mobilizar o paciente e trocar a roupa de cama, podendo ocasionar cansaço e lesões osteomusculares, mesmo nos casos em que os profissionais realizam a atividade em dupla⁽³⁰⁾.

O banho de leito, por tratar-se de um cuidado fisiológico básico⁽⁹⁾, faz parte das atividades diárias da equipe de enfermagem e, dependendo do dimensionamento de pessoal e das condições de infraestrutura do ambiente, sobrecarrega a equipe que realiza a ação⁽³⁰⁾.

Dentre os demais cuidados que se destacaram estão os fisiológicos complexos⁽⁹⁾, relacionados com o DE risco de lesão por pressão⁽⁸⁾: implementar protocolo de prevenção e tratamento de feridas, proteger pele e proeminências ósseas, realizar mudança de decúbito e inspecionar pele em busca de hiperemia e isquemia⁽⁹⁾.

A classe dos cuidados semi-intensivos pressupõe cuidados a pacientes crônicos, estáveis sob o ponto de vista clínico, porém, com total dependência das ações de enfermagem quanto ao atendimento das necessidades humanas básicas⁽³⁾.

Na classificação realizada pelas enfermeiras com o SCP de Perroca, 22.106 pacientes foram classificados com necessidade de cuidados semi-intensivos, cerca de 50% do primeiro conjunto de dados.

Ao aplicar o algoritmo RF no segundo conjunto de dados, a variável principal foi o DE risco de queda⁽⁸⁾ (3,76%) e vários cuidados a ele relacionados⁽⁹⁾. A prevenção de quedas é a sexta meta internacional de segurança, tendo em vista as suas altas taxas de incidência, que correspondem a dois em cada cinco eventos adversos⁽³¹⁾. As causas de quedas em hospitais são multifatoriais⁽³²⁾ e relacionam-se com as demais variáveis importantes dessa classe de cuidados, tais como idade média de 62,6 anos, os DEs dor aguda e mobilidade física prejudicada e os cuidados de enfermagem relativos à ferida operatória. Estas variáveis remetem aos fatores de risco da limitação para caminhar no período pós-operatório, os quais também foram constatados em diferentes estudos⁽³²⁻³⁶⁾.

A natureza das atividades de enfermagem à beira leito justifica a preocupação dos profissionais em planejar e executar estratégias de prevenção de quedas, aplicando protocolos de segurança recomendados por órgãos governamentais nacionais e internacionais, com alocação de equipe dedicada à gestão de riscos assistenciais, além de estudos sobre o tema⁽³⁷⁾. Ademais, sabe-se que o dimensionamento adequado de pessoal e a capacitação das equipes para a prevenção de quedas também influenciam na incidência desse tipo de evento⁽³⁵⁾.

A classe de cuidados intensivos compreende cuidados a pacientes graves, com risco iminente de vida, sujeitos à instabilidade de sinais vitais, que requeiram assistência de enfermagem permanente e especializada⁽³⁾. Essa definição de Perroca⁽³⁾ deve ser relativizada neste estudo, porque pacientes com instabilidade clínica grave não ficam em unidades de internação. No entanto, pela opção de apresentar as 15 principais variáveis de cada classe de cuidado, algumas variáveis não estão explicitadas neste artigo, tais como as prescrições e cuidados relacionados aos sinais vitais, que aparecem a partir da vigésima variável, e que são mencionados na definição de Perroca⁽³⁾.

O cuidado de enfermagem implementar protocolo de prevenção e tratamento de feridas⁽⁹⁾ foi a variável mais importante na classe (7,42%) e, junto com os demais cuidados fisiológicos complexos⁽⁹⁾, como realizar mudança de decúbito, proteger pele e proeminências ósseas e inspecionar pele em busca de hiperemia e isquemia, estão relacionados ao DE risco de lesão por pressão⁽⁸⁾.

Um estudo global identificou que a ocorrência de lesões é um dos eventos adversos mais frequentes em pacientes hospitalizados em todo o mundo, com prevalência geral de 12,8%⁽³⁸⁾, ocorrendo principalmente em pacientes dependentes, com doenças crônicas, internação prolongada, com redução do senso de percepção e da mobilidade e com alterações nutricionais⁽³⁹⁾. Tais características estão fundamentadas em diversas variáveis que se destacaram na classe de cuidados intensivos: no DE síndrome de déficit autocuidado⁽⁸⁾; nos cuidados de enfermagem implementar cuidados com sonda nasoenteral, realizar banho de leito e utilizar fralda descartável; assim como nas prescrições médicas administrar dieta e medicamentos por sonda nasoenteral e na consultoria com fisioterapeuta.

