


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE ELECTRÓNICA
VALPARAÍSO – CHILE



PLATAFORMA TECNOLÓGICA PARA LA PRIORIZACIÓN
DE CASOS DE CÁNCER DE MAMA EN CHILE

BASTIÁN IGNACIO CORNEJO LIZAMA

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL TELEMÁTICO

PROFESOR GUÍA
NICOLÁS SEBASTIÁN GÁLVEZ RAMÍREZ

PROFESOR CORREFERENTE
WERNER UWE CREIXELL FUENTES

OCTUBRE 2023

Agradecimientos

Primero que nada, quiero aclarar que no hay un orden de preferencia en esta sección. Las personas mencionadas aquí se han ganado mi cariño y se han convertido en importantes partes de mi vida en distintos grados. Por todo lo que han hecho por mí, lo que hacen ahora y lo que harán en el futuro, muchísimas gracias a todos ustedes. Les aprecio desde el fondo de mi corazón.

Gracias, mamá, por todo en esta vida. Por proporcionarme educación, por confiar en mí, por preocuparte tanto, por quererme incondicionalmente. Recuerdo claramente el día en que dijiste: “No puedo darte una educación”, y aún así lo lograste. Confiaste en mí a pesar de que muchos decían que no podría hacerlo. Nos dijeron que no podría irme a estudiar tan lejos. Han pasado casi 10 años desde esa conversación, y recuerdo lo triste que estaba ese día porque nos dijeron que mis sueños eran imposibles. Mientras escribo esto, me emociono al ver todo el proceso y todo lo que hemos superado juntos. Nunca habría imaginado que esta sería mi vida actual. No puedo agradecerte lo suficiente por todo lo que has hecho por mí. Te quiero mucho, y espero que nunca lo olvides. Y mencionar también a mi hermana y a mi papá; gracias por estar siempre presentes, por su constante apoyo y por formar parte de este proceso.

A los amigos más cercanos, los chiquillos. Katty y Luis, muchas gracias por los años de amistad, por los buenos momentos que compartimos y por todas las risas que hemos tenido juntos. Gracias también por presentarme a Alejandro (Guerrero, para evitar confusiones), que aunque no llegó al mismo tiempo que ustedes y no nos conocimos bajo las mismas circunstancias, se convirtió en un gran amigo. Y gracias a ti, Ale, por ser un amigo tan especial, por cuidarme y preocuparte en todo momento, incluso cuando hablo de disparates que Katty no soporta escuchar.

Gracias a los amigos de IRE. Aunque nunca fui parte de la fundación, me hicieron sentir como si perteneciera a un grupo donde podía estar cómodo. Disfruté cada momento que compartimos y todo eso fue posible gracias a ustedes.

A las amigas, amigos y amigas que conocí en el camino. Sin importar la distancia, siempre les tengo un gran cariño, y verlos ocasionalmente en la universidad o fuera de ella alegra mi día. Especialmente a Vania, cuyos conocimientos me fueron de gran ayuda durante el último tramo de mi carrera y me sacaron de apuros en momentos difíciles.

Y en resumen, gracias a todos por hacer que mi vida sea más bonita.

Dedicatoria

Para mi abuelo, con mucho cariño.

*Aunque siento que esperaste toda una vida para este momento,
anhelo que desde donde estés, sientas orgullo por los logros de tu nieto.*

Resumen

En Chile, las principales causas de mortalidad que afectan a la población incluyen trastornos del sistema circulatorio, afectaciones respiratorias, causas externas de morbilidad y mortalidad, y enfermedades digestivas; siendo el cáncer una de las principales. En el año 2020, se registraron un total de 28.584 fallecimientos debido al cáncer, siendo los tipos más comunes el de pulmón, estómago, próstata, colon, páncreas y mama. Este último constituye la principal causa de muerte entre las mujeres, y se aborda principalmente a través de enfoques preventivos. En este contexto, los exámenes de mamografía desempeñan un papel crucial, proporcionando un clasificador conocido como BI-RADS, que se utiliza para evaluar los hallazgos detectados. Así, éste clasificador se ha convertido en uno de los principales indicadores para el diagnóstico temprano del cáncer de mama.

En respuesta a esta problemática, el presente trabajo se enfoca en la formalización del problema de la priorización de pacientes con cáncer de mama, realizando una investigación sobre cómo se aborda este problema y las listas de espera en otros contextos. Además, se explora la tecnología utilizada en herramientas de apoyo a la toma de decisiones médicas en diversas áreas. Luego, se procede a diseñar e implementar una plataforma de priorización de pacientes que consta de tres módulos fundamentales: limpieza de datos y la extracción de BI-RADS de los informes de mamografía; predecir el valor de BI-RADS para las mamografías que no mencionan este valor y priorizar a los pacientes en consecuencia; y integrar todo en una interfaz intuitiva que facilita la carga de archivos y la visualización de los pacientes priorizados.

Abstract

In Chile, the leading causes of mortality affecting the population include circulatory system diseases, respiratory diseases, external causes of morbidity and mortality, digestive diseases, and cancers. In 2020, 28,584 deaths were registered due to cancer, the most common types being lung, stomach, prostate, colon, pancreas, and breast cancer. The latter represents the primary cause of death among women in the country and is primarily addressed through preventive approaches. In this context, mammography examinations play a crucial role. These examinations provide a classifier known as BI-RADS, which measures their detected findings. This BI-RADS value has become one of the leading indicators for early breast cancer diagnosis.

In response to this issue, this work focuses on formalizing the problem of prioritizing breast cancer patients. It researches how this problem and waiting lists are addressed in other contexts. Additionally, it explores the technology used as decision-support tools in various medical areas. Then, a patient prioritization platform is designed and implemented, consisting of three fundamental modules: data cleaning and the extraction of BI-RADS from mammography reports; predicting the BI-RADS value for mammograms that do not mention this value and prioritizing patients accordingly; integrating all through an intuitive visual interface that facilitates file loading and patient prioritization visualization.

Índice general

Índice de figuras	7
Índice de tablas	8
1. Introducción	9
1.1. Propósito	10
1.2. Objetivos	10
1.2.1. Objetivo General	10
1.2.2. Objetivos Específicos	11
1.2.3. Contribuciones	11
1.3. Estructura de la memoria	11
2. Formalización del Problema	13
2.1. Descripción del problema	13
2.2. Criterios de priorización	16
2.2.1. Ejemplo de Caso Clínico	22
2.3. Problema abordado en otros contextos	23
2.4. ¿Cómo Chile enfrenta el problema de la priorización?	25
3. Contexto de la Solución	28
3.1. Ciencia de Datos	28
3.1.1. Obtención y Transformación de los Datos	28
3.1.2. Explotación de los Datos	30
3.1.3. Visualización de los Datos	34
4. Diseño de la Solución	38
4.1. Caso de Uso	38

4.2. Clasificación BI-RADS	39
4.3. Requerimientos del Sistema	40
4.4. Requisitos de Ambiente y Diseño del Sistema	41
4.4.1. Hardware y Software de Desarrollo	41
4.4.2. Perfiles de Usuario	42
4.4.3. Diagrama de Contexto	42
4.4.4. Diagrama de Arquitectura.	43
5. Implementación de la Interfaz de la Plataforma de Priorización	48
5.1. Limpieza de Datos	48
5.2. Sistema de Priorización	49
5.3. Predicción de BI-RADS	50
5.3.1. Diseño	50
5.4. Resultados de Clasificación	51
5.5. Interfaz Gráfica	53
5.5.1. Interfaz Preliminar	54
5.5.2. Interfaz Final	56
6. Conclusiones	61
6.1. Trabajo Futuro	62

Índice de figuras

2.1. Algoritmo Emergency Severity Index (ESI).	20
2.2. Número estimado de casos nuevos de cáncer en 2020 en Chile.	26
3.1. Ejemplo de salida de medSpaCy.	34
3.2. Puntos de tiempo e intervalos de atención en el Departamento de Emergencia.	35
4.1. Diagrama de Contexto.	43
4.2. Diagrama de Arquitectura.	44
4.3. Diagrama de Interfaz del Sistema.	45
5.1. Matrices de Confusión de los Clasificadores a Evaluar.	52
5.2. Análisis según Clases de Prioridad.	53
5.3. Menú Principal y Desplegable de Categoría BI-RADS.	54
5.4. Tabla de Reportes Médicos según BI-RADS seleccionado, en este caso 4.	55
5.5. Interfaz Gestión de Archivos.	56
5.6. Interfaz Visualización de Pacientes Priorizados en Tabla.	57
5.7. Tabla de Pacientes Priorizados con Detalle de Informe.	58
5.8. Detalle de Buscador de Pacientes por ID.	58
5.9. Tabla de Pacientes Priorizados con Filtro por ID de Paciente Específico.	59
5.10. Detalle de Filas por Página.	59
5.11. Tabla Configurada para 20 Filas por Página.	60

Índice de tablas

2.1. Clasificación CTS.	16
2.2. Puntaje de Alerta Temprana de Triage (TEWS).	17
2.3. Lista de discriminadores de CTG (adultos).	18
2.4. Categorización CTAS.	19
2.5. Categorización MTS.	21
2.6. Categorización de pacientes según nivel de gravedad en Chile.	25
3.1. Detalle de las herramientas tecnológicas utilizadas para NLP.	33
3.2. Resumen de algunos sistemas de tableros de control actuales.	36
4.1. Clasificación BI-RADS.	40
4.2. Requisitos Funcionales y Requisitos No Funcionales.	41
4.3. Perfiles de Usuario.	42
4.4. Matriz de Requisitos Funcionales y Módulos.	47
5.1. Tabla de Niveles de Prioridad junto a su respectiva descripción.	49
5.2. Distribución Dataset de Entrenamiento Balanceado.	51
5.3. Distribución dataset de testing por BI-RADS y Prioridad.	52
5.4. Descripciones de los Elementos en la Vista Principal.	54
5.5. Correcciones de los Requisitos.	55
5.6. Descripción de Elementos en Vista General.	57

Capítulo 1

Introducción

Durante las últimas dos décadas la tasa de mortalidad en Chile ha experimentado un crecimiento constante, superando actualmente las 100.000 muertes al año. Según el informe de Estadísticas Vitales de 2019 [1] publicado por el Instituto Nacional de Estadísticas, las principales causas de muerte se atribuyen a cánceres, enfermedades del sistema circulatorio, enfermedades respiratorias, causas externas de morbilidad y mortalidad, y enfermedades digestivas.

El cáncer es una enfermedad que afecta a una gran proporción de la población chilena. De acuerdo con estadísticas recopiladas de diversas fuentes [2], en el año 2020 se registraron 28.584 casos de fallecimiento por esta enfermedad. Entre los tipos de cáncer más comunes se encuentran los de pulmón, estómago, próstata, colon, páncreas y mamas, donde este último representa la *principal causa de muerte de mujeres en Chile*.

En la actualidad, el sistema de salud no cuenta con un mecanismo de priorización de pacientes, lo que genera largas listas de espera. Esto perjudica especialmente a aquellas personas que padecen casos graves de enfermedades y deben esperar su turno para recibir tratamiento adecuado. Además, la revisión de los numerosos exámenes médicos de cada paciente por parte del personal de salud se vuelve aún más lenta debido a la diversidad de formatos y al nivel variable de información contenida en los resultados. Estos factores marcan la diferencia en el tipo de tratamiento que se le brinda a cada individuo. Por lo tanto, priorizar la atención de los pacientes, ubicando en primer lugar aquellos casos de mayor gravedad que pueden optar por un tratamiento curativo, y facilitar la visualización rápida de la información de estos pacientes, tendrá un impacto positivo en la calidad de la atención médica y en la salud de los pacientes.

Dentro del contexto del cáncer de mama, el diagnóstico oportuno juega un papel fundamental para mejorar el pronóstico del paciente. En Chile, los pacientes recorren diversas instituciones de salud, acumulando una serie de documentos clínicos con fines diagnósticos que, según los criterios clínicos establecidos, determinan la prioridad con la que deben ser atendidos para evaluar la gravedad del cáncer y establecer el tratamiento correspondiente.

Este problema plantea un desafío significativo para la salud pública, puesto que afecta directamente a aquellos que deben esperar a que sus documentos sean revisados para obtener un diagnóstico preciso y un tratamiento adecuado. No enfrentar este desafío adecuadamente de forma temprana tiene un impacto negativo en el tratamiento del paciente, lo que aumenta la posibilidad de que la enfermedad deteriore aún más el estado de salud de éste, haciéndolo más difícil de tratar.

1.1. Propósito

En esta memoria se describe la creación e implementación de una plataforma para el manejo de pacientes de cáncer de mama. Esta plataforma será capaz de recibir como entrada los documentos clínicos de los pacientes y, utilizando herramientas y técnicas del área de ciencia de datos, asignar un nivel de priorización a los casos de cáncer de mama en función de la información contenida en los documentos clínicos y la identificación de entidades relevantes en ellos.

