

Carga de trabajo de enfermería: uso de inteligencia artificial para el desarrollo de modelo clasificador*

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>

Destacados: (1) Desarrollo de modelo clasificador predictivo de la carga de trabajo de enfermería. (2) Identificación de las principales variables que generan carga de trabajo de enfermería. (3) Posibilidad de automatización de la evaluación de la carga de trabajo de enfermería. (4) Calificación de la gestión asistencial. (5) Contribución en los estudios de dimensionamiento de personal.

Objetivo: describir el desarrollo de un modelo clasificador predictivo de la carga de trabajo de enfermería, utilizando inteligencia artificial.

Método: estudio observacional retrospectivo, en fuentes secundarias de registros electrónicos de pacientes, con uso de aprendizaje automático. La muestra por conveniencia se constituyó de 43.871 evaluaciones realizadas por enfermeras asistenciales con el Sistema de Clasificación de Pacientes de Perroca, que sirvieron como patrón oro, y datos clínicos del expediente electrónico de 11.774 pacientes, que constituyeron las variables. Para la organización de los datos y la realización de los análisis se utilizó la plataforma de ciencia de datos Dataiku®. El análisis de los datos ocurrió de forma exploratoria, descriptiva y predictiva. Estudio aprobado por el Comité de Ética e Investigación de la institución campo del estudio. **Resultados:** el uso de inteligencia artificial posibilitó el desarrollo del modelo clasificador de evaluación de la carga de trabajo de enfermería, identificando las variables que más contribuyeron para su predicción. El algoritmo clasificó correctamente el 72% de las variables y el área bajo la curva *Receiver Operating Characteristic* fue del 82%. **Conclusión:** hubo el desarrollo de un modelo predictivo, demostrando que es posible entrenar algoritmos con datos del expediente electrónico del paciente para predecir la carga de trabajo de enfermería y que las herramientas de inteligencia artificial pueden ser efectivas para la automatización de esta actividad.

Descriptor: Enfermería; Carga de Trabajo; Informática Aplicada a la Enfermería; Expedientes Electrónicos de Salud; Inteligencia Artificial; Aprendizaje Automático.

* La publicación de este artículo en la Serie Temática "Salud digital: aportes de enfermería" es parte de la Actividad 2.2 del Término de Referencia 2 del Plan de Trabajo del Centro Colaborador de la OPS/OMS para el Desarrollo de la investigación en Enfermería, Brasil. Artículo parte de la tesis de doctorado "Modelo clasificador predictivo para la evaluación de la carga de trabajo de enfermería: un análisis secundario de Big Data", presentada en la 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, Países Bajos.

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

⁵ Becaria del Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Brasil.

Cómo citar este artículo

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>

Introducción

La carga de trabajo en enfermería se caracteriza por la demanda de trabajo requerida de los profesionales de enfermería en las actividades de cuidado al paciente⁽¹⁾. Existen sistemas de clasificación que categorizan a los pacientes de acuerdo con la cantidad, complejidad y tiempo dedicado para el cuidado. Varios sistemas de clasificación se utilizan en el mundo, no existiendo una base científica para que un sistema tenga preferencia sobre otro, pero todos buscan estimar la carga de trabajo, proporcionando parámetros para la planificación de los recursos asistenciales necesarios⁽²⁾.

En Brasil, el Sistema de Clasificación de Pacientes (SCP) de Perroca se utiliza para pacientes adultos hospitalizados en unidades de internación. Se consideran nueve áreas de cuidado en su evaluación: planificación y coordinación del proceso de cuidar, investigación y monitoreo, cuidado corporal y eliminaciones, cuidados con piel y mucosas, nutrición e hidratación, locomoción y actividad, terapéutica, soporte emocional y educación a la salud. Cada indicador posee una graduación de 1 a 4, indicando la complejidad creciente del cuidado. Estos valores sumados conducen a la clasificación en una de las cuatro categorías de cuidados: mínimos, intermedios, semi-intensivos e intensivos, que determinan el grado de dependencia del paciente respecto a los cuidados de enfermería⁽³⁾.

La evaluación continua de la carga de trabajo trae implicaciones positivas al manejo del proceso de trabajo de los enfermeros, aunque tenga un grado de subjetividad y exija tiempo dedicado para la aplicación de los instrumentos, en medio de tantas asignaciones asistenciales y gerenciales desarrolladas⁽⁴⁾. Este contexto demuestra la importancia del perfeccionamiento de este proceso, pues la evaluación de la carga de trabajo proporciona parámetros para el dimensionamiento de personal de las instituciones brasileñas de salud⁽⁵⁾. Un cuadro de personal equilibrado permite la realización de cuidados esenciales a los pacientes, la prevención de eventos adversos, además de seguridad a los profesionales y satisfacción en el trabajo⁽²⁾.

En los hospitales, la inversión creciente en el Prontuario Electrónico del Paciente (PEP) permite la sistematización de los datos provenientes de los registros de los atendimientos de los profesionales y la utilización de técnicas innovadoras de procesamiento ágil de grandes volúmenes de datos clínicos y análisis predictivos, además del desarrollo de herramientas que automatizan actividades⁽⁶⁾.