O risco de lesão por pressão geralmente é determinado por escalas de predição aplicadas por enfermeiras⁽⁴⁰⁾, mas existem iniciativas de automatização desse processo, como é o caso de um estudo japonês que desenvolveu um modelo preditivo de AM para identificar precocemente o risco de lesão por pressão, a partir de registros no prontuário eletrônico⁽⁴¹⁾. Também é objetivo

desse modelo a retirada da carga adicional de trabalho gerada pela atividade⁽⁴¹⁾, de modo semelhante ao proposto em nosso estudo de modelo de avaliação da carga de trabalho de enfermagem.

As variáveis que configuram as quatro classes do modelo de avaliação da carga de trabalho de enfermagem desenvolvido remetem a um contexto assistencial complexo e contemplam as nove áreas de cuidado do SCP de Perroca⁽³⁾, no entanto, considerando a variável mais importante de cada classe, observam-se algumas especificidades.

A única classe em que as fragilidades sociais tiveram destaque foi a dos cuidados mínimos e elas são fatores determinantes para o tempo de internação, guardando relação com as áreas de cuidado suporte emocional e educação à saúde do SCP de Perroca⁽³⁾, que demandam uma coordenação de cuidados entre equipes assistenciais.

Na classe dos cuidados intermediários, a variável realizar banho de leito demonstra a forte influência dos cuidados fisiológicos básicos⁽⁹⁾, bem como a relação com a área cuidado corporal e eliminações⁽³⁾.

As classes dos semi-intensivos e intensivos são direcionadas pelos cuidados fisiológicos complexos⁽⁹⁾ (prevenção/tratamento de quedas e de lesões por pressão), associando-se às áreas de locomoção e à atividade e de cuidados com pele e mucosas⁽³⁾. Ambas exigem intervenções permanentes de cuidados diretos aos pacientes e também indiretos, os quais demandam a organização do ambiente assistencial e colaboração multidisciplinar⁽³⁾.

Este modelo teórico de avaliação de carga de trabalho de enfermagem retrata a realidade de um hospital universitário de alta complexidade, o que pode justificar as particularidades dos resultados encontrados. A singularidade de cada cenário assistencial deve ser considerada para se obter modelos confiáveis, sabendo-se que, embora os algoritmos possam produzir previsões e recomendações úteis, o conhecimento e a experiência humana são essenciais para a tomada de decisão⁽⁶⁾.

Este estudo tem limitações relacionadas à capacidade de generalização, porque utiliza dados de pacientes de uma única instituição. Considerando que são escassos os conhecimentos sobre aplicativos de aprendizado de máquina projetados para avaliação de carga de trabalho de enfermagem, sugere-se investir na modelagem dos dados para melhorar o desempenho do modelo, especialmente nas classes de cuidados semi-intensivos e intensivos, no intuito de ambos alcançarem o mínimo de 80% de classificações corretas para serem considerados com bom desempenho. Para isso, será importante validar o modelo desenvolvido com a coleta de dados eletrônicos diretamente da ferramenta de avaliação da carga de

trabalho (SCP de Perroca), a qual foi informatizada no sistema institucional durante a realização deste estudo, proporcionando a qualificação dos dados do padrão ouro. Outra sugestão é testar o modelo com o uso exclusivo de variáveis com terminologias padronizadas, fundamentais para pesquisas que envolvem ciência de dados, tais como as taxonomias dos diagnósticos e dos cuidados de enfermagem (NANDA-I e NIC), o que poderá aumentar a capacidade de buscar padrões no banco de dados analítico e de compreender as classificações realizadas pelo modelo.

Destaca-se que a replicação do estudo exige estrutura tecnológica institucional, disponibilidade de plataformas de ciências de dados e profissionais com conhecimento na área, além de PE informatizado, utilizando sistema de linguagem padronizada. Ressalta-se, ainda, que os modelos de classificação de carga de trabalho de enfermagem, apesar de serem excelentes norteadores para a gestão assistencial, nunca representarão a totalidade de necessidades dos pacientes por serem inúmeras, multidimensionais e interdependentes.

Acredita-se que o modelo classificador desenvolvido agrega avanços ao conhecimento científico na enfermagem, tendo em vista que é o primeiro estudo brasileiro para avaliar carga de trabalho de enfermagem usando técnicas de IA, com dados do PEP e utilizando um SCP validado como padrão ouro. O estudo é inovador, visto que tal conhecimento é incipiente na Enfermagem, e estimula a automatização de processos, qualificando a gestão assistencial.

