



REVISTA DE LA FACULTAD DE CIENCIAS DE LA SALUD

Vol. 28(1):154-169, abril - julio 2025
i-ISSN 0123-7047 e-ISSN 2382-4603



Artículo original

Construcción de un prototipo de registro de caídas basado en machine learning para mayores institucionalizados

Development of a fall registration prototype based on machine learning for institutionalized older adults

Construção de um protótipo de registro de quedas baseado em machine learning para idosos institucionalizados

José Luis Dinamarca-Montecinos   
josedinamarca@gmail.com - jose.dinamarca@uv.cl
Universidad de Valparaíso. Valparaíso, Chile.
Hospital Dr. Gustavo Fricke. Viña del Mar, Chile

María Jesús Flores-Moraga  
mariajesus.flores@usm.cl - jesuflores.382@gmail.com
Universidad Técnica Federico Santa María. Valparaíso, Chile.

Roberto Alejandro Durán-Novoa  
roberto.duran@usm.cl - durannovoa@uwalumni.com
Universidad Técnica Federico Santa María. Valparaíso, Chile.

Juan Carlos Briede-Westermeyer  
juancarlos.briede@usm.cl - jcbriede@gmail.com 
Universidad Técnica Federico Santa María. Valparaíso, Chile.

INFORMACIÓN DEL ARTÍCULO:

Artículo recibido: 23 de agosto de 2024

Artículo aceptado: 31 de julio de 2025

DOI: <https://doi.org/10.29375/01237047.5165>

Cómo citar. Dinamarca-Montecinos JL, Flores-Moraga MJ, Durán-Novoa RA, Briede-Westermeyer JC. Construcción de un prototipo de registro de caídas basado en machine learning para mayores institucionalizados. MedUNAB [Internet]. 2025;28(1):154-169. doi: <https://doi.org/10.29375/01237047.5165>

RESUMEN

Introducción. Las caídas en personas mayores institucionalizadas representan un problema de salud pública subestimado, asociado a discapacidad, dependencia y mortalidad. En Chile, la ausencia de registros estandarizados en establecimientos de larga estadía para adultos mayores (ELEAM) limita la prevención efectiva. Este estudio tuvo como objetivo diseñar un prototipo de sistema digital de registro de caídas basado en aprendizaje automático, o *machine learning* (ML), para su implementación en ELEAM. **Metodología.** Se empleó la metodología de diseño de doble diamante en cuatro fases: a) identificación de actores y levantamiento de información mediante entrevistas cualitativas; b) análisis de causas y



Contribución de los autores

JLDM.

Conceptualización, redacción y preparación del borrador original. **MJFM.**

Conceptualización, visualización e investigación.

RADN. Redacción, revisión, edición y supervisión. **JCBW.** Conceptualización, redacción, revisión y edición.

priorización de ideas con matrices Analytical Hierarchy Process (AHP) y Pugh; c) diseño conceptual y generación del producto mínimo viable (PMV), y d) elaboración de prototipos para validación de usabilidad. **Resultados.** Se evidenció una gran heterogeneidad en los registros actuales y ausencia de análisis posterior de datos. Se desarrolló un PMV que incluye un formulario de registro de caídas, visualización de medidas preventivas, perfiles de usuario diferenciados y herramientas educativas. El sistema fue validado internamente por cuidadores, directivos y profesionales de salud en ELEAM. **Discusión.** El uso de ML permitiría automatizar el análisis de datos y personalizar medidas preventivas. El diseño participativo y el enfoque preventivo fueron claves para su aceptabilidad. **Conclusiones.** El prototipo desarrollado tiene potencial para optimizar el registro de caídas en ELEAM, mejorar la prevención y fortalecer la atención en personas mayores institucionalizadas.

Palabras clave:

Anciano de 80 o más Años; Aprendizaje Automático; Anciano; Informática Médica; Prevención de Accidentes; Registros Electrónicos de Salud; Inteligencia Artificial; Hogares para Ancianos.

ABSTRACT

Introduction. Falls in institutionalized older adults represent an underestimated public health problem associated with disability, dependence and mortality. In Chile, the absence of standardized records in long-term care facilities (LTCF) for older adults limits effective prevention. The objective of this study was to design a prototype of a digital fall registration system based on machine learning (ML) for its implementation in LTCF. **Methodology.** The double diamond design methodology was used in four phases: a) identifying stakeholders and gathering information through qualitative interviews; b)

analyzing causes and prioritizing ideas with an Analytical Hierarchy Process (AHP) and Pugh matrices; c) conceptual design and generating the minimum viable product (MVP), and d) developing prototypes for usability validation. **Results.** There was evidence of great heterogeneity in the current records and a lack of subsequent data analysis. A MVP was developed, which includes a form for recording falls, a visualization of preventive measures, differentiated user profiles and educational tools. The system was internally validated by caregivers, managers and health care professionals in LTCF. **Discussion.** Using ML would make it possible to automate data analysis and customize preventive measures. The participatory design and preventive approach were key to its acceptability. **Conclusions.** The developed prototype has the potential to optimize how falls are recorded in LTCF, improve prevention and strengthen care for institutionalized older adults.

Keywords: :

Aged, 80 and over; Machine Learning; Aged; Medical Informatics; Accident Prevention; Electronic Health Records; Artificial Intelligence; Homes for the Aged.

RESUMO

Introdução. Quedas em idosos institucionalizados representam um problema de saúde pública subestimado, associado à deficiência, dependência e mortalidade. No Chile, a falta de registros padronizados em instituições de longa permanência para idosos (ILPI) limita a prevenção eficaz. Este estudo teve como objetivo projetar um protótipo de sistema digital de registro de quedas baseado em aprendizado de máquina, ou machine learning (ML), para sua implementação em ILPI. **Metodologia.** Foi utilizada a metodologia de design duplo-diamante em quatro fases: a) identificação de stakeholders e coleta de informações por meio de entrevistas qualitativas; b) análise de causas e priorização de ideias com matrizes Analytical Hierarchy Process (AHP) e Pugh; c) design conceitual e geração do produto mínimo viável (PMV); e d) elaboração de protótipos para validação de usabilidade. **Resultados.** Foi evidenciada heterogeneidade significativa nos registros atuais e ausência de análise posterior dos dados. Foi desenvolvido um PVM que inclui um formulário de registro de quedas, visualização de medidas preventivas, perfis de usuário diferenciados e ferramentas educativas. O sistema foi validado internamente por cuidadores, gestores e profissionais de saúde em ILPI. **Discussão.** O uso de ML permitiria a automação da análise de dados e a personalização de medidas preventivas. O design participativo e uma abordagem preventiva foram fundamentais para sua aceitabilidade. **Conclusões.** O protótipo desenvolvido tem o potencial para otimizar o registro de quedas em ILPI, melhorar a prevenção e fortalecer o atendimento a idosos institucionalizados.