Así, la aproximación de los enfermeros con la ciencia de datos amplía las posibilidades de desarrollar soluciones innovadoras, con información útil, extraída de los bancos de datos⁽⁷⁾, principalmente en las instituciones donde hay

un ambiente favorable a la informatización de todas las etapas del Proceso de Enfermería (PE), lo que promueve la sistematización de datos y uso de lenguaje estandarizado, tales como los Diagnósticos de Enfermería (DEs) de NANDA Internacional (NANDA-I)⁽⁸⁾ y las intervenciones y actividades de la Clasificación de las Intervenciones de Enfermería (NIC)⁽⁹⁾.

Los bancos de datos analíticos introducen los conceptos relacionados a volúmenes de datos, velocidad, variedad, veracidad y valor, que caracterizan la definición de *Big Data*, demostrando identidad con este contexto dinámico de los hospitales, que se están beneficiando del desarrollo de sistemas inteligentes⁽⁷⁾.

La Inteligencia Artificial (IA) demuestra comportamiento inteligente y puede desarrollar actividades con algún grado de autonomía para alcanzar objetivos específicos, por ello su uso en enfermería puede ofrecer asertividad de datos y reducción en el tiempo de trabajo⁽¹⁰⁾.

Las técnicas de IA, como el aprendizaje automático, asisten en las respuestas a los problemas de enfermería y los enfermeros comprometidos en esta discusión mundial elevan la calidad de la práctica y de la gestión asistencial y tienen mucho que contribuir en el desarrollo de sistemas informatizados y desarrollo de modelos predictivos⁽¹⁰⁾.

Estos avances han sido impulsados por estudios multidisciplinarios con profesionales de la salud y científicos de datos, que buscan desarrollar modelos que atiendan a la complejidad del ambiente hospitalario^(7,10-11).

Aunque los hospitales brasileños necesitan enfrentar desafíos relacionados con la infraestructura tecnológica, sistematización de datos e interoperabilidad entre sistemas para la utilización de las herramientas de IA, el liderazgo de los enfermeros tiene un papel fundamental en la búsqueda de innovaciones y en el desarrollo de competencias, para que los profesionales del área puedan estar preparados para un mundo cada vez más informatizado⁽¹¹⁾.

La aplicación de la IA en ambientes de cuidado de enfermería es reciente y ha sido explorada principalmente en los hospitales, en procesamiento de imágenes y señales, en clasificación de actividades de enfermería, en la comunicación de cuidados y en la detección de caídas. La identificación de otras áreas de aplicación de esta técnica puede generar importantes contribuciones para la enseñanza, para la investigación y para la práctica de enfermería⁽¹²⁾.

En lo que respecta a la evaluación de carga de trabajo de enfermería, en revisión de la literatura, no se encontraron estudios brasileños que apliquen IA para la realización de esta medición. Escasas publicaciones internacionales tratan la utilización de instrumentos automatizados⁽¹³⁻¹⁵⁾, sin embargo, no hay mención sobre el uso de datos generados por el PE, que es una metodología

de referencia para la organización de la asistencia y de los registros de enfermería⁽¹⁶⁾.

La Asociación Norteamericana de Enfermería (ANA) estimula el desarrollo de sistemas de evaluación de carga de trabajo de enfermería automatizados, destacando la importancia del fundamento científico y de la capacidad de integración con las plataformas institucionales. La ANA resalta que los instrumentos deben ser simples y eficientes, para traducir la realidad de cada local y no generar carga de trabajo adicional a los enfermeros, pero necesitan ser validados y sus resultados monitoreados a fin de ofrecer predicciones correctas sobre las necesidades de los equipos y de los pacientes⁽¹⁷⁾. La operacionalización de estas recomendaciones depende del desarrollo de investigaciones conjuntas entre profesionales de la salud y científicos de datos, de manera a superar esta brecha de conocimientos y las eventuales debilidades en el uso de datos secundarios y IA⁽¹⁷⁾.

Basándose en estas ideas y en la carencia de investigaciones sobre el tema, este artículo tiene como objetivo describir el desarrollo de un modelo clasificador predictivo de la carga de trabajo de enfermería, utilizando IA.

Método

Tipo de estudio

Se trata de un estudio observacional retrospectivo, en fuentes secundarias de registros electrónicos de pacientes, con la elaboración de un modelo clasificador predictivo con técnicas supervisadas de Aprendizaje Automático (AA)⁽¹⁸⁾.

Escenario del estudio

El estudio se llevó a cabo de 2021 a 2023, en un hospital público universitario de gran tamaño, con atención a pacientes de alta complejidad. La institución está acreditada internacionalmente en estándares de calidad y seguridad y tiene como pilares la asistencia, la enseñanza y la investigación de excelencia e innovación. El hospital desarrolló su propio sistema informatizado en la década de los 80, el cual ha sido mejorado desde entonces. El PE y los instrumentos de evaluación de carga de trabajo ya están incorporados, pero no poseen interoperabilidad entre sí.

Logística de los datos

Los investigadores utilizaron las etapas del proceso de *Knowledge Discovery in Databases* (KDD)⁽¹⁸⁾ como guía en la logística de los datos: selección, pre-procesamiento, transformación y minería de datos e

interpretación de resultados. El KDD⁽¹⁹⁾ es un proceso para identificar patrones consistentes en grandes cantidades de datos y descubrir información relevante para apoyar decisiones estratégicas.