Conclusão

Neste estudo, foi desenvolvido um modelo classificador preditivo da carga de trabalho de enfermagem, utilizando IA. O resultado do modelo demonstrou que é possível treinar algoritmos com dados do PEP para prever a carga de trabalho de enfermagem. As variáveis tempo de internação, realizar banho de leito, risco de queda e implementar protocolo de prevenção e tratamento de feridas representaram a maior carga de trabalho na classificação final do modelo, dando visibilidade a aspectos relevantes a serem considerados no planejamento das escalas de atividades da equipe de enfermagem e do dimensionamento de pessoal no contexto estudado. O desenvolvimento de modelos classificadores preditivos da carga de trabalho de enfermagem implica na possibilidade de automatizar a atividade, tornando-a objetiva, precisa e proporcionando que os enfermeiros possam destinar o tempo dedicado à avaliação para outras demandas assistenciais e gerenciais. O modelo preditivo tem potencial para

ser aplicado em diferentes ambientes, desde que os algoritmos sejam treinados com conjuntos de dados qualificados e representem a realidade de cada local.

Agradecimentos

Agradecemos a Maria Tereza Ponz pela extração de dados do prontuário eletrônico dos pacientes e a Cássia Teixeira dos Santos pela colaboração na formatação do texto.

Referências

1. Swinger PA, Vance DE, Patrician PA. Nursing workload in the acute-care setting: A concept analysis of nursing workload. *Nurs Outlook*. 2016;64(3):244-54. <https://doi.org/10.1016/j.outlook.2016.01.003>
2. Griffiths P, Saville C, Ball J, Jones J, Pattison N, Monks T, et al. Nursing workload, nurse staffing methodologies and tools: A systematic scoping review and discussion. *Int J Nurs Stud*. 2020;103:103487. <https://doi.org/10.1016/j.ijnurstu.2019.103487>
3. Perroca MG. Development and content validity of a new version of a patient classification instrument. *Rev. Latino-Am. Enfermagem*. 2011;19(1):58-66. <https://doi.org/10.1590/S0104-11692011000100009>
4. Macedo ABT, Riboldi CO, Silva KS, Mergen T, Echer IC, Souza SBC. Validation of parameters to fill in the Perroca's patient classification system. *Rev Gaúcha Enferm*. 2018;39:e20170241. <https://doi.org/10.1590/1983-1447.2018.20170241>
5. Conselho Federal de Enfermagem (BR). Resolução nº 543/2017 2017 [Internet]. Rio de Janeiro: COFEN; 2017 [cited 2022 Dec 18]. Available from: http://www.cofen.gov.br/resolucao-cofen-5432017_51440.html
6. Kim SH, Song H. How digital transformation can improve hospitals' operational decisions. *Harv Bus Rev* [Internet]. 2022 Jan [cited 2022 Nov 23]. Available from: <https://hbr.org/2022/01/how-digital-transformation-can-improve-hospitals-operational-decisions>
7. Pruinelli L. Nursing and Data: Powering Nursing Leaders for Big Data Science. *Rev Bras Enferm*. 2021;74(4):e740401. <https://doi.org/10.1590/0034-7167.2021740401>
8. Herdman TH, Kamitsuru S, Lopes, CT. *NANDA International Nursing Diagnoses. Definitions and Classification*. 12th ed. New York, NY: Thieme; 2021-2023.
9. Wagner C, Butcher H, Clarke M. *Nursing Interventions Classification (NIC)*. 8th ed. St. Louis, MO: Elsevier; 2022.
10. Ronquillo CE, Peltonen LM, Pruinelli L, Chu CH, Bakken S, Beduschi A, et al. Artificial intelligence in nursing: Priorities and opportunities from an international invitational think-tank of the Nursing and Artificial Intelligence Leadership Collaborative. *J Adv Nurs*. 2021;77(9):3707-17. <https://doi.org/10.1111/jan.14855>
11. Velez L. The Nursing of the Future: combining Digital Health and the Leadership of Nurses. *Rev. Latino-Am. Enferm*. 2020;28:e3338. <https://doi.org/10.1590/1518-8345.0000.3338>
12. Seibert K, Domhoff D, Bruch D, Schulte-Althoff M, Fürstenau D, Biessmann F, et al. Application scenarios for artificial intelligence in nursing care: rapid review. *J Med Internet Res*. 2021;23(11):e26522. <https://doi.org/10.2196/26522>
13. Griffiths P, Saville C, Ball JE, Chable R, Dimech A, Jones J, et al. The Safer Nursing Care Tool as a guide to nurse staffing requirements on hospital wards: observational and modeling study. *Health Serv Deliv Res*. 2020;8(16). <https://doi.org/10.3310/hsdr08160>
14. The Shelford Group. Safer nursing care tool [Internet]. [place unknown]; 2019 [cited 2023 Jan 18]. Available from: <http://shelfordgroup.org/safer-nursing-care-tool/>
15. Meyer KR, Fraser PB, Emeny RT. Development of a nursing assignment tool using workload acuity scores. *J Nurs Adm*. 2020;50(6):322-7. <https://doi.org/10.1097/NNA.0000000000000892>
16. Barros ALBL, Lucena AF, Morais SCR, Brandão MAG, Almeida MA, Cubas MR, et al. Nursing Process in the Brazilian context: reflection on its concept and legislation. *Rev Bras Enferm*. 2022;75(6):e20210898. <https://doi.org/10.1590/0034-7167-2021-0898>
17. American Nurses Association. Defining staffing: workforce management patient classification and acuity systems. The request for proposal process [Internet]. Silver Spring, MD: ANA; 2017 [cited 2022 Feb 11]. Available from: https://www.nursingworld.org/~497e37/globalassets/practiceandpolicy/work-environment/nurse-staffing/website-staffing-and-acuity-systems-pdf-final_2017.pdf
18. Sarker IH. Machine learning: algorithms, real-world applications and research directions. *SN Comput Sci*. 2021;2(160):1-21. <https://doi.org/10.1007/s42979-021-00592-x>
19. Fayyad U, Piatetsky-Shapiro G, Smyth P. From data mining to knowledge discovery in databases. *AI Mag*. 1996;17(3):37-54. <https://doi.org/10.1609/aimag.v17i3.1230>
20. Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, et al. Scikit-learn: Machine Learning in Python. *J Mach Learn Res*. 2011;12:2825-30. <https://www.jmlr.org/papers/volume12/pedregosa11a/pedregosa11a.pdf>