La implementación de una plataforma de ciencia de datos adaptada específicamente a la priorización de casos de cáncer de mama en Chile representaría un avance significativo en el manejo eficiente de la información clínica y en la toma de decisiones médicas. Esta plataforma permite la automatización y agilización del proceso de evaluación y clasificación de los casos, optimizando el tiempo de respuesta y brindando una atención más precisa y oportuna a los pacientes.

1.2. Objetivos

1.2.1. Objetivo General

Generar una interfaz visual que sirva de punto de salida para un sistema de información integrado que permite la lectura automática de documentos clínicos y que, utilizando aprendizaje automático, permita la priorización de pacientes para su atención.

1.2.2. Objetivos Específicos

- Definir un prototipo de interfaz la cual permita la visualización de los datos de los pacientes y la priorización entregada por el sistema.
- Diseñar una vista que permita al usuario ingresar una serie de datos para ser procesados a partir de un archivo con formato específico.
- Diseñar vista que permita la visualización de datos procesados por el algoritmo de aprendizaje automático en una tabla que resuma las características principales de los informes para la revisión de pacientes.

1.2.3. Contribuciones

Las contribuciones de este trabajo son: el análisis y transformación de los datos para su posterior procesamiento durante la ejecución del algoritmo, el diseño de un algoritmo de predicción y priorización de pacientes, la visualización de los datos y el diseño de la plataforma web que permite el ingreso de datos al algoritmo.

1.3. Estructura de la memoria

La estructura del presente documento se compone de la siguiente forma:

- El capítulo 1 describe el contexto en el que se encuentra el desafío planteado, así como la motivación que impulsó al equipo de trabajo a desarrollar este trabajo. Además, se presenta la solución propuesta para abordar la problemática identificada.
- El capítulo 2 se enfoca en la formalización del problema, las listas de espera y técnicas de priorización de pacientes, tanto en otros contextos como en el caso de Chile.
- El capítulo 3 trata sobre el contexto de la solución, donde se describen técnicas utilizadas para desarrollar soluciones tecnológicas en la asistencia en la toma de decisiones médicas en varios contextos.
- El capítulo 4 presenta el diseño de la solución, donde se describe el caso de uso de la solución, los diagramas que detallan el flujo de la aplicación y los módulos de ésta, conectándolos con los requisitos funcionales.

- El capítulo 5 se centra en la implementación de la solución, describiendo el proceso llevado a cabo en cada módulo que compone ésta y la interfaz del sistema que integra todos los módulos.
- El capítulo 6 concluye y resume los resultados obtenidos a partir del trabajo y logros realizados. Además, se menciona el trabajo futuro que podría fortalecer o mejorar la solución propuesta.

Capítulo 2

Formalización del Problema

En el siguiente capítulo se describe con mayor detalle el problema abordado en la presente memoria, donde se tratan temas como los problemas en el Sistema de Salud, la priorización de pacientes y las listas de espera. Se discuten distintos criterios de priorización donde se presentan algunos sistemas de triage y finalmente se habla sobre el problema y cómo este ha sido abordado en otros contextos y cuál es la situación en el caso Chile.

2.1. Descripción del problema

Las listas de espera son una forma de optimizar el flujo incierto de los pacientes y la carga de trabajo de los proveedores. No obstante, el aumento en la demanda de los servicios hace que las listas de espera crezcan rápidamente, resultando en tiempos de espera exageradamente largos [3]. Este suele ser el caso de los países con sistemas de salud financiados públicamente, donde los tiempos de espera excesivos tienen graves consecuencias como el deterioro de la calidad de vida de los pacientes [4].

Resulta clave reducir los tiempos de espera con el fin de mejorar el accesos a los distintos servicios médicos. Así, se han utilizado diversas estrategias en distintos contextos para mejorar el flujo de pacientes en los centros médicos, por ejemplo, aumentar el personal y el equipo disponible, o introducir métodos para la reducción de atenciones perdidas. Estas se pueden aplicar sin problema en servicios de urgencias, a medida que el presupuesto lo permita, pero para los servicios no urgentes, como la cirugía electiva no ocurre lo mismo. Por lo tanto, una gestión que permita garantizar que los pacientes con casos de mayor urgencia reciban atención antes que aquellos con menor necesidad, es indispensable [5].

Una estrategia para lograr esto es la utilización de métodos de priorización de pacientes. La

priorización es una forma de limitar los costos económicos de los servicios médicos, permitiendo decidir qué servicios son cubiertos por la comunidad asegurada o los contribuyentes y cuáles no. Bajo el contexto de la Comisión Central de Ética de la Asociación Médica Alemana, se define la priorización como la determinación de la prioridad relativa de medidas médicas, indicaciones, grupos de pacientes o áreas de atención [6]. Este enfoque tiene como objetivo limitar la carga económica en general, es decir, racionalizar, optimizar y priorizar los servicios prestados. Por lo tanto, la priorización de pacientes se refiere al proceso de clasificar las referencias en un orden deseado a partir de distintos criterios [7]. No obstante, esto trae consigo un efecto negativo en los tiempos de espera [8] debido a que los pacientes con mayor necesidad son tratados primero, y se debe obtener un balance equitativo en los tiempos de espera de los demás pacientes que no sea excesivo.

Este desafío implica comparar de manera dinámica la función de los pacientes según sus diversas características asociadas y el beneficio que obtendrían del servicio, por lo que es importante establecer parámetros adecuados y consistentes [9]. La ausencia de prácticas como esta [10] no permite mejorar el flujo de las listas de espera, y a su vez, se subestima a pacientes en condiciones menos urgentes no siendo atendidos de manera oportuna. Una herramienta capaz de proporcionar una priorización explícita, transparente y justa debe centrarse en entornos electivos, es decir, no en casos de emergencia, donde las probabilidades de tratar situaciones críticas sea menor y los factores a considerar tienen distintos niveles de prioridad, los cuales son difíciles de evaluar con precisión, como el dolor, la pérdida de función, el riesgo de deterioro, el impacto de una discapacidad, el estado socioeconómico, entre muchos otros.

Las herramientas de priorización de pacientes (del inglés PPT) son creadas a partir de conjuntos de criterios generales y tienen como propósito ayudar al personal médico en la toma de decisiones respecto a la gestión del orden de atención de los pacientes. Éstas miden realmente un fenómeno abstracto como el nivel de urgencia de un paciente, por lo que su proceso de validación está orientado hacia la evaluación y reducción de errores en el proceso de medición. Para evaluar la calidad, se investiga la confiabilidad, es decir, la estabilidad de los resultados obtenidos y su consistencia. Estas herramientas suelen ser utilizadas generalmente en casos de intervenciones electivas, como por ejemplo en la cirugía general [11] y servicios no urgentes como son el caso de resonancias magnéticas [12] o servicios de salud mental infantil [13].

Estas herramientas son capaces de agilizar la velocidad de entrega de los exámenes que son realizados, pero no afecta o genera cambios en el ámbito de la atención del sistema de salud. Una atención adecuada no es necesariamente la que genera un mayor número de pacientes atendidos en el menor tiempo posible, sino aquella que puede brindar atención temprana a los pacientes que podrían verse gravemente afectados por el paso del tiempo y el deterioro de su salud, evitando que sus condiciones

se vuelvan irreversibles.

En Chile, hasta el momento, no se ha implementado ninguna herramienta específica que permita una priorización de pacientes en el sistema de salud pública, excepto en áreas de urgencia, generando largas listas de espera que deterioran la calidad de vida de las personas en la mayoría de los casos. Lo anterior implica que en la literatura no se encuentra una investigación que se haya enfocado en el caso de Chile y, por ende, no ha sido sintetizada. Como tal, hay muy poca evidencia sobre el uso de las PTT en sistemas de atención médica, por lo que es necesario investigar como este problema ha sido abordado en diferentes contextos.

En el país, el cáncer es una de las principales enfermedades que afectan a la población chilena. De acuerdo con estadísticas recopiladas de diversas fuentes, en el año 2020 se registraron 28.584 casos de fallecimiento por esta enfermedad. Entre los tipos de cáncer más comunes se encuentran los de pulmón, estómago, próstata, colon, páncreas y mamas; donde el último representa la principal causa de muerte de mujeres en Chile con un 19.7% de tasa de mortalidad. La implementación de una PPT sería relevante en Chile debido a las necesidades del sistema de salud pública.

La atención de los pacientes de cáncer de mama en el país no está definida por prioridad según la gravedad de los casos, sino que se realiza según el orden de llegada, y no existen implementaciones o herramientas tecnológicas que prioricen los casos o disminuyan las largas listas de espera.

Para este, uno de los puntos críticos que hace la gran diferencia respecto al tratamiento que recibe un paciente, corresponde al diagnóstico temprano de dicha enfermedad. Un hallazgo temprano de ésta permite que se puedan tomar acciones rápidamente antes de que el caso agrave y no sea posible aplicar un tratamiento curativo. Muchos pacientes no presentan síntomas inicialmente, siendo tarde cuando son diagnosticados, generando campañas regularmente respecto a la realización de exámenes anuales a pesar de no padecer síntomas, para evitar hallazgos tardíos.

En el ámbito del procesamiento del lenguaje natural, el análisis de documentos diagnósticos clínicos ha permitido crear sistemas capaces de identificar términos clínicos [14] y que definen la gravedad del caso del paciente según los términos utilizados, como también han dado pie a otros sistemas capaces de clasificar el nivel de BI-RADS [15] a partir del entrenamiento de modelos de predicción. Esta y otras tecnologías serán vistas en el siguiente capítulo.

2.2. Criterios de priorización

Habitualmente en servicios de urgencia se implementan sistemas de triage [16] para priorizar a los pacientes e intentar regular las listas de espera. Algunos sistemas conocidos a lo largo del mundo son, por ejemplo:

- **CTS – Cape Triage Score:** El sistema sudafricano CTS [17] fue desarrollado y validado por el Cape Triage Group, a partir de 2004, el cual corresponde a un concepto de 5 niveles con los colores descritos en la Tabla 2.1.

Color	Descripción
Rojo	Tratamiento inmediato.
Naranja	Tratamiento en un plazo de 10 minutos.
Amarillo	Tratamiento en un plazo de 60 minutos.
Verde	Tratamiento en un plazo de 4 horas.
Azul	Fallecido.

Tabla 2.1: Clasificación CTS.

Los pacientes se asignan a estas a partir de 2 categorías: TEWS y discriminadores (Véase las tablas 2.2 y 2.3). En primer lugar, el Puntaje de Alerta Temprana de Triage (en inglés TEWS), incluye parámetros clínicos y fisiológicos como movilidad, frecuencia respiratoria (en inglés RR) y cardíaca (en inglés HR), presión arterial sistólica (en inglés SBP), temperatura, estado de alerta o AVPU (Alerta, Respuesta verbal, Respuesta al dolor, Inconsciente) y antecedentes de trauma. En segundo lugar, se utilizan los llamados discriminadores, que incluyen el mecanismo de lesión, los síntomas, la indicación de dolor y la opinión de expertos. Primero se determina el TEWS y se asigna un nivel de triage en función de ello. Luego, el paciente se clasifica según los discriminadores mencionados. Si se obtiene un nivel más alto a través de los discriminadores, este es el nivel correcto en el que se debe realizar el tratamiento. Investigaciones anteriores han demostrado una clara reducción en los tiempos de espera para los pacientes [18].

	3	2	1	0	1	2	3	
Mov.				Camina	Con asistencia	Camilla/Inmóvil		Mov.
RR		Menor a 9		9 - 14	15 - 20	21 - 29	Más de 29	RR
HR		Menor a 41	41 - 50	51 - 100	101 - 110	111 - 129	Más de 129	HR
SBP	Menor a 71	71 - 80	81 - 100	101 - 199		Más de 199		SBP
Temp.		Menor a 35		35 - 38.4		38.5 o más		Temp.
AVPU				Alerta (A)	Voz (V)	Dolor (P)	No responde (U)	AVPU
Trauma				No	Sí			Trauma
Más de 12 años / más alto que 150 cm								

Tabla 2.2: Puntaje de Alerta Temprana de Triage (TEWS).

Color	Rojo	Naranja	Amarillo	Verde	Azul
TEWS	7 o más	5 - 6	3 - 4	0 - 2	Muerto
Tiempo objetivo para tratar	Inmediata	Menos de 10 minutos	Menos de 60 minutos	Menos de 240 minutos	Muerto
Mecanismo de lesión		Transferencia de alta energía			
Manifestación		Falta de aire - agudo		Todos los demás pacientes	
		Tos con sangre			
		Hemorragia - no controlada	Hemorragia - controlada		
	Convulsión - actual	Convulsión - postictal			
		Neurología focal - aguda			
		Nivel de conciencia reducido			
		Extremidad en riesgo			
		Luxación - otra articulación	Luxación - dedo o dedo del pie		
		Fractura - compuesta	Fractura - cerrada		
	Quemadura - rostro / inhalación	Quemaduras en más del 20 %	Quemadura - otra		
		Quemadura - eléctrica			
		Quemadura - circumferencial			
		Quemadura - química			
		Intoxicación / sobredosis	Dolor abdominal		
	Hipoglucemia - glucosa menor a 3	Diabético - glucosa superior a 11 y cetonuria	Diabético - glucosa superior a 17 (sin cetonuria)		
		Vómito - sangre fresca	Vómito - persistente		
		Embarazo y traumatismo o dolor abdominal	Embarazo y trauma		
Dolor		Severo	Moderado	Leve	
	Discreción del profesional de salud				

Tabla 2.3: Lista de discriminadores de CTG (adultos).