Estructuración de la base de datos analítica

La estructuración de la base de datos analítica implica selección, pre-procesamiento y transformación de los datos⁽¹⁹⁾.

En la etapa de selección se definió los datos del estudio, que fueron organizados en dos conjuntos, seguido de la recolección de datos y la importación de los mismos a la plataforma de ciencia de datos Dataiku®, asociada al *software* de procesamiento de *Big Data* PostgreSQL®, que permitió el manejo de la base de datos y la relación de datos complejos entre sí.

El primer conjunto de datos se organizó a partir de 107.507 evaluaciones de pacientes realizadas por enfermeras asistenciales de doce unidades de internación clínico-quirúrgicas, en el período de 2015 a 2019, utilizando el SCP de Perroca⁽³⁾. Estos datos corresponden a los puntajes de los pacientes y las respectivas clasificaciones en las categorías de cuidados mínimos, intermedios, semi-intensivos e intensivos. Las hojas de cálculo contenían el número de la cama del paciente y la fecha de la evaluación. Los datos fueron recolectados por los investigadores directamente de las hojas de cálculo informatizadas del sistema de la institución y fueron organizados en una sola hoja de cálculo para ser usados como patrón oro.

El segundo conjunto se organizó a partir de datos extraídos del PEP de pacientes internados en las mismas unidades, en el mismo período que el primer conjunto de datos. La solicitud de consulta a los expedientes (*query*) fue planificada en reuniones con el analista de Tecnología de la Información (TI) que realiza esa actividad en la institución, considerando las variables en estudio. Así, en cada *query* se solicitó una variable representativa de la carga de trabajo de enfermería, basada en las nueve áreas de cuidado del SCP de Perroca⁽³⁾: cuidados de enfermería, diagnósticos de enfermería, registros de los signos vitales, prescripciones de dieta, prescripción de medicamentos, prescripción de soluciones, prescripción de hemoterapia, prescripción de oxigenoterapia, solicitudes de exámenes recogidos por la enfermería, solicitudes de consultorías por especialistas y existencia de conductas educativas a pacientes y familiares.

En todas las *queries* también se solicitaron las variables edad, sexo, escolaridad, fecha de internación y los identificadores número de la cama y del expediente. Así, el estudio contempló 15 diferentes variables, que se

ampliaron, considerando sus estratificaciones, como por ejemplo: los cuidados de enfermería totalizaron 846 y los diagnósticos de enfermería totalizaron 189 variables. Los datos disponibles en tablas fueron referentes a 58.888 pacientes internados. Entre estos, se seleccionaron aquellos que estaban registrados en la misma cama y en la misma fecha de internación que los pacientes del primer conjunto de datos, lo que resultó en 11.774 pacientes.

No se incluyeron en el modelo datos anteriores a 2015, por no haber registros sistematizados de evaluación de los pacientes con el SCP de Perroca y datos posteriores a 2019, porque los procesos asistenciales fueron alterados durante la pandemia causada por el coronavirus.

En la etapa de preprocesamiento, los investigadores realizaron revisión y limpieza para garantizar la calidad de los datos.

Para el primer conjunto de datos, los criterios de exclusión adoptados fueron: pacientes diferentes que tenían evaluaciones con SCP de Perroca⁽³⁾ el mismo día y estaban registrados en la misma cama, porque hubo duda si la evaluación registrada era del paciente que salió o del que entró en la cama; paciente con dos evaluaciones diferentes el mismo día y que estaba registrado en la misma cama, debido a la posibilidad de error al registrar la cama del paciente o por la posibilidad de ser un segundo registro relativo al mismo paciente para corregir un error de evaluación, en lugar de la corrección haber sido realizada en el primer registro; pacientes con menos de 48 horas de internación en el momento de la evaluación, pues se infería que estos pacientes tendrían menos chances de exponerse a las variables establecidas para el análisis. Tras aplicar estos criterios en el conjunto de 107.507 evaluaciones se obtuvieron 43.871 evaluaciones para el estudio.

En relación con el segundo conjunto de datos, la etapa de preprocesamiento exigió bastante tiempo y dedicación de los investigadores en la revisión, sin embargo, la reorganización de tablas no implicó en alteración del número de pacientes, corroborando los 11.774 pacientes.

Los datos de los dos conjuntos fueron importados a la plataforma de ciencia de datos Dataiku® a medida que fueron siendo disponibles.

En la etapa de transformación, los datos brutos fueron procesados para tener uniformidad y ser minados con técnicas de AM, en busca de patrones y relaciones en el gran conjunto de datos (*Big Data*).

Minería de los datos

La minería de datos es el proceso de analizar grandes conjuntos de datos para identificar patrones y extraer información que genera conocimientos y apoya

decisiones⁽¹⁹⁾. En la minería de datos se usan algoritmos de AM, que definen la secuencia de los procedimientos por medio de instrucciones matemáticas automatizadas⁽¹⁸⁾. Este estudio se desarrolló en el lenguaje *Python*, con el módulo de algoritmos de clasificación del paquete *Scikit-learn*⁽²⁰⁾. El algoritmo aplicado fue el *Random Forest* (RF), caracterizado por una combinación de predictores que se desarrollan en forma de árboles de decisión y se distribuyen en las clases conforme el grado de pureza y de homogeneidad⁽²¹⁾.