21. Breiman L. Random Forests. *Mach Learn.* 2001;45:5-32. <https://doi.org/10.1023/A:1010933404324>
22. Abraham A, Pedregosa F, Eickenberg M, Gervais P, Mueller M, Kossaifi J, et al. Machine learning for neuroimaging with scikit-learn. *Front Neuroinform.* 2014;8(14):1-10. <https://doi.org/10.3389/fninf.2014.00014>
23. Nahm FS. Receiver operating characteristic curve: overview and practical use for clinicians. *Korean J Anesthesiol.* 2022;75(1):25-36. <https://doi.org/10.4097/kja.21209>
24. Dataiku. Method for computing multiclass ROC AUC [Internet]. New York, NY: DSS; 2023 [cited 2023 June 20]. Available from: https://doc.dataiku.com/dss/latest/_downloads/cf297152034aae9c6b1a54069289c435/multiclass-roc-auc.pdf
25. Buffon MR, Severo IM, Mergen T, Rosa NG, Almeida MA, Lucena AF. Correspondence between NANDA International nursing diagnoses and Perroca's patient classification. *Rev Min Enferm.* 2021;25:e-400. <https://doi.org/10.5935/1415-2762-20210048>
26. Perroca MG, Gaidzinski RR. Sistema de classificação de pacientes: construção e validação de um instrumento. *Rev Esc Enferm USP.* 1998;32(2):153-68. <https://doi.org/10.1590/S0080-62341998000200009>
27. Horta WA. *Processo de Enfermagem.* São Paulo: Guanabara Koogan; 2011.
28. Safavi KC, Khaniyev T, Copenhaver M, Seelen M, Langle ACZ, Zanger J, et al. Development and Validation of a Machine Learning Model to Aid Discharge Processes for Inpatient Surgical Care. *JAMA Netw Open.* 2019;2(12):e1917221. <https://doi.org/10.1001/jamanetworkopen.2019.17221>
29. Ende E, Schouten B, Pladet L, Merten H, Galen L, Marinova M, et al. Leaving the hospital on time: hospital bed utilization and reasons for discharge delay in the Netherlands. *Int J Qual Health Care.* 2023;35(2):mzad022. <http://doi.org/10.1093/intqhc/mzad022>
30. Moller G, Magalhães AMM. Bed Bath: Nursing Staff Workload and Patient Safety. *Texto Contexto Enferm.* 2015;24(4):1044-52. <https://doi.org/10.1590/0104-0707201500003110014>
31. Dykes PC, Burns Z, Adelman J, Benneyan, J, Bogaisky M, Carter E, et al. Evaluation of a Patient-Centered Fall-Prevention Tool Kit to Reduce Falls and Injuries A Nonrandomized Controlled Trial. *JAMA Netw Open.* 2020;3(11):e2025889. <https://doi.org/10.1001/jamanetworkopen.2020.25889>
32. Severo IM, Kuchenbecker RS, Vieira DFVB, Lucena AF, Almeida MA. Risk factors for fall occurrence in hospitalized adult patients: a case-control study. *Rev. Latino-Am. Enfermagem.* 2018;26:e3016. <https://doi.org/10.1590/1518-8345.2460.3016>
33. Quadros DV, Lima JS, Kreling A, Pereira APL, Barbosa AS, Magalhães AMM. Occurrence of falls in clinical-surgical units and the degree of care complexity. *Res Soc Dev.* 2022;11(14):e362111436411. <https://doi.org/10.33448/rsd-v11i14.36411>
34. Luzia MF, Vidor ID, Eilert, ACF, Lucena, AF. Falls prevention in hospitalized patients: evaluation through the nursing outcomes classification/NOC. *Appl Nurs Res.* 2020;54:151273. <https://doi.org/10.1016/j.apnr.2020.151273>