- **CTAS – Canadian Triage and Acuity Scale:** Sistema canadiense desarrollado en 1995 [19] e introducido en todo el país en dos versiones, la primera en 1997 y la segunda revisada en 2004. Al igual que CTS, también cuenta con 5 niveles de categorización:

Nivel CTAS	Gravedad	Color	Tiempo
1	Reanimación	Azul	Paciente debe ser visto por un médico inmediatamente un 98 % del tiempo
2	Emergente	Rojo	Paciente debe ser visto por un médico dentro de 15 minutos un 95 % del tiempo
3	Urgente	Amarillo	Paciente debe ser visto por un médico dentro de 30 minutos un 90 % del tiempo
4	Semi-urgente	Verde	Paciente debe ser visto por un médico dentro de 60 minutos un 85 % del tiempo
5	No urgente	Blanco	Paciente debe ser visto por un médico dentro de 120 minutos un 80 % del tiempo

Tabla 2.4: Categorización CTAS.

Una característica especial de este sistema son los tiempos establecidos para reevaluar al paciente y, si es necesario, volver a evaluar su situación. Al igual que la mayoría de los otros sistemas, el CTAS se basa en un extenso catálogo de presentaciones de síntomas. Sin embargo, en el sistema canadiense también se incluyen diagnósticos iniciales o sospechas, lo que dificulta su implementación en países donde se requiere un diagnóstico médico.

En la práctica, el CTAS funciona de la siguiente manera: primero se selecciona una presentación principal de síntomas y esto determina el nivel de CTAS. Estas presentaciones orientadas a queja se dividen en las siguientes categorías principales:

- Neurológica
- Respiratoria
- Cardiovascular
- Gastrointestinal
- Genitourinaria
- Ginecología/Obstetricia
- Ortopedia/Cirugía de Traumatología
- Dermatología
- Oftalmología
- Otorrinolaringología

De manera similar al CTS, se aplica luego el uso de modificadores primarios como la presión arterial, pulso, temperatura o respiración, los cuales pueden aumentar el nivel determinado. El dolor puede aumentar el nivel de CTAS, al igual que la evaluación del mecanismo de lesión.

- **ESI – Emergency Severity Index:** El Sistema de Indicadores de Emergencia (ESI, por sus siglas en inglés) fue desarrollado en Estados Unidos e implementado por primera vez en 1999. Desde entonces, ha experimentado cuatro modificaciones, siendo la más reciente en 2004. Aunque también consta de 5 categorías, el ESI [20] se distingue por tener una triage de 2 niveles. Inicialmente, los pacientes se clasifican en las categorías 1 (amenaza inmediata para la vida) y 2 (crítico). Luego se realiza una subdivisión basada en el uso esperado de recursos médicos, como radiografías, tomografías computarizadas, electrocardiogramas y pruebas de laboratorio. Si un paciente no requiere de estos estudios, se le asigna la categoría 5; si los requiere, se le asigna la categoría 4. Para aquellos pacientes que necesitan múltiples recursos, se recopilan los parámetros vitales y se los clasifica en las categorías 2 o 3 según corresponda. Esto se puede observar en la Figura 2.1.




Figura 2.1: Algoritmo Emergency Severity Index (ESI).

A diferencia de otros sistemas, el ESI no establece ventanas de tiempo específicas en las que el tratamiento debe comenzar, ni se especifica una reevaluación. Por lo tanto, este sistema simple es una herramienta efectiva para determinar el orden de tratamiento, pero no proporciona información sobre cuándo se ha superado el umbral de peligro para un paciente.

- **MTS – Manchester Triage System:** El Sistema de Triage de Manchester se implementó por primera vez en Manchester en 1995 y se extendió ampliamente en el Reino Unido, lo que llevó a la formulación de una guía de entrenamiento uniforme en 1997. En 2001 se realizó la primera revisión y en 2006 se llevó a cabo una segunda revisión. Esta versión está actualmente en uso, tanto en inglés como en traducciones.

El MTS también es un sistema de 5 niveles con una codificación por colores. Comienza evaluando el motivo de consulta. Cada motivo de consulta se evalúa utilizando uno de los 52 algoritmos disponibles, que contienen signos y síntomas específicos para cada motivo de consulta y determinan la gravedad o riesgo de la consulta, lo que ayuda a determinar la clasificación de triage. Para cada categoría de triage, existe un tiempo máximo de espera establecido para la evaluación realizada por un médico.

Nivel MTS	Urgencia	Color	Tiempo (min)
	Llegada a triage		5
1	Atención Inmediata	Rojo	0
2	Muy urgente	Naranja	10
3	Urgente	Amarillo	30
4	Normal	Verde	90
5	No urgente	Azul	120

Tabla 2.5: Categorización MTS.

Las herramientas de priorización de pacientes en los servicios de atención médica utilizan criterios generales que abarcan factores personales, sociales, clínicos, entre otros. Estas herramientas mutan en medida del contexto donde se aplica. Por ejemplo para casos de medicina no urgente, se priorizan en medida de los tipos de servicios que necesitan los pacientes como la cirugía electiva. Otros estudios de priorización de pacientes para esta última [21], han definido herramientas que asignan un puntaje basándose en criterios como la edad, género, etnia y condición quirúrgica del paciente, como también disponibilidad del cirujano, del cual se obtuvo un aumento de la prioridad adecuado según la urgencia de las categorías de juicio clínico (urgente, semi urgente y rutinario), ponderando con éxito los criterios de prioridad que reflejan el juicio clínico tradicional.

Al priorizar a los pacientes, además de los criterios mencionados previamente, existen otros factores a considerar. El pronóstico, por ejemplo, se refiere a la probabilidad de recuperación del paciente

y a la calidad de vida que se espera después del tratamiento. Otro factor relevante es la capacidad funcional, que evalúa la habilidad del paciente para llevar a cabo actividades cotidianas como bañarse, vestirse y comer. Además, se considera el tiempo de espera que el paciente ha estado esperando para recibir tratamiento. Por último, también se toman en cuenta las preferencias del paciente, permitiéndoles expresar sus preferencias de tratamiento en algunos casos [22].

2.2.1. Ejemplo de Caso Clínico

A continuación se tiene un caso clínico el cual describe distintos signos vitales de un paciente que acude a urgencias:

“Esteban de 54 años acude a servicio de urgencia debido a que persiste con dolor de cabeza durante dos días que no ceden al uso de paracetamol en casa, además refiere un “pitido en el oído”. Al ingreso menciona que ambos padres son hipertensos y a él hace 2 años le diagnosticaron hipertensión pero que nunca ha asistido a ningún control ni se ha tomado los medicamentos. Al control de signos vitales:

- Presión Arterial (PA) 210/120 mmHg
- Frecuencia Cardíaca (FC) 121 lpm
- Frecuencia Respiratoria (FR) 18 rpm
- Saturación (Sat) 96 %
- Temperatura (T°) 36,8 °C
- Escala Visual Analógica del Dolor (EVA) 9/10

Médico de urgencias indica administrar captopril 12,5 mg y observar evolución. Al control a los 15 minutos PA en 170/98 mmHg, se inicia tratamiento farmacológico con enalapril 10 mg. Se recontrola 15 minutos después con PA 148/84 mmHg. Se indica control en CESFAM en 7 días más para evaluar fármacos a utilizar. Se realiza educación sobre patología y se entrega receta con tratamiento para continuar en casa.”

Aplicando los diversos criterios de clasificación previamente descritos, se ha dado paso a una evaluación ejemplar de un caso clínico concreto. Dicho caso ha sido sometido a un análisis exhaustivo siguiendo los rigurosos parámetros del Cape Triage Score (CTS), la Canadian Triage and Acuity Scale (CTAS), el Emergency Severity Index (ESI) y el Manchester Triage System (MTS).

Tras someter al paciente a un análisis concienzudo, se ha determinado que su TEWS según el

Cape Triage Score es de 5, lo que conlleva a la clasificación en la categoría naranja correspondiente al nivel 2, según la escala CTS.

Aplicando la Canadian Triage and Acuity Scale (CTAS), el paciente ha sido categorizado en función de sus síntomas cardiovasculares, resultando en una clasificación de nivel 2 CTAS, caracterizada por el distintivo color rojo.

Evalutando los síntomas del paciente y de acuerdo con el Emergency Severity Index (ESI), se ha llegado a la conclusión de que el paciente merece una categorización ESI 2 debido a la severidad del dolor que presenta. Esta clasificación prioriza la atención que requiere con urgencia.

Del mismo modo, al ser sometido a la evaluación del Manchester Triage System (MTS), el paciente ha sido ubicado en el nivel 2 MTS, considerando la naturaleza del problema que presenta.

Este análisis no solo resalta la importancia de cada sistema de clasificación en la atención médica, sino que también demuestra cómo su implementación rigurosa y precisa puede tener un impacto directo en la priorización y calidad de la atención al paciente. Es evidente que estas evaluaciones se sustentan en la solidez de los protocolos internacionalmente reconocidos como los vistos anteriormente. Además, es posible notar que en todas estas categorizaciones al paciente se le asigna un nivel similar de prioridad de forma general.

2.3. Problema abordado en otros contextos

Alrededor del mundo este problema en la priorización de los pacientes [23] ha sido abordado desde distintos puntos de vista. Canadá ha llevado a cabo programas para disminuir o eliminar los tiempos de espera de los pacientes en el Sistema de Salud debido a que se ha convertido en una de las principales características de este [24]. Las personas deben esperar pacientemente hasta que el sistema administrado por el gobierno pueda tratarlos, y esta espera forzada ha llevado a muchos sufrir de forma prolongada.

Otros países como Nueva Zelanda en el pasado han definido criterios para acceder a distintos servicios [25], como también qué condiciones o tratamientos deberían recibir financiamiento, prefiriendo el desarrollo de pautas clínicas como base para la evaluación. Actualmente el país cuenta con un grave problema respecto al tiempo de espera de los pacientes en el sistema de salud, llegando a esperar varias semanas [26] por una atención de rutina. Por lo mismo, recientemente han implementado un algoritmo que permite priorizar a los pacientes según una serie de criterios para que aquellos que han esperado durante un largo tiempo puedan optar por cirugías [27]. Sus intentos por disminuir las listas de espera

son claras y demuestran la existencia de un problema que no se limita a una ubicación específica, sino que ocurre de forma global.

En el contexto del crecimiento de la población, como por ejemplo en Ghana, la situación respecto a su sistema de salud con recursos limitados dificulta que la atención médica pueda satisfacer las necesidades de los pacientes. La ausencia de un sistema de priorización aumenta la probabilidad de que los pacientes desarrollen complicaciones debido a los altos tiempos de espera y las demoras en el tratamiento. Es por esto que, con el fin de acelerar la comprensión de diagnósticos médicos y dada la ambigüedad de la atención médica, se utiliza un conjunto de términos lingüísticos probabilísticos como una técnica para ayudar a los expertos en salud expresar precisamente sus evaluaciones en el problema de priorización de pacientes. Un grupo de investigadores han implementado un método basado en la integración media ponderada, para definir el grado de prioridad, y el operador de media simétrica de Maclaurin en el conjunto de términos descrito anteriormente [28]. En éste se describen los operadores de agregación PLPMSM (del inglés, Probabilistic Linguistic Prioritized Maclaurin Symmetric Mean) y PLPDMSM (del inglés, Probabilistic Linguistic Prioritized Dual Maclaurin Symmetric Mean) en extensión, donde destacan que estos nuevos operadores tienen la capacidad de considerar la interdependencia entre los criterios y a la vez modelar su relación de prioridad.

También es el caso de los hospitales públicos de China, específicamente por la gran cantidad de población. Asignar el orden en que los pacientes son hospitalizados es una tarea compleja debido a la distinta información que hay respecto a los pacientes, por lo que clasificarlos intentando cubrir la mayor cantidad de factores que existen a la hora de priorizar no resulta sencillo, y los criterios que se consideran principalmente para hacerlo son cualitativos. Es por esto que bajo este contexto, en [29] proponen un método integral de toma de decisiones multicriterio multiplicativo intuitivo llamado ORESTE (Organisation, Rangement et Synthèse de Données Relationnelles, en francés) para abordar el problema. Este utiliza una función de puntuación que considera los pesos subjetivos y objetivos de los criterios en el método propuesto, las cuales consideran la vaguedad de las percepciones de las personas hacia las alternativas, aplicando un modelo de relación de preferencia multiplicativa intuitiva [30] para representar las preferencias de los expertos sobre las alternativas con respecto a los criterios predeterminados.