Palavras-chave:

Idoso de 80 Anos ou mais; Aprendizagem de Máquina; Idoso; Informática Médica; Prevenção de Acidentes; Registros Eletrônicos de Saúde; Inteligência Artificial; Instituição de Longa Permanência para Idosos.

Introducción

El envejecimiento poblacional es un fenómeno global que plantea grandes desafíos para la salud pública. Entre 2015 y 2050, la proporción mundial de personas mayores de 60 años se duplicará, pasando del 12% al 22%, y se estima que más del 80% residirá en países de ingresos bajos y medianos (1). América Latina y, en particular, Chile enfrenta un envejecimiento más acelerado, con una proyección de que para 2050 cerca del 30% de su población tendrá más de 65 años (2).

Las caídas son consideradas uno de los grandes síndromes geriátricos y constituyen la segunda causa de muerte por lesiones no intencionadas a nivel global. Anualmente, ocurren más de 37 millones de caídas que requieren atención médica y ocasionan la pérdida de más de 38 millones años de vida ajustados por discapacidad (AVAD, por sus siglas en inglés) (3), una carga superior a la de lesiones por transporte, ahogamiento y quemaduras combinadas (4). En contextos institucionales, la prevalencia de caídas puede superar el 40% y se ha asociado con deterioro funcional acelerado, aislamiento social y dependencia institucional. Estudios recientes en Estados Unidos muestran que aproximadamente la mitad de los residentes de hogares de cuidado prolongado experimentan al menos una caída al año, con consecuencias clínicas y organizacionales significativas (5).

A nivel clínico, más del 50% de las caídas en personas mayores resultan en lesiones y cerca del 20% reviste gravedad significativa, siendo las fracturas (especialmente de cadera) las más graves, con mortalidad al año de hasta un 30% (6). En Chile, la prevalencia anual de caídas en población mayor supera el 30%, y entre el 60% y el 70% de estas ocurren en establecimientos de larga estadía para adultos mayores (ELEAM), que afectan en su mayoría a mujeres entre 80 y 90 años, con polifarmacia y alta comorbilidad (7). Las intervenciones más efectivas son las multifactoriales, que combinan evaluación integral del riesgo, ejercicio físico, revisión de medicamentos y adaptación ambiental (8). No obstante, su implementación efectiva requiere herramientas que faciliten la recolección sistemática y el análisis de datos, lo que es especialmente desafiante en contextos institucionales en los que los registros de caídas suelen ser heterogéneos, manuales y sin capacidad de retroalimentación clínica.

En este escenario, el uso de tecnologías basadas en ML ofrece un enfoque innovador. Este subcampo de la inteligencia artificial (IA) permite procesar grandes volúmenes de datos, identificar patrones de riesgo, automatizar alertas y adaptar intervenciones en tiempo real

(9). Los modelos de aprendizaje automático aplicados a la predicción de caídas en residencias de adultos mayores han demostrado una capacidad predictiva adecuada, con valores de AUC-ROC (por sus siglas en inglés) entre 0.710 y 0.750 en cohortes de validación externa, con el uso de predictores clínicos, como equilibrio, fuerza de agarre, fatiga, comorbilidad y edad (10). Por su parte, sistemas de detección de caídas en tiempo real que emplean algoritmos de aprendizaje profundo, como redes neuronales convolucionales (CNN, por sus siglas en inglés) y recurrentes (RNN, por sus siglas en inglés), y modelos, como XGBoost, han alcanzado niveles de precisión superiores al 95% en entornos controlados, con el uso de datos provenientes de sensores portables e infraestructura ambiental (11).

Existen actualmente diversos sistemas que integran ML para la gestión de caídas. Por ejemplo:

- STEADI (CDC): plataforma con recursos clínicos para evaluar y gestionar riesgos de caídas en atención primaria (12,13).
- Durcal: sistema móvil con geolocalización, alertas y registros automatizados para familiares y cuidadores (14).
- CarePredict: plataforma con sensores portables que monitorean actividades y predicen caídas mediante algoritmos ML.
- HomeCare Fall Prevention: herramienta de intervención domiciliaria cocreada con usuarios, que incluye registro digital y monitoreo predictivo (15).
- Azure Machine Learning e IBM Watson IoT: plataformas que permiten integrar sistemas de monitoreo, sensores ambientales y datos clínicos con modelos de predicción personalizados (16,17).

La clasificación participativa de causas de caídas resultante del trabajo de campo se resume en seis categorías principales (Figura 3).

Sin embargo, en Chile aún no existen sistemas consolidados de este tipo aplicados a ELEAM, y la ausencia de estadísticas nacionales y de registros digitales limita la identificación de patrones de riesgo, así como dificulta la prevención efectiva. De esta manera, es necesario realizar un estudio que permita construir el diseño de un prototipo funcional de sistema digital para el registro y análisis predictivo de caídas en personas mayores institucionalizadas, con el uso de técnicas de aprendizaje automático (ML) y un enfoque participativo con actores de ELEAM en Chile.

Metodología

Diseño del estudio

Se realizó un estudio observacional descriptivo de tipo prospectivo, con enfoque participativo, orientado al desarrollo, la implementación y validación preliminar de un prototipo funcional de sistema digital para el registro y análisis predictivo de caídas en adultos mayores institucionalizados. El estudio se desarrolló entre marzo y diciembre de 2023 en tres ELEAM de carácter público en la Región del Biobío (Chile). La metodología se estructuró en tres fases: a) caracterización del problema, b) construcción del prototipo digital basado en ML y c) validación técnica y contextual.

Este estudio se diseñó conforme a las recomendaciones de la guía STROBE (por sus siglas en inglés) para estudios observacionales, con el fin de resguardar la transparencia en el diseño, los participantes, el análisis y la interpretación de resultados (18).