En el desarrollo del modelo predictivo se utilizó la técnica de validación cruzada *k-fold* ($k=5$), con división de la base de datos analítica en k particiones para que el modelo sea entrenado en $k-1$ particiones y validado en la partición restante. Este procedimiento fue repetido, alternando la partición de los datos de entrenamiento⁽²²⁾, buscando acertar la clase de cuidados de los pacientes (mínimo, intermedio, intensivo, semi-intensivo).

El proceso incluyó estrategias para garantizar la calidad de las etapas: mejoras en los parámetros del algoritmo RF, los cuales alcanzaron una composición final de 1000 árboles, con seis capas de profundidad⁽²¹⁾, y verificaciones para evitar el *overfitting* (ajuste excesivo que ocurre cuando el modelo de aprendizaje de máquina proporciona predicciones precisas solo para datos de entrenamiento, como si el modelo no fuera capaz de generalizar para otros datos no vistos) y el *data leakage* (compartimiento de datos entre las fases de entrenamiento y validación). Estos ajustes elevaron la precisión hasta el punto de saturación de desempeño de las métricas del modelo⁽²²⁾.

Las métricas evaluadas resultaron de la matriz de confusión (precisión, sensibilidad, F1 score y precisión) y del desempeño de la curva ROC (*Receiver Operating Characteristic*) y de la AUC-ROC (*Area Under The ROC Curve*)⁽²²⁾.

La importancia de cada variable para la clasificación final de la carga de trabajo de enfermería fue conocida en la fase de predicción del modelo⁽²³⁾.

Análisis de los datos

Para el análisis de datos se utilizó la plataforma de ciencia de datos Dataiku® y el *software* de procesamiento de *Big Data* PostgreSQL®. El análisis exploratorio se realizó en todas las etapas de la investigación para la comprensión de los datos y de las relaciones entre las variables⁽¹⁹⁾. El análisis descriptivo se utilizó para detallar las características de los conjuntos de datos y los resultados de las variables se presentaron en frecuencia relativa. El análisis predictivo ocurrió en la fase de interpretación de los resultados, permitiendo explorar

las relaciones entre variables de eventos anteriores y variables previstas en el modelo desarrollado, y conocer el desempeño de las métricas correspondientes⁽¹⁸⁾.

Aspectos éticos

El estudio fue aprobado por el Comité de Ética e Investigación institucional (2021-0521) y registrado en la *Plataforma Brasil* (55207921.50000.5327). Se adoptaron las recomendaciones del Término de Compromiso de Uso de Datos por parte de los investigadores y se dispuso el uso del Término de Consentimiento Informado.

Resultados

Caracterización de las evaluaciones de los pacientes realizadas por enfermeras con el SCP de Perroca, referente al primer conjunto de datos

Las evaluaciones realizadas por las enfermeras comprendieron 43.871 registros. La mayoría de los pacientes está en la clase de cuidados semi-intensivos (50,61%), seguida de la clase de cuidados intermedios (31,25%). La edad promedio es de 61 años [Desviación

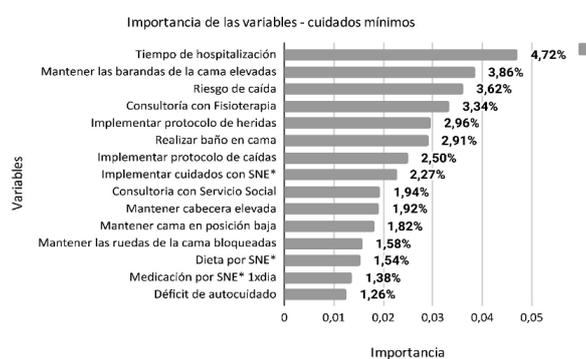
Estándar (DE)±16,4], el 50,08% son de sexo masculino y el 52,77% poseen educación primaria.

Caracterización de los pacientes de quienes se extrajeron datos de los expedientes electrónicos para componer las variables del segundo conjunto de datos

Los pacientes internados en las unidades clínico-quirúrgicas se caracterizaron por 11.774 personas, con una edad promedio de 61,6 años (DE ±16,7), el 50,95% son de sexo masculino y el 54,39% tienen educación primaria.

Importancia de las variables en el modelo predictor de evaluación de la carga de trabajo de enfermería

El algoritmo RF fue entrenado para clasificar las variables en las cuatro clases de cuidados del SCP de Perroca⁽³⁾. El número total de variables que componen cada clase es diferente: 574 para mínimos, 701 para intermedios, 731 para semi-intensivos y 692 para intensivos. En este artículo se presentan las 15 variables más importantes para cada clase, según el grado de importancia en el modelo, conforme a las Figuras 1, 2, 3 y 4.