Durante el brote de COVID-19 en abril de 2020, un caso en particular resaltó la sobrecarga de pacientes que enfrentaron diversas instituciones de salud [31], al punto de que el personal tuvo que ser reasignado para intentar manejar a todos aquellos que necesitaban de monitoreo intenso. Dichas reasignaciones causaron una interrupción repentina de la atención médica de rutina de los pacientes. Bajo este escenario, aquellos que padecen de cáncer se vieron gravemente afectados por miedo al contagio y cancelaban sus atenciones. Por lo mismo, el Centro Europeo para la Prevención y Control

de Enfermedades (ECDC) [32] describe 4 tipos de escenarios para describir el progreso del brote de COVID-19. Es en base a este que investigadores sugieren para aquellos pacientes de cáncer de mama distintos niveles de prioridad según se aplique a cada situación [33]. Los casos que definen estos corresponden a consultas, diagnósticos, toma de exámenes y cirugía, entre otros, describiendo cada nivel de prioridad.

2.4. ¿Cómo Chile enfrenta el problema de la priorización?

En 2019 según estadísticas proporcionadas por el Ministerio de Salud [34], se registró una lista de espera con 4.908.654 casos registrados donde un 45,7 % de los casos, o bien 2.242.314 casos, no fueron atendidos, de los cuales 32.726 fueron reportados por fallecimiento y otros 1.492 por indicación médica para reevaluación.

En el pasado, en un intento de priorizar a los pacientes y disminuir las largas listas de espera en los servicios de urgencia del sistema de salud pública, el Ministerio de Salud propuso implementar [35] el Sistema de Triage Manchester [36], pero en su lugar este sistema fue adaptado en los distintos centros médicos donde actualmente se categorizan los ingresos según 5 niveles definidas:

Categoría	Descripción
C1	Situación de riesgo vital que requiere atención inmediata: Infarto, hemorragias masivas, quemaduras con riesgo vital.
C2	Paciente debe ser estabilizado por posible riesgo vital: Descompensación de enfermedades, compromiso conciencia.
C3	Emergencia relativa, debe recibir tratamiento: Fractura, heridas, quemaduras sin riesgo vital, dolor abdominal focalizado.
C4	Paciente estable. Puede acudir al SAPU: Dolor abdominal, reacciones alérgicas, dolores de espalda o cabeza.
C5	Sin riesgo vital. Puede acudir a consultorio: Gripes comunes, curaciones.

Tabla 2.6: Categorización de pacientes según nivel de gravedad en Chile.

Este sistema no ha sido efectivo pues las listas de espera siguen aumentando y los pacientes no logran ser atendidos a tiempo [37]. Como se ha discutido previamente, esto genera un deterioro en la salud del paciente en la mayoría de los casos lo cual es inaceptable, dado que ha sido motivo en los últimos años del aumento en las defunciones en hospitales [38].

Para enfermedades como el cáncer, un punto clave corresponde al diagnóstico oportuno de dicha enfermedad pues permite tomar acciones rápidamente evitando un mayor deterioro en la salud del paciente. En [2] los informes obtenidos muestran que en el año 2020 la tasa de incidencia estandarizada

por edad de cáncer en Chile fue de 283,7 por cada 100.000 personas, mientras que países como Argentina o Brasil cuentan con 289,6 y 278,6 por cada 100.000, respectivamente. Por otro lado, países como Colombia (222,5) y México (151,6) tuvieron tasas de incidencia más bajas. Como se muestra en la Figura 2.2, los principales tipos de cáncer con mayor incidencia corresponden al cáncer de próstata, colorecto y mama.




Figura 2.2: Número estimado de casos nuevos de cáncer en 2020 en Chile.

Dentro del país se han realizado investigaciones que analizan casos de cáncer de mama, los cuales fueron llevados a cabo en la región Metropolitana. En [39] han establecido que es posible disminuir las incidencias de esta enfermedad dado que a lo largo de los años estudiados en el Hospital Sótero del Río respecto a estos pacientes, se ha visto una disminución en la mortalidad de pacientes, confirmando su hipótesis.

Chile no cuenta con ningún sistema de priorización de pacientes de cáncer de mama, una enfermedad que a nivel mundial y nacional representa la principal causa de muerte en mujeres. La falta de un sistema de priorización efectivo conlleva a la existencia de largas listas de espera en el sistema de salud pública, lo cual tiene graves consecuencias para las pacientes afectadas.

La implementación de un algoritmo de priorización de pacientes de cáncer de mama podría ser una solución efectiva para abordar este problema. Este tipo de algoritmo podría basarse en diferentes

criterios, como la gravedad del caso, el estadio de la enfermedad, la edad de la paciente y otros factores relevantes. Al tener en cuenta estos criterios, el algoritmo podría clasificar a las pacientes en función de su nivel de urgencia y necesidad de tratamiento.

Este podría tener un impacto positivo en la calidad de vida de las pacientes, pues podrían recibir un diagnóstico de forma oportuna y, por consecuencia, un tratamiento más temprano, aumentando las posibilidades de un pronóstico favorable y una mejor respuesta al tratamiento. Esto implicaría una reducción en la morbilidad y mortalidad asociada al cáncer de mama, así como una mejora en la calidad de vida de las pacientes.

Es importante destacar que el uso de un algoritmo de priorización no reemplazaría la labor clínica y la evaluación médica individualizada. Más bien, sería una herramienta complementaria que ayudaría a optimizar los recursos y agilizar el proceso de atención, sin comprometer la calidad y la personalización del cuidado médico. Esta propuesta se verá con mayor detalle en el siguiente capítulo, donde se abordará en profundidad el uso de herramientas de priorización de pacientes y clasificación de estadios de cáncer de mama.

Capítulo 3

Contexto de la Solución

En el presente capítulo se describen algunas técnicas utilizadas para el desarrollo de soluciones tecnológicas que buscan asistir en la toma de decisiones médicas en distintos contextos. Específicamente se describen en éste técnicas de extracción de información relevante a partir de informes médicos, el uso de datos para herramientas de Aprendizaje de Máquinas (ML, del inglés *Machine Learning*) y distintas alternativas existentes que son utilizadas actualmente para la visualización de la información.

3.1. Ciencia de Datos

La Ciencia de Datos (en inglés *Data Science*) se ha popularizado en los últimos años en la medicina dada la gran cantidad de información que es posible recolectar actualmente, ya sea a través de Registros de Salud Electrónicos (EHR, del inglés *Electronic Health Records*) o dispositivos capaces de recopilar datos vitales. Además, es una herramienta de apoyo que resulta de gran utilidad en el diseño de sistemas para la toma de decisiones, sin embargo se necesitan usar mejores prácticas como la adopción de estándares de modelado de información, la estratificación de pacientes en subgrupos para un mejor modelamiento predictivo [40].

3.1.1. Obtención y Transformación de los Datos

Los textos médicos cuentan con una serie de términos técnicos que la gente comúnmente no son capaces de entender con claridad y necesitan que un médico capacitado pueda facilitar al paciente la información que contienen éstos. A veces los términos que se utilizan llevan a diferencias en los

diagnósticos que informan los médicos, por lo que no es extraño buscar una segunda opinión al respecto; así se entiende que si tan solo se contara con la información crítica y relevante de un informe médico, distintos especialistas lleguen a un mismo diagnóstico.

Algunas técnicas de extracción de información relevante de textos clínicos abarcan herramientas como el etiquetado gramatical (en inglés POS tagging) que consiste en clasificar cada palabra de un texto según su uso en la parte del discurso. Por ejemplo, esta técnica se utiliza en [41] con el propósito de estructurar la información contenida en informes médicos no estructurados y ayudar a los especialistas a comprender el estado del paciente eficientemente. Sus resultados obtenidos muestran que es posible construir una forma estructurada y, además, que los términos clave sean extraídos correctamente, contribuyendo con el procesamiento y análisis automático de reportes médicos. Otro caso se demuestra en [42] donde se utiliza el Aprendizaje Profundo (DL del inglés *Deep Learning*) para extraer términos clínicos de reportes de radiología no estructurados. En este caso, se define un modelo de información que consta de tres tipos de entidades clínicas: observaciones, hallazgos clínicos y modificadores. Se utilizaron distintos modelos de Deep Learning para realizar pruebas de rendimiento, donde BiLSTM-CRF [43], específicamente la versión entrenada previamente utilizando informes de tomografías computarizadas (CT) de tórax del Hospital de la Universidad de Osaka, resultó ser el que arrojó los mejores resultados, indicando que las entidades definidas inicialmente del modelo de información son adecuadas para la extracción de términos clínicos, probando además que el modelo es lo suficientemente generalizable para ser utilizado con datos de otras instituciones.

En otros casos como el cáncer de mama, es importante que los reportes de las mamografías cuenten con un clasificador BI-RADS explícito, pues es uno de los principales discriminadores frente a la priorización de pacientes (véase en Capítulo 4). En [44] se propone clasificar mamografías con el apoyo de su respectivo clasificador BI-RADS, donde dicho proceso es realizado de forma automatizada con la asistencia Word2vec [45] y TFIDF [46]. Los resultados muestran que si se incluyen informes del Sistema de Información Hospitalaria (en inglés Hospital Information System, HIS) la precisión de los resultados aumenta en un 4 % en contraste a no utilizar estos.

También existen casos con acercamientos más simples a este tema, como lo demuestran en [47] donde el modelo propuesto busca extraer el valor BI-RADS de un informe de mamografía de forma automatizada con el propósito de asistir en el análisis manual que realizan los radiólogos. Dicho modelo es capaz de anotar y clasificar todas las menciones de BI-RADS presentes en un informe entregando retroalimentación a los especialistas. Es deseable contar con los valores BI-RADS en los informes de mamografías, pero no es una práctica estandarizada por lo que en algunos casos ocurre que no todos estos cuentan con dicho clasificador de forma explícita. Esta situación plantea un desafío adicional, ya que comprender el contenido completo del informe es fundamental para realizar diagnósticos precisos.

En el contexto de sistemas de apoyo para la toma de decisiones médicas, es posible abordar esta problemática mediante técnicas de Procesamiento de Lenguaje Natural o Redes Neuronales, las cuales se explorarán en la Sección 3.1.2.

3.1.2. Explotación de los Datos

El procesamiento de lenguaje natural o NLP [48] por sus siglas en inglés (*Natural Language Processing*) es un campo de las ciencias de computación la cual busca permitir que las computadoras comprendan el texto de manera similar a la forma en que los humanos lo hacen. Una de las primeras técnicas en este ámbito es el uso de *Word Embeddings* [49], la cual consiste en un método donde se convierten las palabras en representaciones numéricas, asignando valores similares a sus sinónimos, con el objetivo de capturar la semántica de las palabras en una secuencia de texto.

- En [50] se utiliza el sistema Apache cTAKES [51], el cual corresponde a una plataforma de extracción de información de documentos médicos electrónicos, utilizada en la detección de la recurrencia del cáncer de mama documentos clínicos en la investigación.
- Otra aplicación esta técnica es a través del entrenamiento de Redes Neuronales (NN), donde una de las más destacadas dentro de esta área es la red XLNET [52], la cual es una mejora del modelo BERT (Bidirectional Encoder Representations from Transformers) [53], ambas diseñadas por Google. BERT hace uso de transformers, un mecanismo de atención que aprende las relaciones contextuales entre las palabras de un texto. A diferencia de los modelos direccionales que leen la entrada de texto secuencialmente, es decir, de izquierda a derecha o de derecha a izquierda, esta técnica lee toda la secuencia de palabras a la vez, analizando el contexto de ambos lados de cada palabra y no de uno solo (izquierda y derecha de la palabra) [54]. La mejora que ofrece XLNET es que este es un modelo auto regresivo que utiliza la técnica Transformers - XL [55], siendo capaz de trabajar con una secuencia de texto tal igual que BERT, pero además de ser capaz de obtener información de secuencias anteriores para realizar predicciones [56].
- El estudio de aplicación y rendimiento de las técnicas XLNET y BERT en el área de salud para el análisis de textos no estructurados han sido ampliamente estudiadas por universidades e institutos de investigación. Ejemplos de estos son la investigación de la Universidad de Minnesota para la extracción de fenotipos del cáncer utilizando la red BERT [57] y otra de la Universidad de Harvard para el modelado de notas clínicas y predicción de la ventilación mecánica prolongada empleando una red XLNET [58].
- Un sistema utilizado para la extracción de información en reportes médicos es MedLEE (Medical

Language Extraction and Encodig) [59] el cual es un sistema privado desarrollado por la Universidad de Columbia, este extrae y codifica la información clínica de los reportes, inicialmente pensado para detectar tuberculosis desde los informes radiológicos pero actualmente ya se ha extendido su uso a un mayor tipo de reportes ganando terreno en el dominio del cáncer de mama siendo aplicado a mamografías. Algunas alternativas open source a MedLEE pueden ser la mencionada anteriormente cTAKES y HITEx (Health Information Text Extraction) [60] el cual es un software desarrollado para resolver problemas en el dominio médico para extraer información como diagnósticos, medicamentos, entre otros. Este software está basado en GATE (General Architecture for Text Engineering) [61], un sistema open source que ofrece una infraestructura para desarrollar e implementar componentes de software para NLP.