Participantes y contexto

Los participantes incluyeron a profesionales y técnicos responsables del cuidado directo de los residentes en

ELEAM, así como a encargados de gestión institucional. La muestra fue intencionada y se definió en colaboración con el Servicio Nacional del Adulto Mayor (SENAMA), organismo estatal encargado de coordinar políticas públicas y promover el bienestar y protección de los derechos de las personas mayores en Chile (19).

Los tres ELEAM seleccionados pertenecen a la red pública de SENAMA y fueron priorizados por su disposición a participar en procesos de innovación y mejora tecnológica. La participación fue voluntaria y se solicitó consentimiento informado mediante un formulario escrito.

El estudio fue aprobado por el Comité de Ética Institucional de la Universidad de Santiago de Chile. Además, el protocolo completo del estudio (incluidos todos los instrumentos, procedimientos y fases de validación) recibió aprobación formal mediante el Informe Ético n.º 263/2020. El mapa de actores y la matriz de poder/interés que orientaron la priorización de entrevistas y focos de intervención se presentan en la Figura 1 y Figura 2. Se obtuvo consentimiento informado escrito de todos los participantes. No se utilizó información clínica sensible ni identificable de residentes de los ELEAM, así como los datos fueron tratados bajo estrictos principios de confidencialidad y anonimización.



Figura 1: Mapa de *stakeholders* externos e internos y su relación con las caídas
Fuente: elaborado por los autores




Figura 2: Matriz de poder e interés

Fuente: elaborado por los autores

Procedimiento y desarrollo del sistema

El estudio adoptó el modelo doble diamante, una herramienta de design thinking desarrollada por el Design Council del Reino Unido (2004) y ampliamente utilizada en innovación sanitaria (20). Este modelo comprende cuatro

fases: a) discover (explorar y comprender el problema), b) define (definir claramente el reto), c) develop (idear y prototipar soluciones) y d) deliver (evaluar y refinar prototipos) (21). Este encuadre metodológico se apoyó con técnicas participativas para caracterizar causas y barreras (Figura 3).



Figura 3: Clasificación de causas de caídas

Fuente: elaborado por los autores

Varios estudios en contextos de salud digital han demostrado que este enfoque facilita la alineación entre las necesidades reales de usuarios y la evolución de prototipos iterativos, así como mejora su aceptación y utilidad final (22).

Fase 1: Caracterización y codiseño

Se aplicó un proceso de caracterización contextual que incluyó observación directa, entrevistas semiestructuradas y análisis documental de registros de caídas existentes en los ELEAM. Para las entrevistas, se utilizó un guion cualitativo diseñado ad hoc, validado por expertos en gerontología y sistemas de información. El guion abordó dimensiones, como el uso actual de registros, percepción del riesgo, procedimientos institucionales y barreras tecnológicas. Este instrumento está representado esquemáticamente en la Figura 1.

La información recogida permitió identificar las variables relevantes para el diseño del sistema digital y necesidades de usabilidad por parte del personal. En esta etapa, se empleó un enfoque de codiseño con los equipos técnicos y administrativos de los ELEAM, que integró sus sugerencias en la arquitectura funcional del sistema.

Estrategia de desarrollo incremental: PMV

Como parte del enfoque metodológico adoptado, se desarrolló un PMV del sistema digital, el cual representa una versión funcional primaria que incluye únicamente las características esenciales para operar y generar retroalimentación de usuarios reales (23) en ELEAM. Esta estrategia, inspirada en el enfoque Lean Startup, permite iterar ágilmente, reducir riesgos y validar supuestos críticos antes del escalamiento del sistema. Específicamente, en proyectos de salud digital, el uso de PMV facilita el involucramiento temprano de profesionales clínicos, la mejora continua mediante *build-measure-learn*, así como garantiza una adecuada aceptación tecnológica y cumplimiento normativo (24).

El PMV implementado incluyó ingreso estructurado de datos de incidentes, módulo básico de análisis predictivo con ML y visualización gráfica de eventos. A pesar de no integrar aún interoperabilidad con historiales clínicos institucionales, esta versión permitió validar la funcionalidad básica y la aceptación definitiva del prototipo por parte del personal de tres ELEAM, alineándose con prácticas recomendadas en el desarrollo de tecnologías sanitarias (25).

Fase 2: Construcción del prototipo

El prototipo digital fue desarrollado como una plataforma de registro estructurado, alojada localmente, con capacidad de análisis automático y visualización de datos. Las variables incluidas fueron edad, sexo, diagnóstico principal, fecha y hora del incidente, ubicación, tipo de lesión, uso de ayudas técnicas, número de medicamentos y factores ambientales reportados. (26).

Tabla 2. Matriz AHP de requerimientos de un sistema de registro de caídas

Mujer (n=297)		Hombre (n=184)
A	Medio de comunicación entre usuarios	Debe permitir a los diferentes tipos de usuarios (administradores, cuidadores, profesionales de la salud) intercambiar información y coordinar acciones.
B	Creación de cuentas para distintos usuarios	Debe permitir la creación de cuentas personalizadas para diferentes tipos de usuarios, con niveles de acceso y funciones específicas para cada rol.
C	Análisis de datos	Debe incluir herramientas de análisis de datos para identificar patrones, factores de riesgo y proporcionar recomendaciones basadas en la información recopilada.
D	Actualización de medidas preventivas	Debe ser capaz de actualizar las medidas preventivas recomendadas de manera continua, basándose en los análisis de datos y la evolución de los casos.
E	Registro de incidentes por cualquier usuario	Debe tener la capacidad de que cualquier usuario pueda registrar incidentes de caídas.
F	Centralización de datos	Debe centralizar toda la información relevante sobre las caídas de los residentes, así como permitir un acceso y gestión eficiente de los datos.
G	Historial detallado de todas las caídas de los residentes	Debe mantener un historial detallado de todas las caídas registradas y proporcionar acceso a la información completa sobre cada incidente.
H	Informes periódicos	Debe generar informes periódicos que resuman el historial de caídas.
I	Sistema de evaluación de riesgo	Debe permitir la evaluación de los riesgos de caídas.
J	Acceso rápido para registrar caídas	Debe tener un acceso rápido y directo para registrar caídas, así como minimizar el tiempo necesario para documentar un incidente.
K	Panel de control simple	Debe ser intuitivo y fácil de usar, así como permitir a los usuarios acceder rápidamente a las funciones principales del sistema.
L	Formulario de registro simple	Debe ser sencillo y fácil de completar para facilitar la entrada de datos por parte de los usuarios.
M	Recursos educativos básicos	Debe ofrecer recursos educativos básicos que faciliten la educación de los residentes en la prevención de caídas.