35. Montejano-Lozoya R, Miguel-Montoya I, Gea-Caballero V, Mármol-López MI, Ruíz-Hontangas A, Ortí-Lucas R. Impact of Nurses' Intervention in the Prevention of Falls in Hospitalized Patients. *Int J Environ Res Public Health.* 2020;17(17):6048. <https://doi.org/10.3390/ijerph17176048>
36. Kim J, Lee E, Jung Y, Kwon S. Patient-level and organizational-level factors influencing in-hospital falls. *J Adv Nurs.* 2022;78:3641-51. <http://doi.org/10.1111/jan.15254>
37. Severo IM, Kuchenbecker R, Vieira DFVB, Pinto LRC, Hervé MEW, Lucena AF, et al. A predictive model for fall risk in hospitalized adults: A case-control study. *J Adv Nurs.* 2019;75(3):563-72. <https://doi.org/10.1111/jan.13882>
38. Li Z, Lin F, Thalib L, Chaboyer W. Global prevalence and incidence of pressure injuries in hospitalized adult patients: a systematic review and meta-analysis. *Int J Nurs Stud.* 2020;105:103546. <https://doi.org/10.1016/j.ijnurstu.2020.103546>
39. Chung ML, Widdel M, Kirchhoff J, Sellin J, Jelali M, Geiser F, et al. Risk factors for pressure injuries in adult patients: a narrative synthesis. *Int J Environ Res Public Health.* 2022;19(2):761. <https://doi.org/10.3390/ijerph19020761>
40. Huang C, Ma Y, Wang C, Jiang M, Foon LY, Lv L, et al. Predictive validity of the braden scale for pressure injury risk assessment in adults: A systematic review and meta-analysis. *Rev Nurs Open.* 2021;8(5):2194-207. <https://doi.org/10.1002/nop2.792>
41. Nakagami G, Yokota S, Kitamura A, Takahashi T, Morita K, Nogushi H, et al. Supervised machine learning-based prediction for in-hospital pressure injury development using electronic health records: a retrospective observational cohort study in a university hospital in Japan. *Int J Nurs Studies.* 2021;119:103932. <https://doi.org/10.1016/j.ijnurstu.2021.103932>

Contribuição dos autores

Concepção e desenho da pesquisa: Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena.

Obtenção de dados: Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena. **Análise e interpretação dos dados:** Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena. **Análise estatística:** Ninon Girardon da Rosa, Tiago Andres Vaz,

Amália de Fátima Lucena. **Redação do manuscrito:** Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena. **Revisão crítica do manuscrito quanto ao conteúdo intelectual importante:** Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena.

Todos os autores aprovaram a versão final do texto.

Conflito de interesse: os autores declararam que não há conflito de interesse.

Recebido: 03.11.2023
Aceito: 13.03.2024

Editora Associada:
Andrea Bernardes

Copyright © 2024 Revista Latino-Americana de Enfermagem
Este é um artigo de acesso aberto distribuído sob os termos da Licença Creative Commons CC BY.

Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original. É a licença mais flexível de todas as licenças disponíveis. É recomendada para maximizar a disseminação e uso dos materiais licenciados.

Autor correspondente:

Ninon Girardon da Rosa

E-mail: ninongrosa@gmail.com

 <https://orcid.org/0000-0001-5701-0494>