Dada la amplia diversidad de formatos de estos documentos, se enfrenta al desafío de requerir una gran cantidad de datos estandarizados para adaptar una red neuronal al problema. Diversas investigaciones han abordado esta cuestión proponiendo enfoques diferentes, pero con una idea central común: un sistema con la capacidad de extraer los términos médicos de los reportes clínicos y a partir de la implementación de algoritmos propios que analicen la presencias de estas, asignar una puntuación al reporte y determinar el nivel de gravedad o dolencia del paciente. Debido a que los informes clínicos son textos no estructurados, es decir, carecen de un formato predefinido y varían según la institución y el médico que los redacta, en ocasiones, el uso de redes neuronales puede no ser la opción más adecuada para diseñar una solución genérica.

En Agosto de 2021, investigadores de McGill University Health Centre de Canadá idearon un algoritmo NLP generalizable para la extracción de dolores a partir de documentos clínicos de cáncer [62] utilizando un repositorio de vocabularios biomédicos desarrollado por la Biblioteca Nacional de Medicina de Estados Unidos llamado *Unified Medical Language System (UMLS)* [63] para conocer la terminología empleada en los reportes médicos.

Basándose en esta premisa, primero, para la extracción de términos médicos de los documentos, se utilizan herramientas como MetaMap [64], un programa diseñado para acceder a los conceptos médicos del conjunto de datos UMLS, y un algoritmo implementado en Python que hace uso principalmente de la biblioteca spaCy [65]. El propósito principal de esta herramienta es eliminar espacios en blanco, caracteres especiales, detectar abreviaciones médicas y determinar si estos conceptos están negados o no. Los resultados se dirigen a una canalización de procesamiento del lenguaje natural (NLP), que previamente se ha entrenado y validado con conjuntos de datos públicos como MIMIC-III [66] e i2b2 [67]. Esta canalización utiliza un clasificador basado en reglas en conjunto con una serie de tablas que organizan los conceptos médicos según las dolencias. Se verifica si los conceptos obtenidos en el paso anterior coinciden con estos o si se trata de menciones de dolores irrelevantes, lo que finalmente

da como resultado un valor de dolor asociado, denominado “score pain”. Finalmente, utilizando esta puntuación se calcula una intensidad del dolor promedio para el documento clínico asociado, con el fin de representar si es que, a través del reporte, se identifica una dolencia relevante en el paciente o no.

Desde un punto de vista probabilístico se puede mencionar la utilización de *Redes de Bayesianas o de creencia*, las cuales corresponden a un modelo gráfico que muestra variables estocásticas representadas a partir de nodos y también enlaces que representan influencias probabilísticas directas entre dichas variables. Estas son de gran utilidad para el razonamiento bajo incertidumbre en sistemas de asistencia para la toma de decisiones médicas. La idea detrás de las Redes Bayesianas es otorgar valores de probabilidad a las variables, indicando el grado de creencia que se les otorga. Cada nodo cuenta con dos o más estados posibles. Para el nodo ‘*metástasis*’, por ejemplo, los dos posibles estados corresponden a ‘*si*’ y ‘*no*’. Cada uno de los posibles estados además es asociado con un valor de probabilidad y la suma de estos valores corresponde a 1. Estas redes son capaces de identificar relaciones entre distintos diagnósticos, hallazgos por imagenología o resultados de laboratorio, y pueden ser utilizadas para planificar exámenes de carácter diagnóstico, intervenciones terapéuticas o asistir en la interpretación de informes diagnósticos y hallazgos.

Es así como el consorcio MIDAS desarrolló MammoNet [68], un modelo de cáncer de mama que utiliza redes bayesianas para asistir en la formulación de diagnósticos a partir de la mamografía. El modelo propuesto muestra que las redes bayesianas son una potencial herramienta para asistir en la formulación de diagnósticos y la planificación de otros procesos diagnósticos adicionales.

Otra propuesta realizada recientemente utilizando también modelos bayesianos para realizar detecciones tempranas de cáncer de mama corresponde a un sistema predictivo [15] que principalmente se basa en variables como la edad, peso, índice de masa corporal, consumo de alcohol, herencia familiar de cáncer, menopausia, embarazos, entre otros más. Utiliza también dos bases de datos separando a aquellas personas con cáncer y sin cáncer, tomando la misma de entrenamiento para las pruebas. Su sistema define un sistema de clasificación bayesiano que utiliza 24 características para definir a los pacientes dentro de la base de datos, realizando después una validación del sistema para determinar los aciertos y errores de reconocimiento, logrando un alto porcentaje de aciertos con un mínimo de 5 características que, por sí solas, son insuficientes para identificar el cáncer.

Explotación de los Datos con Herramientas Tecnológicas

Dentro de las herramientas existentes para el trabajo relacionado con NLP, en la actualidad, dentro de la más usadas podemos encontrar la plataforma Natural Language Toolkit (NLTK) [69] que ha sido líder en el procesamiento general de textos. También podemos encontrar la biblioteca de

Python: spaCy [65]. Esta es una biblioteca open-source utilizada en el procesamiento avanzado del lenguaje natural y machine learning utilizada para construir sistemas de extracción de información, de comprensión del lenguaje natural y para preprocesar texto para los modelos de Machine Learning.

Nombre	Descripción
Natural Language Toolkit (NLTK) [69]	Se compone de una serie de bibliotecas NLP altamente funcionales para el análisis de textos basado en reglas y en aprendizaje automático. Si bien ha hecho posible cientos de proyectos e investigaciones con éxito, su enfoque del procesamiento de textos como listas de cadenas y la falta de una arquitectura unificadora han dificultado su capacidad para escalar a grandes conjuntos de datos.
spaCy	Ofrece una arquitectura robusta para construir y compartir módulos de NLP personalizados y de alto rendimiento, adoptando una visión del texto orientada a objetos. Debido a esto, permite una integración perfecta de métodos estadísticos y de aprendizaje automático con la NLP basado en reglas, y permite la creación de componentes personalizados para tareas especializadas. Esta biblioteca también posee la característica de estar impulsado por Cython, un compilador estático optimizador para Python que genera código C o C++ muy eficiente, permitiendo alcanzar una velocidad de rendimiento excepcional. En pocas palabras, spaCy proporciona un marco para la construcción modular <i>plug-and-play</i> de pipelines NLP personalizados.
medspaCy [70], [71]	Esta biblioteca derivada de spaCy ofrece ser una herramienta de gran capacidad en el ámbito NLP con un enfoque al análisis de reportes clínicos. Los componentes incluidos presentan tanto una inicialización por defecto como un gran número de parámetros de personalización opcionales. Esto permite que los componentes sean rápidos de configurar, aprender y utilizar para desarrollar prototipos, a la vez que son totalmente personalizables para necesidades más específicas. En pocas palabras, utilizando las herramientas para NLP ofrecidas por spaCy, medspaCy permite la detección de términos médicos y análisis en profundidad de reportes clínicos (véase Figura 3.1).
John Snow Labs [72]	Otra de las alternativas que han sido sugeridas en el contexto de las redes neuronales corresponde a la utilización de modelos ya entrenados de John Snow Labs, específicamente apuntando al uso de Spark NLP [73], la cual es una biblioteca de Python que utiliza componentes de Spark ML como los ya mencionados antes transformadores y los estimadores. Este último en particular tiene un método que asegura y entrena una parte de los datos. Una de las desventajas con las que cuentan estos modelos pre-entrenados es que la gran mayoría fueron en el idioma inglés, lo cual implica que se traduzcan las entidades pero no es un tarea sencilla dado que este paso puede resultar en una variación de los resultados. No obstante, un modelo que resulta de interés que se basa en esta biblioteca llamado <i>Detect tumor morphology in Spanish texts</i> [74], que como bien su nombre lo dice se encarga de detectar entidades de morfología de tumor en español. Dicho modelo fue entrenado con el data set de CANTEMIST [75], el cual está enfocado en el análisis oncológico en el idioma español.

Tabla 3.1: Detalle de las herramientas tecnológicas utilizadas para NLP.




Figura 3.1: Ejemplo de salida de medSpaCy.

3.1.3. Visualización de los Datos

La cantidad de información contenida en un informe médico varía entre pacientes y revisar una gran cantidad de éstos de distintos pacientes a lo largo de la jornada puede tomar una gran cantidad de tiempo al no poder observar de manera rápida los datos claves de en un reporte. Por lo tanto, si una herramienta de asistencia para la toma de decisiones busca mostrar información relevante al especialista sobre un paciente, esta misma no debería estar sobrecargada con todos los términos clínicos extraídos de este pues no todos los datos en sí son relevantes para el diagnóstico de un paciente.

Revisando distintos casos en los que se ha implementado algún sistema o herramienta de apoyo visual tomando por ejemplo el caso de sistemas de triage, en [76] se propone implementar una herramienta de triage digital que identificará a los niños de alto riesgo y busca reducir el tiempo de tratamiento. Dicha solución responde los resultados obtenidos en las investigaciones realizadas en dicho artículo, donde se identifica que la sepsis es la principal causa de muerte y discapacidad en niños. Cada hora de retraso en el tratamiento se asocia a un mayor riesgo de morbilidad y mortalidad. Además, la carga de la sepsis es mayor en países de ingresos bajos y medianos, donde es posible que el tratamiento oportuno no ocurra debido a retrasos en el diagnóstico y la priorización de niños críticamente enfermos.

Por otro lado, en [77] se hace un análisis de las formas de visualizar la información y apoyar efectivamente a los usuarios a reconocer el potencial informativo de los datos que se les proporciona. El campo de visualización de datos se ha centrado en crear herramientas de visualización de información que ayuden al sistema visual humano a interactuar mejor con los datos mediante la agregación, filtrado, búsqueda u otra forma de cribado y reducción de información relevante. En sí, las herramientas de visualización están diseñadas específicamente para ayudar a nuestro sistema visual a procesar de manera más eficiente detalles que de otra forma requerirían un esfuerzo cognitivo significativo. En otras palabras buscan proporcionar información que sea percibida fácilmente y pueda ser procesada con facilidad. En este mismo artículo se busca desarrollar paneles interactivos que resalten información dinámica dentro de

un contexto adecuado para satisfacer las necesidades de información de tareas conocidas y que respalden la exploración de los datos para lograr una mejor conciencia de la situación. La implementación de esta herramienta es realizada en la plataforma Tableau, donde desarrollan cinco paneles que transmiten el censo (es decir, el número de pacientes actuales, el puntaje de gravedad de cada paciente, la ubicación actual de los pacientes, camas disponibles, etc.), estado de los pedidos de laboratorio e imágenes, factores que contribuyen al puntaje de hacinamiento actual de la unidad, medidas de flujo de pacientes, incluyendo la duración de cada etapa de atención del paciente, y la información de carga de trabajo para cada profesional médico (véase Figura 3.2). Estos son accesibles dentro de la red del hospital y generalmente se visualizan en el mismo sistema de computadoras que el expediente médico electrónico. Dentro de cada panel los usuarios pueden interactuar con la visualización para obtener detalles a nivel de paciente, usar filtros para modificar la pantalla seleccionando características de pacientes y proveedores, o usar información emergente para obtener detalles adicionales al pasar el cursor sobre cada punto de datos.




Figura 3.2: Puntos de tiempo e intervalos de atención en el Departamento de Emergencia.

En [78] se revisan distintos sistemas de software que buscan asistir en el cálculo de las dosis de distintos fármacos según sea el caso las cuales se pueden apreciar en la Tabla 3.2. En estos específicamente destacan el uso de Pronóstico Bayesiano (en inglés Bayesian Forecast) el cual demuestra obtener mejoras

terapéuticas como es el caso de el número de pacientes cuyos niveles de fenitoína en el mínimo estuvieron dentro del rango objetivo fue mayor con el pronóstico bayesiano (63,6 % de los mínimos), en comparación con el ajuste de dosis convencional (34 %).

Software	Actualización Bayesiana	Pronóstico Bayesiano	Promedio Bayesiano	Dosis	Fármacos
MM-USC *PACK BestDose [79]	Sí	Sí	No	Sí a la exposición objetivo	Aminoglucósidos, digoxina
APK systems [79]	Sí		No	Sí al AUC objetivo	Aminoglucósidos
Abbottbase [80]	Sí	Sí	No	Sí, a un AUC	Aminoglucósidos
Drugcalc [81]	Sí	No	No	Sí, a un AUC	Aminoglucósidos
Dosecalc [82]	No	No	No	Sí, a un AUC	
MW/Pharm [83]	Sí	Sí	No	Sí	180 modelos de medicamentos
CHOP Pediatric Knowledgebase Dashboard [84]	Sí	Sí	No	Sí a través de pronósticos	Oncología pediátrica (metotrexato)
NZ FirstDose Dashboard [85]	No	Sí	No	Sí	Amikacina y vancomicina
TCIworks [80]	Sí	No	No	No	Gentamicina, enoxaparina y suministrado por el usuario.
Baysient Dose Evaluation system [86]	Sí	Sí	Sí	Sí, múltiples	Cualquiera

Tabla 3.2: Resumen de algunos sistemas de tableros de control actuales.