Fuente: elaborado por los autores.

Se incorporó una capa predictiva con el uso de algoritmos supervisados (regresión logística, Random Forest y XGBoost), entrenados con una base simulada de eventos basada en datos históricos anonimizados de los ELEM participantes. La estructura del modelo consideró variables de entrada relevantes clínicamente, y se aplicaron

criterios de interpretación que usaron técnicas SHapley Additive exPlanations (SHAP). Las especificaciones de requerimientos empleadas en la priorización se detallan en la Tabla 2, y sus pesos normalizados se presentan en la Tabla 3. La comparación de alternativas mediante matriz de Pugh se sintetiza en la Tabla 4.

Tabla 3. Matriz normalizada de requerimientos de un sistema de registro de caídas

	Matriz normalizada													Sumatoria	%
A	0.04	0.10	0.02	0.07	0.01	0.03	0.02	0.10	0.02	0.05	0.03	0.07	0.09	0.67	5%
B	0.01	0.03	0.01	0.01	0.02	0.02	0.01	0.02	0.02	0.06	0.02	0.04	0.02	0.30	2%
C	0.11	0.10	0.05	0.14	0.13	0.05	0.01	0.10	0.09	0.06	0.03	0.05	0.06	1.00	8%
D	0.02	0.08	0.01	0.03	0.03	0.05	0.01	0.10	0.02	0.05	0.03	0.04	0.16	0.63	5%
E	0.19	0.08	0.03	0.07	0.06	0.03	0.14	0.14	0.09	0.10	0.04	0.05	0.09	1.11	9%
F	0.11	0.10	0.11	0.07	0.19	0.10	0.14	0.07	0.09	0.10	0.17	0.05	0.09	1.40	11% 3°
G	0.08	0.10	0.21	0.14	0.02	0.03	0.05	0.02	0.02	0.06	0.04	0.05	0.06	0.89	7%
H	0.01	0.05	0.02	0.01	0.02	0.05	0.10	0.03	0.09	0.06	0.02	0.04	0.09	0.60	5%
I	0.08	0.05	0.03	0.07	0.03	0.05	0.10	0.02	0.05	0.06	0.04	0.05	0.01	0.63	5%
J	0.15	0.08	0.16	0.14	0.13	0.20	0.14	0.10	0.14	0.19	0.26	0.30	0.13	2.11	16% 1°
K	0.11	0.10	0.16	0.10	0.13	0.05	0.10	0.14	0.09	0.06	0.09	0.07	0.06	1.27	10% 4°
L	0.08	0.10	0.16	0.14	0.19	0.30	0.14	0.14	0.14	0.10	0.17	0.15	0.09	1.90	15% 2°
M	0.01	0.05	0.03	0.01	0.02	0.03	0.02	0.01	0.14	0.05	0.04	0.05	0.03	0.49	4%
	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	13.00	100%

Fuente: elaborado por los autores.

Análisis de datos

El procesamiento se realizó en Python 3.10 y se utilizaron las librerías pandas, *scikit-learn*, XGBoost y Matplotlib. Se aplicó validación cruzada k-fold (k=5) para estimar el rendimiento de los modelos, así como se calcularon métricas de precisión, sensibilidad, especificidad y área bajo la curva (AUC). Se priorizó el equilibrio entre sensibilidad y especificidad para asegurar una adecuada detección de riesgo sin sobrecarga de alertas falsas (27).

Validación del prototipo

Se realizó una validación técnica funcional mediante pruebas controladas en entorno de simulación y una validación contextual a través de talleres participativos con funcionarios de los ELEM. En estas sesiones, se evaluaron aspectos de usabilidad, claridad del sistema, pertinencia del modelo predictivo y potenciales barreras de adopción.

Los resultados cualitativos fueron sistematizados mediante matrices de análisis con categorías predefinidas, elaboradas a partir del guion cualitativo. La retroalimentación obtenida

permitió ajustar el sistema antes de finalizar la versión funcional. La arquitectura de navegación y mapa del sitio empleados en las pruebas se ilustran en la Figura 5.

Resultados

Los resultados del estudio se presentan organizados según las cuatro fases metodológicas definidas en el diseño del proyecto: a) caracterización y levantamiento de causas, b) priorización de requisitos, c) diseño conceptual del sistema y d) validación del prototipo. Esta estructura permite observar la progresión lógica entre el diagnóstico participativo, la toma de decisiones técnicas y la validación funcional y contextual del producto final.

Fase 1: Caracterización de causas de caídas y mapeo participativo

Durante esta fase se realizaron entrevistas semiestructuradas a 15 profesionales de la salud y cuidado en ELEAM, complementadas con herramientas participativas, como el diagrama de Ishikawa, el mapa de actores y la matriz de poder/interés. De este proceso emergieron seis categorías principales que agrupan los factores de riesgo:

- Fisiológicos (fragilidad, deterioro motor)
- Salud (polifarmacia, comorbilidades)
- Medio ambiente (infraestructura, iluminación)
- Educación y sensibilización (formación del personal/residentes)
- Situación residencial (estructura organizacional, personal disponible)
- Diseño de ayudas técnicas (adecuación y mantención de dispositivos)

La clasificación resultante se muestra en la Figura 3.

Estos hallazgos permitieron establecer una comprensión integral y multicausal del fenómeno de caídas en contextos institucionales, así como fundamentaron la necesidad de un sistema de registro adaptado a esa complejidad.

Fase 2: Priorización de requisitos mediante matriz AHP

Para seleccionar los componentes mínimos del sistema a desarrollar, se aplicó el método Analytic Hierarchy Process (AHP), que integra la visión de profesionales de la salud y gestión. A partir de la comparación entre pares de criterios y subcriterios, se establecieron las siguientes cinco prioridades:

- Facilidad de uso
- Pertinencia clínica de las variables
- Integración con protocolos existentes (p. ej., SENAMA)
- Soporte a decisiones clínicas
- Visualización de patrones de riesgo

Los requerimientos y sus pesos se presentan en la Tabla 2 y la Tabla 3, respectivamente, mientras la comparación de alternativas se resume en la Tabla 4.