*SNE = Sonda Nasoenteral

Figura 1 - Descripción de la importancia de las variables en la clase de cuidados mínimos del modelo predictor de evaluación de la carga de trabajo de enfermería (n = 574). Porto Alegre, RS, Brasil, 2023



*SNE = Sonda Nasoenteral

Figura 2 - Descripción de la importancia de las variables en la clase de cuidados intermedios del modelo predictor de evaluación de la carga de trabajo de enfermería (n = 701). Porto Alegre, RS, Brasil, 2023

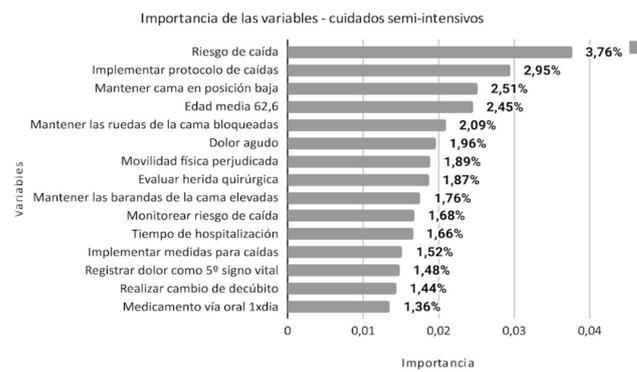


Figura 3 - Descripción de la importancia de las variables en la clase de cuidados semi-intensivos del modelo predictor de evaluación de la carga de trabajo de enfermería (n = 731). Porto Alegre, RS, Brasil, 2023



*SNE = Sonda Nasoenteral

Figura 4 - Descripción de la importancia de las variables en la clase de cuidados intensivos del modelo predictor de evaluación de la carga de trabajo de enfermería (n = 692). Porto Alegre, RS, Brasil, 2023

Métricas de evaluación del desempeño del modelo clasificador

A partir de las clasificaciones de las variables, el modelo buscó identificar las predicciones positivas correctas. Los resultados de las métricas están demostrados en la Tabla 1.

Todas las métricas tuvieron excelentes desempeños en la clase de cuidados intermedios (0,962), seguida

de la clase de cuidados mínimos (0,917). Esto significa que el algoritmo hizo una buena distinción de los cuidados requeridos para los pacientes de estas dos clases. Las clases de cuidados semi-intensivos (0,759) e intensivos (0,791) tuvieron menores resultados. Los modelos con desempeño entre $0,8 < 0,9$ se consideran buenos y aquellos con desempeño $\geq 0,9$ son excelentes⁽²¹⁾.

Tabla 1 - Métricas de evaluación del desempeño del modelo clasificador predictivo de la carga de trabajo de enfermería, según la clasificación en cuidados mínimos, intermedios, semi-intensivos e intensivos del SCP* de Perroca. Porto Alegre, RS, Brasil, 2023

SCP* Perroca	Exactitud	Sensibilidad	Precisión	F1 Score†	AUC- ROC‡
Mínimos	0,990	0,715	0,849	0,776	0,917
Intermedios	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 Clasificación de Pacientes de Perroca; †F1 Score = Function 1 Score; ‡AUC-ROC = Area Under The Receiver Operating Characteristic Curve

Los valores del modelo final están basados en el enfoque *Multiclass Area Under the Curve*, que clasificó las cuatro clases al mismo tiempo y presentó una DE de $\pm 0,036$ ⁽²¹⁻²⁴⁾.

De forma global, el algoritmo RF clasificó correctamente el 72% de las variables del modelo y la AUC-ROC indicó que el modelo tuvo un desempeño del 82% en la clasificación general de los pacientes en las diferentes categorías de cuidados⁽²¹⁾.

Discusión

Se observa que la mayoría de los pacientes evaluados con el SCP de Perroca⁽³⁾ son personas mayores, con educación primaria y pertenecen a la clase de cuidados semi-intensivos. También se identifica que, en la clasificación de los registros del PEP, el algoritmo RF seleccionó variables similares para componer las clases de cuidados, sin embargo, les atribuyó diferentes grados de importancia. Los cuidados de enfermería fueron las variables más expresivas en todas las clases, reforzando el fenómeno investigado: la clasificación de la carga de trabajo de enfermería, que tiene en su esencia la caracterización de la demanda de trabajo requerida de estos profesionales en las actividades diarias de cuidado al paciente⁽¹⁾.

En la práctica clínica de la institución en estudio, estos cuidados prescritos derivan de los diagnósticos realizados por los enfermeros, los cuales se basan en el sistema de lenguaje estandarizado de NANDA-I⁽⁸⁾ y se relacionan con el constructo del SCP de Perroca, fundamentado en la identificación de las necesidades de cuidados a los pacientes⁽³⁾. Un estudio comparativo entre los DEs y las áreas de cuidado del SCP de Perroca, en el mismo escenario, constató correspondencia entre ambos en al menos una área de cuidado del instrumento, demostrando que los DEs pueden indicar, además de las necesidades de cuidado, el grado de complejidad del cuidado y la dependencia del equipo de enfermería, siendo guías importantes en la gestión del cuidado⁽²⁵⁾.

Otro aspecto relevante a destacar es la característica de los pacientes del estudio, cuando se compara con la definición de cada clase de cuidado del SCP de Perroca, pues en todas ellas hay variables propias de pacientes dependientes de la enfermería, probablemente debido a la predominancia de personas mayores, lo que refuerza la importancia de los cuidados de enfermería en atención a las necesidades humanas básicas. Este referencial, preconizado en estudios sobre el PE en Brasil, también fundamentó el SCP de Perroca, visto que las necesidades humanas básicas son fenómenos vitales para los seres

humanos y, por lo tanto, definidos como entes concretos de la Ciencia de Enfermería⁽²⁶⁻²⁷⁾.