Más recientemente en [87] se revisa la literatura de la implementación de dashboards en el sistema de salud, dónde han sido empleados y dónde hay interés por mejorar el actual estado del arte. Definen un dashboard como un sistema visual de información que consta de al menos una figura visual y un almacén de datos que la interfaz gráfica de usuario (GUI) expone, y que está diseñado y construido con el propósito de satisfacer una necesidad de información precisa. Para ello, establecen métricas que les permitan evaluar en distintos casos estos dashboards según sea el escenario en que se prueba, las cuales corresponden a rendimiento de tareas, cambio de comportamiento, flujo de interacción, compromiso percibido, utilidad potencial, rendimiento del algoritmo e implementación del sistema. Finalmente lo que logran identificar con esto es que no se utilizan prácticas de estudios de evaluación durante el diseño de dashboards para los sistemas de salud, mostrando un pobre manejo en el control de calidad de estos.

A partir de la información recopilada, se evidencia una amplia disponibilidad de tecnologías y herramientas para abordar el problema planteado. Sin embargo, tras un análisis exhaustivo de los datos destinados al desarrollo de una solución, se concluye que el uso de redes neuronales como enfoque principal para la priorización y predicción de pacientes no resulta rentable debido a la naturaleza de las muestras obtenidas. La proporción de datos relevantes en la muestra es considerablemente baja en comparación con los requisitos necesarios para un entrenamiento efectivo de una red neuronal. Además, los datos no presentan uniformidad y el equilibrio necesario para desarrollar una red de manera adecuada no se cumple.

Por lo tanto, resulta fundamental determinar de antemano qué información se pretende presentar al usuario a través del panel de control, estableciendo una comunicación directa con el usuario final. Este aspecto se abordará con mayor profundidad en el Capítulo 4, donde se detallará el diseño de la solución, los requisitos específicos que la plataforma debe cumplir y las consideraciones clave que deben tenerse en cuenta durante el proceso de desarrollo.

Capítulo 4

Diseño de la Solución

En el presente capítulo se discute el caso de uso, es decir, en qué contexto se ha decidido trabajar el problema identificado anteriormente. Se detallan, además, los principales factores a considerar en el caso y se explica la clasificación BI-RADS que es utilizada en todo el mundo para los exámenes de mamografía. Posteriormente, se describen los requisitos que debe cumplir la solución a desarrollar, junto con los detalles de funcionalidad de ésta.

4.1. Caso de Uso

La Fundación Arturo López Pérez (FALP) es un centro oncológico chileno de alta especialización que se ha dedicado en los últimos años a brindar acceso oportuno a un tratamiento integral, especialmente a las familias más vulnerables. En el quinquenio 2011-2015 registran más de 59 mil personas atendidas y cerca de 25 mil cirugías realizadas, mientras que entre 2011 y 2017 se realizaron 642.577 consultas médicas, atendiendo a 86.364 nuevos pacientes; además, se efectuaron 36.451 cirugías, 74.950 sesiones de radioterapia y 43.259 egresos hospitalarios [88]. Estas cifras demuestran el alto impacto que han tenido en la población a lo largo de los años y su constante compromiso por brindar la mejor atención a sus pacientes.

Como se ha discutido previamente, el cáncer de mama es una de las principales causas de muerte que afectan a la población femenina en Chile. Los análisis del Ministerio de Salud en el informe “*Análisis de Tendencias Mortalidad y AVPP por cáncer 2000-2019*” [89] muestran que en entre estos años dicha enfermedad causó en promedio 12,4 muertes por cada 100.000 mujeres, mientras que el número de fallecidos por ésta al año aumenta junto con el paso del tiempo.

En consecuencia a esto, la FALP identifica que el desafío existente consiste en:

Implementar un sistema de información integrado que permita la lectura automática de documentos clínicos y la priorización de pacientes, aplicando técnicas de NLP y redes neuronales para resolver un problema de soporte a la decisión médica, abordando un problema de salud pública de alto impacto, con una aproximación que no cambia los procesos clínicos sino que se adapta a ellos.

Es importante destacar que la FALP actualmente cuenta con un algoritmo que permite detectar la presencia de metástasis en los informes médicos de pacientes con cáncer en general. Aunque este aspecto no se relaciona directamente con el contexto y el desafío planteado en este estudio, constituye una referencia útil que permite realizar un primer acercamiento al diseño de la solución del problema mediante la aplicación de métodos y técnicas del área de *Data Science*.

La implementación de un sistema como tal podría significar un gran avance para la priorización de pacientes en esta área, y además podría fomentar la aplicación de herramientas de soporte a la decisión médica en otras áreas reduciendo así las largas listas de espera que actualmente afectan a la población, mejorando significativamente su calidad de vida.

Para ello el sistema debe contar ciertos requisitos discutidos con la FALP como los resultados que no debe arrojar o la información que el sistema debería proporcionar, el flujo esperado y algunas de las tecnologías que debería utilizar. Es necesario realizar una investigación del estado del arte en la resolución de problemas de priorización y procesamiento de documentos clínicos, buscando herramientas utilizadas que puedan servir de ayuda para la implementación de este sistema, pues desde un principio la FALP destaca que una herramienta como tal no existe en el contexto nacional y sólo se utilizan métodos tradicionales para la priorización de pacientes. Mayores detalles sobre el desarrollo del sistema serán abordados durante el siguiente capítulo, sin embargo, es necesario explicar una de las principales clasificaciones existentes en el contexto de cáncer de mama: el clasificador BI-RADS.

4.2. Clasificación BI-RADS

Respecto al cáncer de mama, los principales factores de riesgo [90] son la edad avanzada, la predisposición genética como la presencia de mutaciones BRCA-1 o BRCA-2, los cambios hormonales y un diagnóstico previo de carcinoma ductal in situ (DCIS).

La introducción de la clasificación BI-RADS [91] por el American College of Radiology (ACR) trae consigo una estandarización a la hora de evaluar exámenes de mamografías. Según sus características morfológicas, la clasificación BI-RADS se divide en 7 categorías como se muestra en la Tabla 4.1.

Categoría BI-RADS	Definición
0	Es necesario realizar una evaluación de imagen adicional y/o comparar con mamografías anteriores
1	Hallazgo negativo, es decir, no hay ninguna anomalía importante que reportar
2	Hallazgo benigno (no canceroso)
3	Hallazgo probablemente benigno. Se cuenta con una probabilidad mayor al 98 % de ser benigno
4	Hallazgo sospechoso, se sugiere realizar una biopsia. Esta categoría se divide en tres sub-categorías
4A	Baja sospecha de malignidad
4B	Moderada sospecha de malignidad
4C	Alta sospecha de malignidad
5	Anomalía altamente sugestiva de malignidad
6	Diagnóstico maligno comprobado por biopsia

Tabla 4.1: Clasificación BI-RADS.

Dado que se definen las clasificaciones de BI-RADS según la sospecha de benignidad o malignidad del hallazgo, este indicador resulta ser un excelente criterio para priorizar a los pacientes. Si bien los antecedentes médicos agregan información valiosa para priorizar pacientes y, sobretodo, a aquellos que no cuentan con exámenes que permitan hacer un diagnóstico, para el caso de priorizar reportes médicos de mamografías se considerará como el principal criterio.

4.3. Requerimientos del Sistema

Ya habiendo explicado el caso de uso y la importancia del clasificador BI-RADS, en la Tabla 4.2 se definen los requisitos funcionales y no funcionales con los que debería cumplir el sistema, los cuales fueron discutidos en conjunto a la FALP.

	Requisito	Descripción
Requisitos Funcionales	RF1	El sistema debe poder predecir la prioridad en aquellos informes donde no se indique explícitamente el BI-RADS
	RF2	El sistema debe solicitar los datos correspondientes del paciente al iniciar el análisis
	RF3	El sistema debe tener la capacidad de identificar los conceptos y diagnósticos médicos
	RF4	El sistema debe entregar información del historial de un paciente
	RF5	El sistema permitirá al médico visualizar a todos sus pacientes donde podrá ver toda la información de este incluyendo su nivel de prioridad
Requisitos No Funcionales	RNF1	El sistema no debe otorgar falsos negativos
	RNF2	El sistema debe poder funcionar montado en el servidor interno de la FALP

Tabla 4.2: Requisitos Funcionales y Requisitos No Funcionales.

Los requisitos funcionales describen lo que se espera del sistema y las salidas esperadas de este, especialmente la visualización de la información entregada. Además, el requisito no funcional más importante corresponde al RNF1, donde la FALP enfatiza en que no se deben entregar falsos negativos a la hora de predecir un nivel de prioridad de un paciente. Si el sistema entregara un falso negativo sobre una predicción de BI-RADS, esto significa que a un paciente se le está diciendo que no se encuentra en riesgo vital, cuando en realidad su caso es peor de lo predicho y no se prioriza correctamente debido a una mala predicción. Respecto al caso contrario, donde un paciente obtiene un valor de BI-RADS mayor al que le corresponde en realidad, no es un caso de riesgo el que ocurra esto. Por lo mismo, el primer caso descrito no puede ocurrir pues estos tienen un alto impacto negativo en la salud del paciente.

4.4. Requisitos de Ambiente y Diseño del Sistema

A continuación se mencionan los requisitos de hardware y software para el ambiente de desarrollo de la solución propuesta, indicando los distintos componentes utilizados. Además, se establecen los diagramas que proponen los diseños del sistema que muestran el flujo que debería tener y los usuarios a los que está dirigido.

4.4.1. Hardware y Software de Desarrollo

Para el desarrollo de este proyecto, no se requiere de hardware de alto rendimiento, como GPU o equipos de gama alta, ya que no se emplean redes neuronales ni procesamiento intensivo. Por lo tanto,

es factible llevar a cabo el trabajo utilizando computadoras personales estándar y los periféricos básicos, como mouse, teclado y pantalla, siempre y cuando sean compatibles con el software necesario.

En cuanto al software de desarrollo, se utilizaron diversas herramientas tecnológicas para la implementación del algoritmo de predicción y priorización de pacientes. Estas herramientas incluyen el lenguaje de programación Python 3 y las bibliotecas Jupyter, scikit-learn, Pandas, NumPy, TensorFlow, Spacy y MedSpacy. Además, para la visualización del sistema, se emplearon tecnologías como JavaScript, con un enfoque principal en React y Node.js para la implementación y despliegue del sistema.

4.4.2. Perfiles de Usuario

Para los perfiles de usuario descritos, la solución propuesta está dirigida específicamente al equipo médico que forma parte del proceso de análisis y diagnóstico de pacientes en el área oncológica y, en estricto rigor, especialistas en cáncer de mama. Si bien el equipo médico de ésta se compone por una gran cantidad de trabajadores que se encargan de distintas áreas que son importantes, se decidió describir el perfil de aquellos usuarios que tendrían contacto directo con los exámenes de los pacientes.

Usuario	Perfil				
	Socio-económico y Cultural	Ocupacional	Etario	Características físicas, fisiológicas, psicológicas	Otros
Médico Oncólogo	Trabajador en la FALP	Médico Oncólogo	25 - 65	Busca realizar su trabajo de forma más eficiente para así diagnosticar a un mayor número de pacientes en un menor tiempo	Profesional integral con conocimiento en el área oncológica, especialmente en el diagnóstico y tratamiento del cáncer de mama
Radiólogo	Trabajador en la FALP	Radiólogo Médico	25 - 65	Busca realizar su trabajo de forma más eficiente para así diagnosticar a un mayor número de pacientes en un menor tiempo	Profesional integral con conocimiento en el área oncológica, especialmente en el diagnóstico y tratamiento del cáncer de mama

Tabla 4.3: Perfiles de Usuario.

4.4.3. Diagrama de Contexto

En la Figura 4.1 se puede observar el flujo del problema mencionado en un principio, donde se integra el equipo técnico encargado de entregar los informes de los pacientes y la solución propuesta

este trabajo, donde los informes se envían a la plataforma y son procesados por ésta para luego ser entregados al equipo médico a cargo de los pacientes y puedan observar en detalle los casos de cada uno.




Figura 4.1: Diagrama de Contexto.