Tabla 4. Matriz de PUGH

Códigos de ideas en matriz de PUGH		S1	S2	S3	S4	S5	S6
Criterios AHP	A	1	0	0	0	0	0
	B	1	1	1	0	0	0
	C	1	0	0	0	0	0
	D	1	0	0	0	0	0
	E	1	0	0	1	0	0
	F	1	1	1	1	1	0
	G	1	1	1	1	1	0
	H	1	1	1	1	1	1
	I	0	0	0	0	0	0
	J	1	1	1	1	1	1
	K	1	0	0	0	1	1
	L	1	1	1	1	1	0
	M	0	0	0	0	0	0
Total		11.0	6.0	6.0	6.0	6.0	3.0

Fuente: elaborado por los autores.

Estas prioridades se utilizaron directamente como insumo para orientar el diseño funcional representado en la Figura 4.

Fase 3: Diseño conceptual del sistema: desde los requerimientos al PMV

A partir de las prioridades definidas en la matriz AHP (Fase 2), se sistematizaron las necesidades funcionales y no funcionales más relevantes según los equipos de salud, así como se identificaron los siguientes requerimientos clave:

- Registro simple y rápido de caídas (menos de 2 minutos)
- Visualización gráfica de eventos por zona y hora
- Campos adaptados a lenguaje institucional
- Capacidad de exportación (Excel/formato SENAMA)
- Inclusión de predicción de riesgo con base en datos históricos

Estos requerimientos sirvieron de base para el diseño de un PMV, es decir, una versión inicial y funcional del sistema con las características mínimas necesarias para ser probado por usuarios reales. Esta estrategia permitió una

validación iterativa del desarrollo, siguiendo principios de diseño centrado en el usuario y metodologías ágiles (28). La derivación de elementos mínimos del PMV se ilustra en la Figura 4 y el mapa del sitio en la Figura 5

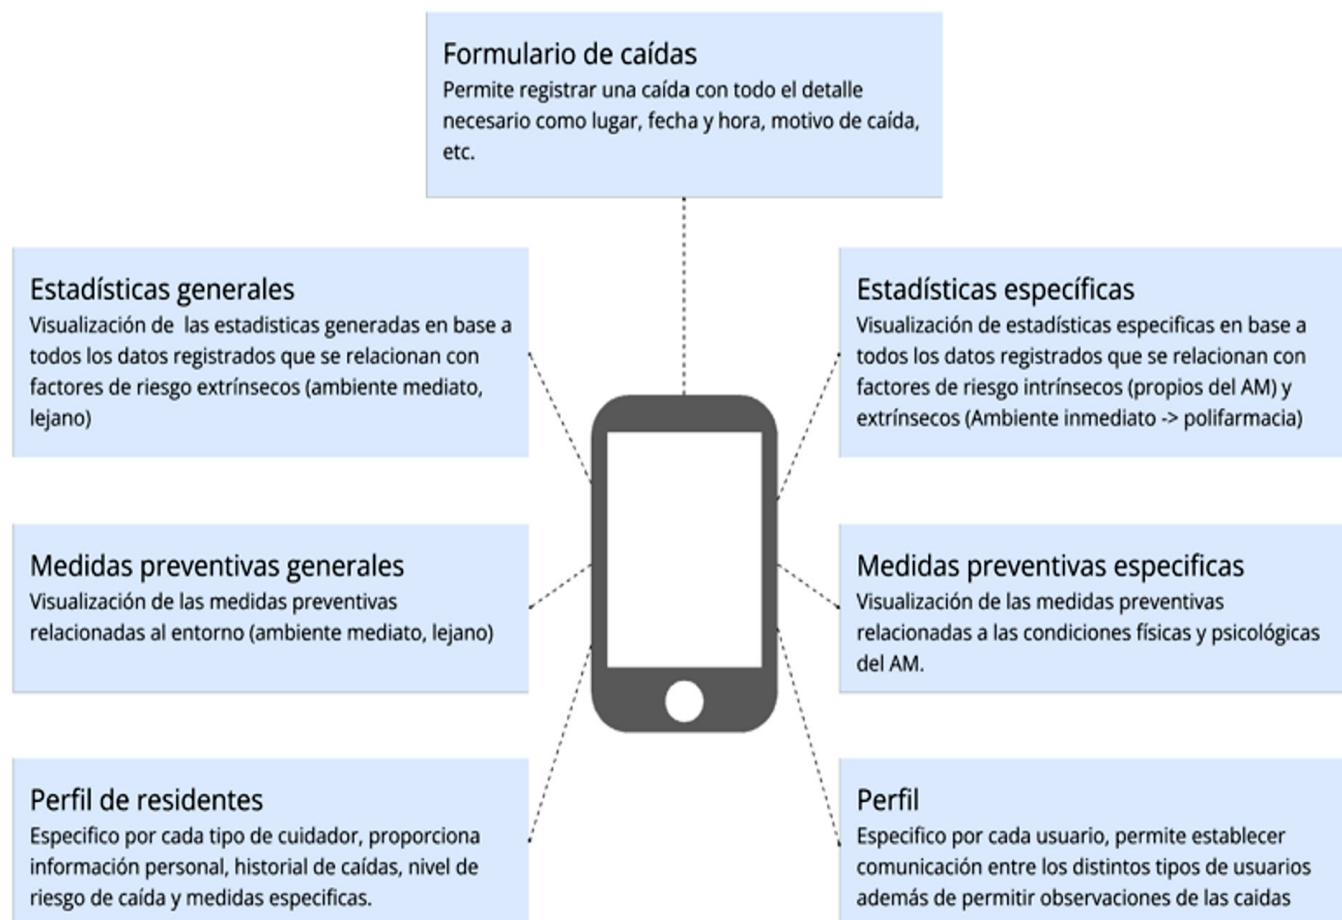


Figura 4: Elementos mínimos a considerar en el diseño conceptual de la aplicación

Fuente: elaborado por los autores

Fase 4: Validación técnica, funcional y contextual

A continuación, los resultados se organizan en tres subcomponentes.

Resultados cualitativos: percepción de los usuarios

Participaron 21 funcionarios distribuidos en tres ELEAM. A través de sesiones grupales y un guion de evaluación de usabilidad (Figura 5), se identificaron tres fortalezas principales:

- Usabilidad intuitiva
- Pertinencia de variables
- Valor preventivo de la visualización

También se identificaron barreras, como conectividad, carga de trabajo y resistencias iniciales a la digitalización. Ver Figura 6, Figura 7 y Figura 8 para flujos e interfaz.