En la clase de cuidados mínimos, donde, conceptualmente, los pacientes están estables desde el punto de vista clínico y físicamente autosuficientes en cuanto a sus necesidades humanas básicas⁽³⁾, el tiempo de internación (período entre la fecha de internación en la unidad hasta la fecha de su evaluación con el SCP de Perroca) fue la variable más importante (4,72%), sugiriendo que, incluso para pacientes que teóricamente requieren menos cuidados, el aumento del tiempo de hospitalización puede generar carga de trabajo para el equipo de enfermería.

Llama la atención que la variable de consultoría al servicio social también se destaca, confirmando un perfil de pacientes que, además de cuidados directos de enfermería, poseen problemas que demandan abordajes del equipo multiprofesional, con intervenciones que facilitan la interfaz entre el sistema de cuidados a la salud con el paciente y la familia. Esto demanda una organización que se relaciona directamente con el tiempo de internación del paciente⁽⁹⁾.

Un estudio estadounidense, que desarrolló un modelo de AM para mejorar el proceso de alta hospitalaria, identificó como principales barreras potenciales al alta: el paciente que no tiene dieta oral regular, la indisponibilidad de servicios de visita domiciliaria y la falta de apoyo social⁽²⁸⁾. Un estudio europeo sobre causas de retraso en el alta hospitalaria refiere, entre los múltiples factores contribuyentes, las dificultades en la transición de cuidados del hospital al hogar o a instituciones de larga estancia⁽²⁹⁾.

Otras variables surgieron en esta clase de cuidados, pero las características de los pacientes no reflejan la definición de Perroca⁽³⁾, porque son diagnósticos y cuidados de enfermería típicos de pacientes dependientes y, aunque fueron clasificados como pertenecientes a la clase de cuidados mínimos, las variables se repiten en las demás clases de cuidados. Ejemplos de esto son el Diagnóstico de Enfermería (DE) déficit de autocuidado⁽⁸⁾, indicando incapacidad para realizar las actividades rutinarias de la vida diaria, tales como alimentación y baño; los cuidados de enfermería relacionados con los dominios fisiológico básico⁽⁹⁾ (realizar baño en cama, implementar cuidados con sonda nasointestinal) y fisiológico complejo⁽⁹⁾ (implementar protocolo de prevención de tratamiento de heridas); además de la consultoría con fisioterapia.

El DE riesgo de caídas⁽⁸⁾, junto con los cuidados del dominio seguridad de los pacientes⁽⁹⁾ (mantener las barreras de la cama elevadas, implementar protocolo de prevención de caídas, mantener la cama en posición baja, mantener las ruedas de la cama bloqueadas) representan

intervenciones de protección contra la ocurrencia de daños, que en menor o mayor grado forman parte de los cuidados universales para los pacientes hospitalizados.

La clase de cuidados intermedios se constituye de pacientes estables bajo el punto de vista clínico y de enfermería, con dependencia parcial de las acciones de enfermería para la atención de las necesidades humanas básicas⁽³⁾. En esta clase, la variable que se mostró más importante fue el cuidado de enfermería realizar baño en cama (8,34%), que, asociado con los cuidados realizar higiene después de la evacuación y utilizar pañal desechable, componen cuidados de higiene corporal que demandan esfuerzo físico para movilizar al paciente y cambiar la ropa de cama, pudiendo ocasionar cansancio y lesiones osteomusculares, incluso en los casos en que los profesionales realizan la actividad en pareja⁽³⁰⁾.

El baño en cama, al tratarse de un cuidado fisiológico básico⁽⁹⁾, forma parte de las actividades diarias del equipo de enfermería y, dependiendo del dimensionamiento de personal y de las condiciones de infraestructura del ambiente, sobrecarga al equipo que realiza esta acción⁽³⁰⁾.

Entre los demás cuidados que se destacaron están los fisiológicos complejos⁽⁹⁾, relacionados con el DE riesgo de lesión por presión⁽⁸⁾: implementar protocolo de prevención y tratamiento de heridas, proteger la piel y las prominencias óseas, realizar cambio de decúbito e inspeccionar la piel en busca de hiperemia e isquemia⁽⁹⁾.

La clase de cuidados semi-intensivos presupone cuidados a pacientes crónicos, estables bajo el punto de vista clínico, pero con total dependencia de las acciones de enfermería en cuanto a la atención de las necesidades humanas básicas⁽³⁾.

En la clasificación realizada por las enfermeras con el SCP de Perroca, 22.106 pacientes fueron clasificados con necesidad de cuidados semi-intensivos, cerca del 50% del primer conjunto de datos.

Al aplicar el algoritmo RF en el segundo conjunto de datos, la variable principal fue el DE riesgo de caída⁽⁸⁾ (3,76%) y varios cuidados relacionados con él⁽⁹⁾. La prevención de caídas es la sexta meta internacional de seguridad, dadas sus altas tasas de incidencia, que corresponden a dos de cada cinco eventos adversos⁽³¹⁾. Las causas de caídas en hospitales son multifactoriales⁽³²⁾ y se relacionan con las demás variables importantes de esta clase de cuidados, tales como la edad media de 62,6, los DE dolor agudo y movilidad física comprometida y los cuidados de enfermería relativos a la herida quirúrgica. Estas variables remiten a los factores de riesgo de la limitación para caminar en el período postoperatorio, los cuales también fueron constatados en diferentes estudios⁽³²⁻³⁶⁾.