4.4.4. Diagrama de Arquitectura.

La Figura 4.2 ilustra de manera detallada los diversos módulos y componentes que integran la solución propuesta, así como los resultados esperados de la misma. El diagrama presenta una visión general del flujo de información, comenzando con la entrada de datos en el sistema. Estos datos son sometidos a un proceso de limpieza y extracción de valores de BI-RADS a través del módulo correspondiente. Posteriormente, en los casos en que esta información no se encuentra inicialmente disponible, se lleva a cabo la predicción de dicho valor. Finalmente, se procede a la priorización de los pacientes, tomando en consideración tanto el valor de BI-RADS como otros criterios relevantes.




Figura 4.2: Diagrama de Arquitectura.

Diagrama de Interfaz.

En la Figura 4.3, se presenta una representación visual del flujo que caracteriza la interfaz del sistema, destacando las diferentes acciones disponibles para el usuario. Entre estas acciones se incluye la posibilidad de filtrar la información por paciente y la capacidad de seleccionar la cantidad de pacientes que se muestran por página. Este diagrama proporciona una visión completa de la experiencia del usuario dentro de la interfaz del sistema.




Figura 4.3: Diagrama de Interfaz del Sistema.

Módulos

1. **Limpieza de Datos:** Este módulo permite corregir datos no válidos, incompletos o incorrectos, eliminación de caracteres o datos innecesarios.
 - **Alcance:** Es el comienzo de este proceso, donde se preparan los datos para ser utilizados en el análisis posterior.
 - **Restricciones:** Los informes deben contar con una extensión mínima.
 - **Estructura General:** Este módulo toma por entrada el dataset con los informes de exámenes, corrigiendo datos erróneos, eliminando caracteres innecesarios y estandarizando los datos.
2. **Identificación y Extracción de Clasificación BI-RADS:** Este módulo permite obtener la clasificación BI-RADS de los informes e identificar cuáles no cuentan con dicha clasificación.
 - **Alcance:** Esta etapa es el inicio del análisis, extrayendo los BI-RADS de los informes para poder ordenarlos por su prioridad e identificando aquellos que no cuentan con la clasificación BI-RADS para continuar hacia la predicción de prioridad.
 - **Restricciones:** Los valores de BI-RADS identificados deben estar dentro del rango 0-6 sino serán considerados como no clasificados.
 - **Estructura General:** Este módulo cuenta con el dataset limpio y estandarizado como entrada, para así realizar la búsqueda de la mención de BI-RADS en los informes y entregando

como salida dos dataset, uno con los informes donde se encontró la clasificación y otro donde se encuentran los informes sin clasificación.

3. **Predicción de Prioridad:** Predice la prioridad con la que cuenta un paciente cuando no se encuentra mención a su BI-RADS en el informe de mamografía.

- **Alcance:** Permite realizar una clasificación de prioridad a pacientes, en los que no se encuentra mención de cuál es su nivel de BI-RADS.
- **Restricciones:** Los resultados falsos negativos, es decir, cuando se predice una prioridad menor a la real deben ser mínimos.
- **Estructura General:** Toma por entrada los resultados del módulo *Identificación y Extracción de Clasificación BI-RADS*. A partir de estos datos se realizará la predicción de la categoría en la que se encuentra utilizando clasificadores.

4. **Asignación de Prioridad de los Pacientes:** Prioriza a los pacientes con cáncer de mama en base a su BI-RADS asociado.

- **Alcance:** Una vez realizada la extracción de BI-RADS, se encarga de asignar la prioridad en base a este valor a aquellos informes donde si se identificó su clasificación.
- **Restricciones:** En caso de haber puntajes similares, se debe obtener información de otras fuentes para decidir.
- **Estructura General:** A partir de la información obtenida, el módulo *Identificación y Extracción de Clasificación BI-RADS* realiza la priorización de los pacientes.

5. **Diseño de Interfaz:** Permite que el médico visualice la priorización y los datos de los pacientes que están a su cargo.

- **Alcance:** En este módulo se visualizarán los datos de los pacientes ordenados por la prioridad que les fue otorgada anteriormente.
- **Restricciones:** Todos los datos entregados a este módulo cuentan con una prioridad asignada.
- **Estructura General:** El médico puede elegir visualizar los datos de todos los pacientes, se mostrarán en una tabla con algunos datos personales y la prioridad que tienen. Por otro lado, podrá seleccionar un paciente en particular y se mostrará el historial de informes con lo que se podrá visualizar la evolución con el tiempo.

Una vez definidos los requisitos funcionales y los módulos del sistema, la Tabla 4.4 resume la relación directa entre los módulos descritos y los requisitos funcionales mencionados.

	Limpieza de Datos	Identificación y Extracción de BI-RADS	Predicción de Prioridad	Asignación de Prioridad de los Pacientes	Interfaz Usuaría
RF1			X		
RF2	X				
RF3		X		X	
RF4					X
RF5					X

Tabla 4.4: Matriz de Requisitos Funcionales y Módulos.

Capítulo 5

Implementación de la Interfaz de la Plataforma de Priorización

En este capítulo, se detalla el desarrollo de los módulos de limpieza de datos, priorización del sistema, predicción de BI-RADS y la interfaz gráfica. Se presenta un resumen conciso de las acciones llevadas a cabo para la limpieza del conjunto de datos y se exponen los resultados obtenidos mediante el sistema de priorización basado en la predicción de BI-RADS. Por último, se presentan dos interfaces visuales que se crearon en el transcurso del proceso: una interfaz preliminar y un prototipo funcional del sistema.

5.1. Limpieza de Datos

A partir del conjunto de datos entregado por la FALP, se procede a analizar la composición de éste. Se cuentan con cerca de 400.000 datos en total, el cual bajo una primera inspección cuenta con las siguientes características:

- Existen datos con dos menciones de BI-RADS.
- Existen datos sin mención de BI-RADS.
- Se identifica un gran grupo de datos duplicados.
- Se identifica un gran grupo de datos vacíos o sin información.
- En su mayoría los datos mencionan BI-RADS entre 0 y 2.

Luego de caracterizar el dataset, el siguiente paso fue realizar una limpieza de este quitando aquellos datos que no son de utilidad. En primera instancia se eliminaron los datos duplicados, se eliminan las tildes presentes y se estandariza el término BI-RADS, pues se encontraba descrito en algunos casos como “BI-RAD”, “BIRADS” e incluso “BI-RASD”. Luego se eliminan los pasos en la descripción de cada informe, los cuales indican cómo generar éstos y no ofrecen información relevante para la priorización de pacientes o predicción de BI-RADS.

Se obtiene un conjunto de aproximadamente 70.000 datos, donde el 99 % de estos cuentan con mención única de BI-RADS, y aproximadamente el 85 % cuentan con una clasificación entre 0 y 2.

5.2. Sistema de Priorización

Utilizando la información de las categorías de BI-RADS se pueden dividir 4 grupos de prioridad:

Nivel de prioridad	Descripción
Nula	Los informes que posean un nivel igual a 0, ya que esto no tiene relación con la gravedad de la enfermedad si no con la calidad del examen, indicando que se debe tomar de nuevo.
Baja	Todos aquellos que tengan un nivel 1 o 2.
Media	En este nivel estarán aquellos que cuenten con BI-RADS 3, se considera por separado al ser la etapa intermedia entre un hallazgo benigno y uno maligno (o con sospecha de malignidad).
Alta	Aquellos que tengan BI-RADS mayor a 3.

Tabla 5.1: Tabla de Niveles de Prioridad junto a su respectiva descripción.

Estableciendo estos niveles de prioridad, es necesario tener en cuenta las siguientes consideraciones para el desarrollo del sistema:

- Si bien los radiólogos deben anotar el BI-RADS en los informes de mamografía la realidad es que en muchas ocasiones no lo hacen, por lo que además se debe considerar la previa predicción de categoría.
- Si el paciente cuenta con BI-RADS distinto en cada mama, se considerará el nivel más alto entre estos para la priorización de este.
- Si el paciente tiene antecedentes de hallazgos malignos que ya han sido tratados, se prioriza en base a su historial debido a que contar con antecedentes de cáncer de mama es también un factor de riesgo. Por ejemplo si un paciente tenía BI-RADS 4, pero ahora es BI-RADS 2 se prioriza como categoría 4.

En la Sección 5.3 se tratará respecto a la predicción del BI-RADS de los pacientes y por qué es necesario realizar ésta.

5.3. Predicción de BI-RADS

Dentro del conjunto de muestras obtenidas previamente, aproximadamente el 1 % (alrededor de 600 casos) de estas no hacen referencia al BI-RADS. Esta situación, que es un problema recurrente según la fundación, es significativa, ya que requiere una respuesta rápida y evita la pérdida de tiempo en revisiones manuales individuales de todos los casos de pacientes, que es el método actual para abordar este problema.

Un aspecto adicional a considerar es la distribución real de las mamografías, tal como se determinó a partir de las muestras proporcionadas. Se observa que la mayoría de estas mamografías están clasificadas con valores BI-RADS entre 0 y 2 (constituyendo más del 80 % de las muestras). Por lo tanto, es muy probable que al seleccionar un informe al azar, este pertenezca a ese grupo. Esto implica que los informes de mayor interés, es decir, los casos con una mayor probabilidad de presentar cáncer, correspondientes a categorías de BI-RADS superiores a 3, representan porcentajes muy bajos en las muestras entregadas. En este contexto, la predicción de BI-RADS en base al informe adquiere una relevancia crítica de alto valor, especialmente para los casos que no mencionan explícitamente éste. No obstante, este módulo conlleva desafíos significativos, como la necesidad de minimizar al máximo los falsos negativos, dado que los informes médicos de los pacientes reflejan aspectos cruciales de sus vidas, cualquier error de diagnóstico en forma de falso negativo puede tener repercusiones directas en su calidad de vida.

Con el fin de formar un prototipo que pueda priorizar correctamente los informes de mamografía, se diseña un clasificador que tenga la capacidad de recibir estos informes sin menciones de BI-RADS y pueda identificarlos en uno de los niveles de priorización pre-establecidos.

5.3.1. Diseño

A partir del conjunto de 70.000 informes aproximadamente, el 70 % fue destinado a un dataset para “training”, mientras que el resto para un dataset de “testing”. Como se explicó en la Sección 5.1, la mayoría de los datos corresponden a casos de prioridad baja o nula, es decir, aquellos con valores BI-RADS de 0 a 2. Esto revela que la muestra está fuertemente sesgada hacia casos menos críticos, dejando una participación significativamente baja de casos de alta prioridad (valores 4 al 6), que son esenciales para realizar una priorización efectiva.

Considerando que los informes con valores de BI-RADS alto son muy escasos en comparación a los demás y la necesidad de evaluar el desempeño de estos al utilizarlos con herramientas de Aprendizaje Automático, se implementó lo siguiente:

1. Agrupar los datos por nivel de **prioridad** y balancear el dataset alrededor de la clase con menor cantidad (“down-sampling”).
2. Se utilizan los siguientes clasificadores de texto dada la incerteza de la calidad del dataset resultante: **Multiclass Naive Bayes (MNB)**, **Support Vector Machine (SVM)** y **K-Nearest Neighbors (KNN)**.

Tras haber agrupado y balanceado el dataset de entrenamiento, se obtuvo la Tabla 5.2:

BI-RADS	Cantidad	Prioridad
0	1147	0
1	573	1
2	573	1
3	1447	2
4	814	3
5	176	3
6	157	3
TOTAL	4587	-

Tabla 5.2: Distribución Dataset de Entrenamiento Balanceado.

5.4. Resultados de Clasificación

Como se introdujo en la Sección 5.3, se busca como solución diseñar e implementar un modelo de predicción de valor BI-RADS a partir del reporte de mamografías. Una vez implementados y entrenados éstos con los datos mencionados en dicha sección, se procedió a utilizar el dataset de testing y comparar el rendimiento de cada uno a través de matrices de confusión.

Cabe mencionar que al igual que el dataset de entrenamiento original, el de testing no se encuentra balanceado, teniendo la siguiente distribución de valores BI-RADS y prioridad (véase Tabla 5.3):

BI-RADS	Prioridad	Cantidad	Cantidad (Prioridad)
0	0	1.697	1.697
1	1	2.899	10.641
2		7.742	
3	2	1.915	1.915
4	3	272	380
5		55	
6		53	
Total		14.633	

Tabla 5.3: Distribución dataset de testing por BI-RADS y Prioridad.

El objetivo frente a estos resultados es encontrar aquel clasificador que sea menos propenso a falsos negativos en casos críticos, es decir, aquel que no identifique casos de prioridad 3 como prioridades más bajas. Los resultados obtenidos con estos clasificadores se pueden observar en la Figura 5.1




Figura 5.1: Matrices de Confusión de los Clasificadores a Evaluar.

Tras analizar los resultados de los clasificadores, se puede apreciar que KNN clasifica erróneamente en prioridades más bajas, MNB posee una menor proporción de informes con prioridad 3 mal clasificados

en comparación a KNN, mientras que SVM Lineal tiene una cantidad mínima de casos con prioridad 3 mal clasificados. Dicho lo anterior, se decide utilizar el clasificador SVM debido a su rendimiento frente a los falsos negativos críticos.