Validación cuantitativa: desempeño de modelos ML

Se utilizó una base de datos simulada con 500 registros balanceados (250 caídas / 250 no caídas), estructurada con base en variables validadas clínicamente. Se comparó el desempeño de tres modelos de clasificación: regresión logística (RL), Random Forest (RF) y XGBoost, aplicando validación cruzada 5-fold. El desempeño comparativo de RL, RF y XGBoost se resume en la Tabla 1.




Figura 5: Diseño conceptual del mapa del sitio
Fuente: elaborado por los autores




Figura 6: Funcionamiento de la interfaz del MVP, acciones del cuidador y proceso interno

Fuente: elaborado por los autores

Registro de caídas

Camilo Gutierrez
 Masculino, 83 años
 + más

Riesgo de caída actual
 Bajo

Fecha: 03-07-2024 **Hora:** 16:00

Lugar de caída:
 Seleccione lugar de caída ▼

Actividad que realizaba el residente:
 Seleccione actividad ▼

Peligros presentes en el entorno:

☐ Poca iluminación en el área

☐ Superficie del suelo resbaladizo o mojado

☐ Superficie desnivelada

☐ Obstáculos presentes en el camino

Descripción de como ocurrió la caída:

Registro de caídas

Camilo Gutierrez
 Masculino, 83 años
 + más

Riesgo de caída actual
 Bajo

Estado del residente previo a la caída:
 Seleccione estado del residente ▼

¿Tomó medicación antes de la caída?
☐ Sí ☐ No ☐ No sé

Detalles específicos:

☐ Calzado Seleccione ▼

☐ Ropa Seleccione ▼

☐ Otro

Nivel de caída:
 Seleccione nivel de caída ▼

¿Usaba contención física en el momento de la caída?
☐ Sí ☐ No

SOS

SOS

Figura 7: Interfaz de previsualización de información para residente

Fuente: elaborado por los autores



Figura 8: Proceso de registro
Fuente: elaborado por los autores

Tabla 1. Comparativa de tres algoritmos

Modelo	AUC-ROC	Precisión	Sensibilidad	Especificidad
Regresión logística	0.77	0.72	0.68	0.76
Random Forest	0.82	0.79	0.81	0.78
XGBoost	0.84	0.83	0.86	0.81

Fuente: elaborado por los autores.

El modelo eXtreme Gradient Boosting (XGBoost) fue seleccionado para su integración en el prototipo debido a su mejor desempeño global, destacando en precisión, sensibilidad y AUC-ROC, lo que lo convierte en una herramienta robusta para la predicción de caídas en entornos institucionales. Este algoritmo tiene la capacidad de modelar relaciones no lineales y manejar datos con ruido o desequilibrio, características comunes en registros clínicos y residenciales.

Asimismo, su alta capacidad de interpretación mediante técnicas como SHAP permite transparentar los factores que más influyen en la predicción, así como facilitar su integración clínica y la confianza del personal en los resultados del sistema.

Fase 4: Diseño visual (wireframe) y validación de la interfaz

Elaboración de wireframes

Se diseñaron *wireframes*, o bosquejos, de baja fidelidad que representaban las principales pantallas del sistema: ingreso de incidentes, panel de visualización y módulo de exportación. Estos fueron presentados a usuarios clave para recoger observaciones sobre estructura, navegación y lenguaje (Figura 5). Este proceso permitió anticipar problemas de interfaz antes del desarrollo técnico.

Validación de la interfaz: cinco procesos complementarios

Una vez desarrollado el PMV, se implementaron cinco procesos de validación de interfaz y contexto:

1. Validación funcional: 12 sesiones de prueba permitieron verificar la navegación completa, sin errores críticos ni trabas técnicas.
2. Validación de usabilidad: Se aplicaron heurísticas simplificadas para evaluar claridad del diseño, carga cognitiva, lenguaje y retroalimentación del sistema.
3. Validación de contenido: Se revisó con usuarios si los campos del sistema correspondían a la práctica clínica real, que resultó en ajustes de nomenclatura.
4. Validación predictiva: Se verificó que los resultados de riesgo generados por el algoritmo (XGBoost) fueran consistentes y comprensibles.
5. Validación contextual: Se exploró la integración del sistema en flujos de trabajo reales, así como compatibilidad con formatos existentes y niveles de conectividad.

Discusión

Optimizar los registros de caídas en ELEAM en Chile

Este estudio reafirma la necesidad urgente de estandarizar y mejorar los sistemas de registro de caídas en ELEAM chilenos. El crecimiento sostenido de esta modalidad asistencial demanda procesos eficientes que aseguren calidad de atención y uso óptimo de recursos, especialmente considerando la vulnerabilidad de sus residentes. La literatura reciente respalda este enfoque: Kamel et al. (29) señalaron que la heterogeneidad en los registros dificulta la evaluación eficaz de riesgos en entornos geriátricos institucionales.

Los sistemas actuales presentan inconsistencias en terminología, datos faltantes y desalineación con protocolos nacionales, lo que limita la toma de decisiones informadas. Este déficit fomenta prácticas rutinarias inadecuadas y aumenta el riesgo de caídas, como lo han advertido otros investigadores en contextos similares. Las discrepancias observadas entre elementos protocolares y elementos estructurales efectivamente implementados durante el levantamiento se sintetizan en la Tabla 5, lo que evidencia oportunidades de mejora en infraestructura y equipamiento.

Tabla 5. Diferencias entre elementos descritos en protocolos y los implementados

	Elementos estructurales	Elementos protocolares
Iluminación	–	+
Rampas	+	–
Barandas	+	+
Barras de seguridad	+	–
Cámaras de vigilancia	+	–
Catre clínico con baranda	+	–
Contención física mecánica	+	+

Fuente: elaborado por los autores.

Interdisciplinariedad y enfoque preventivo con ML

La integración de ML representa una solución prometedora para mejorar la gestión de caídas. Sin embargo, su aplicación exitosa exige un enfoque interdisciplinario, que articule diseñadores, ingenieros, clínicos y autoridades regulatorias. De hecho, un estudio reciente sobre la implementación de IA en hospitales destacó que la colaboración multidisciplinaria es fundamental para alinear la innovación con las prácticas clínicas reales y superar barreras operacionales (29).