La naturaleza de las actividades de enfermería al lado del lecho justifica la preocupación de los profesionales en planificar y ejecutar estrategias de prevención de caídas, aplicando protocolos de seguridad recomendados por órganos gubernamentales nacionales e internacionales, con la asignación de un equipo dedicado a la gestión de riesgos asistenciales, además de estudios sobre el tema⁽³⁷⁾. Además, se sabe que el dimensionamiento adecuado de personal y la capacitación de los equipos para la prevención de caídas también influyen en la incidencia de este tipo de evento⁽³⁵⁾.

La clase de cuidados intensivos comprende cuidados a pacientes graves, con riesgo inminente de vida, sujetos a la inestabilidad de signos vitales, que requieren asistencia de enfermería permanente y especializada⁽³⁾. Esta definición de Perroca⁽³⁾ debe ser relativizada en este estudio, porque los pacientes con inestabilidad clínica grave no permanecen en unidades de internación. Sin embargo, por la opción de presentar las 15 principales variables de cada clase de cuidado, algunas variables no están explícitas en este artículo, tales como las prescripciones y cuidados relacionados con los signos vitales, que aparecen a partir de la vigésima variable, y que son mencionados en la definición de Perroca⁽³⁾.

El cuidado de enfermería implementar protocolo de prevención y tratamiento de heridas⁽⁹⁾ fue la variable más importante en esta clase (7,42%) y, junto con los demás cuidados fisiológicos complejos⁽⁹⁾ realizar cambio de decúbito, proteger piel y prominencias óseas e inspeccionar la piel en busca de hiperemia e isquemia, están relacionados con el DE riesgo de lesión por presión⁽⁸⁾.

Un estudio global identificó que la ocurrencia de estas lesiones es uno de los eventos adversos más frecuentes en pacientes hospitalizados en todo el mundo, con una prevalencia general del 12,8%⁽³⁸⁾ y ocurren principalmente en pacientes dependientes, con enfermedades crónicas, hospitalización prolongada, con reducción del sentido de percepción y de la movilidad y con alteraciones nutricionales⁽³⁹⁾. Estas características están fundamentadas en diversas variables que se destacaron en la clase de cuidados intensivos: en el DE síndrome de déficit de autocuidado⁽⁸⁾; en los cuidados de enfermería implementar cuidados con sonda nasointestinal, realizar baño en cama y utilizar pañal desechable; en las prescripciones médicas administrar dieta y medicamentos por sonda nasointestinal; y en la consulta con fisioterapeuta.

El riesgo de lesión por presión generalmente es determinado por escalas de predicción aplicadas por enfermeras⁽⁴⁰⁾, pero existen iniciativas de automatización de este proceso, como es el caso de un estudio japonés que desarrolló un modelo predictivo de AM para identificar precozmente el riesgo de lesión por presión, a partir de

registros en el expediente electrónico⁽⁴¹⁾. También es objetivo de este modelo eliminar la carga adicional de trabajo generada por esta actividad⁽⁴¹⁾, de manera similar a lo propuesto en nuestro estudio de modelo de evaluación de la carga de trabajo de enfermería.

Las variables que configuran las cuatro clases del modelo de evaluación de la carga de trabajo de enfermería desarrollado remiten a un contexto asistencial complejo y contemplan las nueve áreas de cuidado del SCP de Perroca⁽³⁾, sin embargo, considerando la variable más importante de cada clase, se observan algunas especificidades.

La única clase en la que las fragilidades sociales tuvieron destaque fue en los cuidados mínimos y son factores determinantes para el tiempo de hospitalización, guardando relación con las áreas de cuidado soporte emocional y educación a la salud del SCP de Perroca⁽³⁾, que requieren una coordinación de cuidados entre equipos asistenciales.

En la clase de cuidados intermedios, la variable realizar baño en cama demuestra la fuerte influencia de los cuidados fisiológicos básicos⁽⁹⁾ y la relación con el área de cuidado corporal y eliminaciones⁽³⁾.

Las clases de semi-intensivos e intensivos están dirigidas por los cuidados fisiológicos complejos⁽⁹⁾ (prevención/tratamiento de caídas y de lesiones por presión), asociándose a las áreas de locomoción y actividad y de cuidados con piel y mucosas⁽³⁾. Ambas requieren intervenciones permanentes de cuidados directos a los pacientes e indirectos, que demandan la organización del ambiente asistencial y colaboración multidisciplinar⁽³⁾.

Este modelo teórico de evaluación de la carga de trabajo de enfermería retrata la realidad de un hospital universitario de alta complejidad, lo que puede justificar las particularidades de los resultados encontrados. La singularidad de cada escenario asistencial debe considerarse para obtener modelos fiables, sabiendo que, aunque los algoritmos pueden producir predicciones y recomendaciones útiles, el conocimiento y la experiencia humana son esenciales para la toma de decisiones⁽⁶⁾.