PMV y gestión de expectativa

La definición del PMV fue compleja debido a la multifactorialidad de los cuidados en ELEAM. Su desarrollo se enfocó en datos esenciales: perfil del residente, acciones preventivas y registro de eventos. Esta estrategia se alinea con enfoques Lean Startup en salud, en el que se prioriza entregar valor rápido y generar retroalimentación clínica temprana.

Las pruebas de usuario confirmaron que el prototipo simplificado ayudó a gestionar expectativas y facilitó la comprensión del sistema. Los estudios similares en herramientas de salud digital han mostrado que iterar con prototipos “funcionales” mejora la aceptación y redunda en diseños más útiles (30).

Rendimiento de XGBoost y apoyos científicos

La elección de XGBoost, respaldada por un AUC de 0.84 y sensibilidad de 0.86, respondió a su capacidad para manejar variables no lineales y datos con ruido. Estudios

recientes en contextos similares (residencias en EE. UU. y China) han reportado AUC entre 0.84 y 0.85, que confirma la idoneidad de este enfoque predictivo. Además, el uso de SHAP para explicar las predicciones fortalece la confianza del personal clínico en el sistema, una práctica emergente en AI aplicada a salud para mejorar la interpretabilidad de los modelos (31).

Validación multicomponente e implicancias organizacionales

La validación del prototipo incluyó aspectos funcionales, de usabilidad, contenido, predictivos y organizacionales, para garantizar una evaluación integral. Este enfoque coincide con las recomendaciones de revisiones sobre estrategias de prevención en hogares de larga estadía, que advierten la necesidad de adaptación al entorno y capacitación del personal.

El enfoque participativo permitió identificar barreras reales, como conectividad y carga laboral, y adaptar el prototipo antes de su despliegue, para mejorar su escalabilidad futura.

Fortalezas y limitaciones

Fortalezas

- Enfoque mixto y estructurado según STROBE
- Validación cultural y organizacional
- Uso de un PMV ágil y conectable
- Selección informada de un algoritmo robusto e interpretativo

Limitaciones

1. El uso de datos simulados limita la validez externa
2. Falta de interoperabilidad con sistemas clínicos en producción
3. La escalabilidad real aún no se ha evaluado longitudinalmente

Líneas futuras

Se recomienda

1. Evaluar el sistema con datos reales de ELEAM en cohortes longitudinales
2. Integrar sensores e IoT (por sus siglas en inglés) para enriquecer la detección y validación en tiempo real (32)
3. Fortalecer regulaciones nacionales que promuevan e-health y registros estandarizados
4. Promover alianzas interdisciplinarias para desarrollo contextualizado
5. Involucrar a los residentes desde la etapa de diseño para fomentar la autonomía informada

Conclusiones

El desarrollo colaborativo de un prototipo de registro digital con ML demostró ser funcional, aceptable y con desempeño predictivo adecuado para ELEAM. La combinación de métodos cualitativos y cuantitativos, junto con el uso de PMV e interdisciplinariedad, establece una base sólida para escalar hacia un sistema preventivo e institucionalmente útil. Con validación adicional y ajustes en interoperabilidad, este enfoque podría transformarse en una herramienta efectiva para la prevención real de caídas en contextos de cuidado prolongado.

Conflicto de intereses

Los autores declaran no tener conflictos de intereses.

Financiación

Los autores declaran que este trabajo se desarrolló gracias al aporte del Proyecto Fondecyt Regular No. de ANID 1251564.

Referencias

1. World Health Organization. Ageing and health [Internet]. Ginebra: WHO; 2022. Recuperado a partir de: <https://www.who.int/news-room/fact-sheets/detail/ageing-and-health>
2. Gutiérrez-Murillo RS. Population aging in Latin America: a salutogenic understanding is needed. Eur J Environ Public Health [Internet]. 2022;6(2):em0121. doi: <https://doi.org/10.21601/ejeph/12322>
3. Ghasemi H, Kharaghani MA, Golestani A, Najafi M, Khosravi S, Malekpour MR, et al. The national and subnational burden of falls and its attributable risk factors among older adults in Iran from 1990 to 2021: findings from the global burden of disease study. BMC Geriatr [Internet]. 2025;25(1):253. doi: <https://doi.org/10.1186/s12877-025-05909-6>
4. World Health Organization. Falls [Internet]. Ginebra: WHO; 2021. Recuperado a partir de: <https://www.who.int/news-room/fact-sheets/detail/falls>
5. Shao L, Shi Y, Xie XY, Wang Z, Wang ZA, Zhang JE. Incidence and risk factors of falls among older people in nursing homes: systematic review and meta-analysis. J Am Med Dir Assoc [Internet]. 2023;24(11):1708-1717. doi: <https://doi.org/10.1016/j.jamda.2023.06.002>
6. Stefanacci RG, Wilkinson JR. Falls in older adults. MSD Manual Professional Edition. [Internet]. 2023. Recuperado a partir de: <https://www.msdmanuals.com/professional/geriatrics/falls-in-older-adults/falls-in-older-adults>

7. Campiño-Valderrama SM, Serna-Zuluaga AS, Ayala IC. Riesgo de caídas y su relación con la capacidad física y cognitiva en una residencia de adultos mayores de Santiago de Chile. *Cultura del Cuidado* [Internet]. 2020;17(2):61-74. doi: <https://doi.org/10.18041/1794-5232/cultrua.2020v17n2.7658>
8. Gillespie LD, Robertson MC, Gillespie WJ, Sherrington C, Gates S, Clemson LM, et al. Interventions for preventing falls in older people living in the community. *Cochrane Database Syst Rev* [Internet]. 2012;9:CD007146. doi: <https://doi.org/10.1002/14651858.cd007146.pub3>
9. Tiwari P, Colborn KL, Smith DE, Xing F, Ghosh D, Rosenberg MA. Assessment of a machine learning model applied to harmonized electronic health record data for the prediction of incident atrial fibrillation. *JAMA Netw Open* [Internet]. 2020;3(1):e1919396. doi: <https://doi.org/10.1001/jamanetworkopen.2019.19396>
10. Shao L, Wang Z, Xie X, Xiao L, Shi Y, Wang ZA, et al. Development and external validation of a machine learning-based fall prediction model for nursing home residents: a prospective cohort study. *J Am Med Dir Assoc* [Internet]. 2024;25(9):105169. doi: <https://doi.org/10.1016/j.jamda.2024.105169>
11. Islam M, Tayan O, Islam R, Islam S, Nooruddin S, Nomani-Kabir M, et al. Deep learning based systems developed for fall detection: a review. *IEEE Access* [Internet]. 2020;8:166117-37. doi: <https://doi.org/10.1109/ACCESS.2020.3021943>
12. Stevens JA, Phelan EA. Development of STEADI: a fall prevention resource for health care providers. *Health Promot Pract* [Internet]. 2013;14(5):706-14. doi: <https://doi.org/10.1177/1524839912463576>
13. Lin CC, Meardon S, O'Brien K. The predictive validity and clinical application of Stopping Elderly Accidents, Deaths & Injuries (STEADI) for fall risk screening. *Adv Geriatr Med Res* [Internet]. 2022;4(3):e220008. doi: <https://doi.org/10.20900/agmr20220008>
14. Marín-Úbeda J, Berna-Martínez J (dir). Diseño y desarrollo de una app de monitorización geoespacial para la supervisión de personas dependientes [tesis en Internet]. 2024 [Valencia]: Universidad de Alicante; 2023. Recuperado a partir de: <https://rua.ua.es/entities/publication/1cd22bf1-46bc-4d98-945a-957e5a34feb7>
15. Linnerud S, Hartford-Kvaal LA, Graverholt B, Idland G, Taraldsen K, Brovold T. Stakeholder development of an implementation strategy for fall prevention in Norwegian home care: a qualitative cocreation approach. *BMC Health Serv Res* [Internet]. 2023;23(1):1390. doi: <https://doi.org/10.1186/s12913-023-10394-x>
16. Borra P. The Transformative Role of Microsoft Azure AI in Healthcare. *Int J Emerg Trends Eng Res* [Internet]. 2024;12(7):108-13. doi: <https://doi.org/10.30534/ijeter/2024/021272024>
17. Kadayat Y, Sharma S, Agarwal P, Mohan S. Internet-of-Things Enabled Smart Health Monitoring System Using AutoAI: A Graphical Tool of IBM Watson Studio. *Communication Technologies and Security Challenges in IoT* [Internet]. 2024:427-45. doi: https://doi.org/10.1007/978-981-97-0052-3_21
18. Fragozo-Mendoza MI, Dávila-Mendoza R, López-Ortiz G. Importancia y uso de guías para reportar los principales tipos de estudio en investigación médica. *Cir Cir* [Internet]. 2023;91(2):277-283. doi: <https://doi.org/10.24875/CIRU.22000122>
19. Beninho SG, Rosales Plaza F (dir). Análisis de la arquitectura institucional del servicio nacional de adultos mayores (SENAMA): una mirada hacia protección social de la vejez en Chile [tesis en Internet]. 2024 [Santiago de Chile]: Universidad de Chile; 2017. Recuperado a partir de: <https://repositorio.uchile.cl/handle/2250/150604>
20. Majka M. Mastering product development with the double diamond framework. *ResearchGate* [Internet]. 2024. Recuperado a partir de: https://www.researchgate.net/publication/384691492_Mastering_Product_Development_with_the_Double_Diamond_Framework
21. Wang X, Huang Z, Xu T, Li Y, Qin X. Exploring the future design approach to ageing based on the double diamond model. *Systems* [Internet]. 2023;11(8):404. doi: <https://doi.org/10.3390/systems11080404>
22. Arcia A, Stonbraker S, Mangal S, Lor M. A practical guide to participatory design sessions for the development of information visualizations: tutorial. *J Particip Med* [Internet]. 2024;16:e64508. doi: <https://doi.org/10.2196/64508>
23. Stevenson R, Burnell D, Fisher G. The minimum viable product (MVP): theory and practice. *J Manag* [Internet]. 2024;50(8):3202-31. doi: <https://doi.org/10.1177/01492063241227154>
24. Cook DA, Bikkani A, Poterucha-Carter MJ. Evaluating education innovations rapidly with build-measure-learn: applying lean startup to health professions education. *Med Teach* [Internet]. 2023;45(2):167-78. doi: <https://doi.org/10.1080/0142159X.2022.2118038>
25. Solomon DH, Rudin RS. Digital health technologies: opportunities and challenges in rheumatology. *Nat Rev Rheumatol* [Internet]. 2020;16:525-35. doi: <https://doi.org/10.1038/s41584-020-0461-x>
26. Leiva-Caro JA, Salazar González BC (dir). Relación entre competencia, usabilidad, ambiente y caídas en el adulto mayor [Tesis de grado]. Nuevo León: Universidad Autónoma de Nuevo León; 2013. Recuperado a partir de: <http://eprints.uanl.mx/3525/>
27. Fernandes C, Miles S, Pereira-Lucena CJ. Detecting false alarms by analyzing alarm-context information: algorithm development and validation. *JMIR Med Inform* [Internet]. 2020;8(5):e15407. doi: <https://doi.org/10.2196/15407>

28. Zorzetti M, Signoretti I, Salerno L, Marczak S, Bastos R. Improving agile software development using user-centered design and lean startup. *Inf Softw Technol* [Internet]. 2022;141:106718. doi: <https://doi.org/10.1016/j.infsof.2021.106718>
29. Kamel-Rahimi A, Pienaar O, Ghadimi M, Canfell OJ, Pole JD, Shrapnel S, et al. Implementing AI in hospitals to achieve a learning health system: systematic review of current enablers and barriers. *J Med Internet Res* [Internet]. 2024;26:e49655. doi: <https://doi.org/10.2196/49655>
30. Cahoolessur DK, Rajkumarsingh B. Fall detection system using XGBoost and IoT. *R&D Journal* [Internet]. 2020;36:8-18. doi: <https://doi.org/10.17159/2309-8988/2020/v36a2>
31. Kang CW, Yan ZK, Tian JL, Pu XB, Wu LX. Constructing a fall risk prediction model for hospitalized patients using machine learning. *BMC Public Health* [Internet]. 2025;25(1):242. doi: <https://doi.org/10.1186/s12889-025-21284-8>
32. Jahandideh S, Hutchinson AF, Bucknall TK, Considine J, Driscoll A, Manias E, et al. Using machine learning models to predict falls in hospitalised adults. *Int J Med Inform* [Internet]. 2024;187:105436. doi: <https://doi.org/10.1016/j.ijmedinf.2024.105436>