Este estudio tiene limitaciones relacionadas con la capacidad de generalización, porque utiliza datos de pacientes de una única institución. Considerando que los conocimientos sobre aplicaciones de aprendizaje automático diseñadas para la evaluación de la carga de trabajo de enfermería son escasos, se sugiere invertir en la modelización de los datos para mejorar el desempeño del modelo, especialmente en las clases de cuidados semi-intensivos e intensivos, con el fin de que ambos alcancen al menos el 80% de clasificaciones correctas para ser considerados de buen desempeño. Para ello, será importante validar el modelo desarrollado con la recolección de datos electrónicos directamente de la

herramienta de evaluación de la carga de trabajo (SCP de Perroca), la cual fue informatizada en el sistema institucional durante la realización de este estudio, proporcionando la cualificación de los datos del patrón oro. Otra sugerencia es probar el modelo con el uso exclusivo de variables con terminologías estandarizadas, fundamentales para investigaciones que involucran ciencia de datos, tales como las taxonomías de los diagnósticos y los cuidados de enfermería (NANDA-I y NIC), lo que podría aumentar la capacidad de buscar patrones en la base de datos analítica y de comprender las clasificaciones realizadas por el modelo.

Se resalta que la replicación del estudio exige estructura tecnológica institucional, disponibilidad de plataformas de ciencias de datos y profesionales con conocimiento en esta área, además de un PE informatizado, utilizando sistema de lenguaje estandarizado. También se destaca que los modelos de clasificación de la carga de trabajo de enfermería, a pesar de ser excelentes orientadores para la gestión asistencial, nunca representarán la totalidad de necesidades de los pacientes por ser innumerables, multidimensionales e interdependientes.

Se cree que el modelo clasificador desarrollado agrega avances al conocimiento científico en enfermería, teniendo en cuenta que es el primer estudio brasileño para evaluar la carga de trabajo de enfermería, usando técnicas de IA, con datos del PEP y utilizando un SCP validado como estándar oro. El estudio es innovador, ya que ese conocimiento es incipiente en Enfermería, y estimula la automatización de procesos, cualificando la gestión asistencial.

Conclusión

En este estudio se desarrolló un modelo clasificador predictivo de la carga de trabajo de enfermería, utilizando IA. El resultado del modelo demostró que es posible entrenar algoritmos con datos del PEP para predecir la carga de trabajo de enfermería. Las variables tiempo de hospitalización, realizar baño en cama, riesgo de caída e implementar protocolo de prevención y tratamiento de heridas representaron la mayor carga de trabajo en la clasificación final del modelo, dando visibilidad a aspectos relevantes a ser considerados en la planificación de las escalas de actividades del equipo de enfermería y del dimensionamiento de personal en el contexto estudiado. El desarrollo de modelos clasificadores predictivos de la carga de trabajo de enfermería implica la posibilidad de automatizar esta actividad, haciéndola objetiva, precisa y permitiendo que los enfermeros puedan dedicar el tiempo destinado a esta evaluación a otras demandas asistenciales y gerenciales. El modelo predictivo tiene

potencial para ser aplicado en diferentes ambientes, siempre que los algoritmos sean entrenados con conjuntos de datos cualificados y que representen la realidad de cada lugar.

Agradecimientos

Agradecemos a Maria Tereza Ponz por la extracción de datos del expediente electrónico de los pacientes y a Cássia Teixeira dos Santos por la colaboración en la formatación del texto.

Referencias

- 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>
- 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>
- 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>
- 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>
- 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
- 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>
- 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>
- Herdman TH, Kamitsuru S, Lopes, CT. *NANDA International Nursing Diagnoses. Definitions and Classification*. 12th ed. New York, NY: Thieme; 2021-2023.
- Wagner C, Butcher H, Clarke M. *Nursing Interventions Classification (NIC)*. 8th ed. St. Louis, MO: Elsevier; 2022.
- 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>
- 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>
- 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>
- 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>
- The Shelford Group. Safer nursing care tool [Internet]. [place unknown]; 2019 [cited 2023 Jan 18]. Available from: <http://shelfordgroup.org/safer-nursing-care-tool/>
- 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>
- 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>
- 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
- 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>
- 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>
- 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>

Contribución de los autores

Concepción y dibujo de la pesquisa: Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena.

Obtención de datos: Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena. **Análisis e interpretación de los datos:** Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena.

Análisis estadístico: Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena. **Redacción del**

manuscrito: Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena. **Revisión crítica del manuscrito en cuanto al contenido intelectual importante:** Ninon Girardon da Rosa, Tiago Andres Vaz, Amália de Fátima Lucena.

Todos los autores aprobaron la versión final del texto.

Conflicto de intereses: los autores han declarado que no existe ningún conflicto de intereses.

Recibido: 03.11.2023
Aceptado: 13.03.2024

Editora Asociada:
Andrea Bernardes

Copyright © 2024 Revista Latino-Americana de Enfermagem

Este es un artículo de acceso abierto distribuido bajo los términos de la Licencia Creative Commons CC BY.

Esta licencia permite a otros distribuir, mezclar, ajustar y construir a partir de su obra, incluso con fines comerciales, siempre que le sea reconocida la autoría de la creación original. Esta es la licencia más servicial de las ofrecidas. Recomendada para una máxima difusión y utilización de los materiales sujetos a la licencia.

Autor de correspondencia:

Ninon Girardon da Rosa

E-mail: ninongrosa@gmail.com

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