Para realizar una comparación en mayor profundidad entre distintos kernels de SVM, se procedió a obtener la precisión y *recall* de las clases de mayor importancia para cada uno de los modelos SVM probados (véase Figura 5.2).




Figura 5.2: Análisis según Clases de Prioridad.

A partir de los resultados obtenidos, en términos de precisión y diagnóstico, es menos grave emitir un diagnóstico negativo a una persona saludable que un diagnóstico positivo a una persona con un estado de salud deteriorado. Por lo tanto, esta métrica, aunque no sea la más crucial en una primera aproximación a la solución, sigue siendo un aspecto que merece atención y mejora. En este contexto, se observa que el SVM Lineal demuestra un desempeño superior, alcanzando valores de precisión más elevados en la mayoría de las clases.

5.5. Interfaz Gráfica

A partir de los requisitos levantados, de lo que la plataforma debe mostrar al ingresar a esta. Esto fue un proceso donde se le presentó una vista preliminar de lo que podría ser la interfaz que observaría el usuario y que fue modificada conforme a los comentarios recibidos por diversos miembros de la fundación.

5.5.1. Interfaz Preliminar

En una primera iteración, la interfaz consistía en HTML plano el cual tenía como primera vista un menú principal (véase Subfigura 5.3a) que muestra al usuario 3 opciones:




Figura 5.3: Menú Principal y Desplegable de Categoría BI-RADS.

Las descripciones de cada elemento en esta vista se pueden apreciar en la Tabla 5.4.

Elemento	Descripción
Reportes Médicos	Desplegable que muestra 6 niveles de BI-RADS que el usuario puede elegir para poder observar sólo el nivel seleccionado en una tabla (véase Subfigura 5.3).
Buscar Pacientes	Un buscador que permite mostrar todos los informes relacionados a un paciente.
Estadísticas Informes	Esta opción permite al usuario observar gráficamente estadísticas relacionadas a todos los informes en general, como por ejemplo el número de informes por BI-RADS.

Tabla 5.4: Descripciones de los Elementos en la Vista Principal.

Cuando el usuario, por ejemplo, selecciona la opción 4 de Reportes Médicos, se despliega la siguiente vista correspondiente a una tabla con todos los informes médicos categorizados con BI-RADS 4 como se puede observar en la Figura 5.4 con mayor claridad.

Tabla de Mamografías				
Show 10 entries		Search:		
Name/ID	Tipo Informe	Fecha	BIRADS	Diagnostico
AALT80351648555363	MAMOGRAFIA PROY.COMPLEM.(2UD)	2021-05-14 11:06:51	4	-
ABCE47879394706071	Screening-Bilateral Mammography	2019-10-15 14:23:46	4	-
ABOJ69868755987014	MAMOGRAFIA BILATERAL	2021-02-04 14:35:52	4	-
ADAW91082506260543	MAMOGRAFIA PROY.COMPLEM.(2UD)	2022-01-12 10:33:57	4	-
AFXR20510893195773	MAMOGRAFIA BILATERAL	2021-03-04 09:39:31	4	CS0
AGYA67607585940169	MAMOGRAFIA BILATERAL.	2022-07-13 15:11:18	4	-
AHQQ36940234845330	MAMOGRAFIA BILATERAL.	2021-09-23 14:16:04	4	CS0
AIPQ26465564568446	MAMOGRAFIA PROY.COMPLEM.(2UD)	2021-07-19 16:39:30	4	-
AJRO95445712218299	MAMOGRAFIA BILATERAL	2021-01-22 12:56:37	4	-
ALEW25420600610089	MAMOGRAFIA BILATERAL	2022-03-07 12:49:12	4	-
Showing 1 to 10 of 482 entries		Previous	1	2 3 4 5 ... 49 Next

Figura 5.4: Tabla de Reportes Médicos según BI-RADS seleccionado, en este caso 4.

Como parte de los comentarios que fueron recibidos respecto a esta interfaz preliminar, se mencionan las correcciones a los requisitos en la Tabla 5.5.

Corrección	Descripción
Exceso de Información	La interfaz cuenta con información que no es relevante a la hora de tomar decisiones, por lo que entorpece la vista de los informes.
Detalle de Informes	Debería ser posible visibilizar la descripción detallada de cada informe.
Búsqueda de Pacientes	El buscador es de utilidad, debería permanecer para la búsqueda de pacientes.
Vista General	Deberían poder visualizarse todos los pacientes en lugar de elegir un grupo específico.
Estadísticas de Informes	Las estadísticas de los informes podrían resultar de interés.
Gestión de Archivos	Falta una gestión de archivos que permita al usuario subir los datos que desea que sean priorizados.

Tabla 5.5: Correcciones de los Requisitos.

Estas correcciones representaron nuevos enfoques clave que influyeron significativamente en la implementación del diseño final de la interfaz del sistema. En consecuencia, muchos de estos elementos desempeñaron un papel crucial en la definición de la forma definitiva de la interfaz del sistema.

En relación a las evaluaciones y comentarios recibidos con respecto a la experiencia de usuario y el diseño de la interfaz gráfica, es relevante destacar que no se han identificado observaciones específicas

que sugieran la necesidad de implementar colores o logotipos distintivos que denoten la afiliación de este sistema con la fundación. Los usuarios no han planteado requerimientos particulares en cuanto a esquemas de color específicos o elementos visuales que vinculen directamente el sistema con la identidad de la fundación. Esto se interpreta como un signo de que la interfaz actualmente cumple con estándares de usabilidad y diseño visual, lo que refuerza la noción de que el diseño ha sido efectivamente concebido con un enfoque centrado en el usuario. Sin embargo, se encuentra sujeto a futuras recomendaciones que puedan surgir a medida que el sistema se implemente y utilice de manera más amplia, con el objetivo de optimizar la experiencia del usuario.

5.5.2. Interfaz Final

Considerando las correcciones obtenidas en la primera iteración mostrada al equipo, estos fueron implementadas para lo que corresponde la segunda iteración de la interfaz del sistema, donde se pasó del ambiente en *HTML* puro a una aplicación hecha con *React*, utilizando *JavaScript*, *CSS* y *MUI* para el diseño de las vistas del usuario con el fin de obtener un nivel de claridad visual mayor para el usuario.

Para esta interfaz, se cuenta con dos vistas principales que engloban todo el proceso. La primera se encarga de la gestión de datos la que permite el flujo del procesamiento de éstos para su posterior predicción y priorización, mientras que la segunda se encarga de mostrar los datos ya procesados en una tabla.

Gestión de Archivos

Como se muestra en la Figura 5.5, la gestión de archivos permite al usuario subir un archivo de formato *.xlsx* con una serie de columnas específicas para ser procesadas por el algoritmo de predicción y priorización.





Figura 5.5: Interfaz Gestión de Archivos.

Vista General de Pacientes Priorizados

La segunda vista que se observa en la Figura 5.6 corresponde a la tabla que muestra todos los pacientes ordenados por prioridad, junto con las características que mejor detallan de forma rápida al paciente:



	ID	Fecha Firma	Edad	BI-RADS	Prioridad
▼	TGTU76258497286118	2022-07-20 13:52:45	49	4	3
▼	EVXX19000216253529	2022-07-19 14:36:09	48	6	3
▼	NFX080876093234902	2022-07-18 14:54:14	60	5	3
▼	LWKM11768981521245	2022-07-15 15:18:33	40	4	3
▼	ALCM31612277790745	2022-07-15 15:12:57	44	6	3
▼	XLDN03678184193964	2022-07-15 13:24:59	63	6	3
▼	XLDN03678184193964	2022-07-15 13:22:41	63	6	3
▼	IBNM4394281Z784748	2022-07-15 10:50:58	46	4	3
▼	EMWD33108393830995	2022-07-14 14:54:47	61	5	3
▼	LTYD69286272706920	2022-07-14 12:39:58	55	4	3


Figura 5.6: Interfaz Visualización de Pacientes Priorizados en Tabla.

Las descripciones de las columnas de la tabla de esta vista se pueden apreciar en la Tabla 5.6.

Elemento	Descripción
ID	Indica el ID asignado al paciente
Fecha Firma	Indica la fecha en que se ingresa el informe al sistema de FALP
Edad	Indica la edad del paciente a la fecha de ingreso a FALP
BI-RADS	Indica el BI-RADS asignado al paciente
Prioridad	Indica el nivel de prioridad asignado al paciente

Tabla 5.6: Descripción de Elementos en Vista General.

A partir de esta vista, es posible acceder al detalle de cada informe que se observa, cuya acción es realizada al hacer click en la flecha izquierda que se encuentra al lado de cada informe (Ver Figura 5.7). Esto despliega el informe en la misma vista y permite mostrar múltiples detalles a la vez, los cuales pueden ser ocultados al volver a hacer click en el mismo botón.




	ID	Fecha Firma	Edad	BI-RADS	Prioridad
▼	TGTU76258497286118	2022-07-20 13:52:45	49	4	3
▲	EVXX19000216253529	2022-07-19 14:36:09	48	6	3
Informe mamografía bilateral biads 6 paciente de 48 años con antecedente de cáncer mamario izquierdo en tratamiento con quimioterapia neoadyuvante desde octubre del año 2021 antecedentes familiares de cáncer de mamas se dispone de mamografía y ecotomografía de octubre del año 2021 acr c piel y tejido celular subcutáneo sin alteraciones parenquima glandular mamario heterogeneamente denso el nódulo visible en el cuadrante superior externo de la mama izquierda asociado a una distorsión de la arquitectura ya no es evidente como tal y en la actualidad se observa una discreta distorsión de la arquitectura asociada a microcalcificaciones que se extiende por aproximadamente 36 mm en la unión de los cuadrantes externos de la mama derecha en el tercio posterior se observa un tenue nódulo ovalado de bordes visibles bien definidos de 10 mm que corresponde a un quiste sin ecotomografía contemporánea en la región axilar izquierda se observa clip de marcación que impresiona estar adyacente a un linfonodo no control quimioterapia neoadyuvante con respuesta patológica parcial mayor de los hallazgos descritos en la mama izquierda y en la región axilar ipsilateral nódulo mamario derecho benigno que corresponde a un quiste en ecotomografía contemporánea biads 6 acr c					
▼	NFXH80876093234902	2022-07-18 14:54:14	60	5	3
▼	LWKM11768981521245	2022-07-15 15:18:33	40	4	3
▼	ALCM3161227790745	2022-07-15 15:12:57	44	6	3
▼	XLDN03678184193964	2022-07-15 13:24:59	63	6	3
▼	XLDN03678184193964	2022-07-15 13:22:41	63	6	3
▼	IBNM43942812784748	2022-07-15 10:50:58	46	4	3

Figura 5.7: Tabla de Pacientes Priorizados con Detalle de Informe.

Filtro y Navegación

Se mantiene la funcionalidad de búsqueda de pacientes, donde es posible escribir parte del ID en la barra de búsqueda ubicada en la parte superior de la tabla como se observa en la Figura 5.8, lo cual irá filtrando esta a medida que el usuario escriba.




X	ID	Fecha Firma	Edad	BI-RADS	Prioridad
▼	MNHV75760570880612	2022-03-23 10:13:15	64	-1	3
▼	MNHV75760570880612	2022-03-23 09:22:09	64	4	3

Filas (10) 1-10 of 20583

Figura 5.8: Detalle de Buscador de Pacientes por ID.

También es posible filtrar a los pacientes rápidamente haciendo click en su ID correspondiente. Esta acción filtra la tabla rápidamente y muestra todos los informes que le corresponden a dicho paciente. Para quitar este filtro es posible volver a hacer click en el ID del usuario, como también es posible borrar el ID en la barra de búsqueda o haciendo click en la “X” que se encuentra en la esquina superior izquierda de la tabla, al lado de la barra de búsqueda. En la Figura 5.9 se aprecia el resultado de hacer click en un ID en la tabla como se describió previamente.



The screenshot shows the FALP (Federated Access to Local Patient) interface. On the left is a sidebar with a menu containing 'Cargar Archivo', 'Tabla', and 'Informes'. The main area displays a table of prioritized patients. The table has a search bar at the top with the filter 'XLDN03678184193964' applied. The table columns are: ID, Fecha Firma, Edad, BI-RADS, and Prioridad. There are three rows of data, all with the same ID and priority. At the bottom left of the table is a 'Filas' dropdown menu set to 10, and at the bottom right is a pagination indicator '1-10 of 20583'.

ID	Fecha Firma	Edad	BI-RADS	Prioridad
XLDN03678184193964	2022-07-15 13:24:59	63	6	3
XLDN03678184193964	2022-07-15 13:22:41	63	6	3
XLDN03678184193964	2022-01-05 08:51:47	63	6	3

Figura 5.9: Tabla de Pacientes Priorizados con Filtro por ID de Paciente Específico.

Otra característica que se mantiene de la interfaz preliminar corresponde a la configuración de filas por página de la tabla, donde el usuario puede elegir entre 10, 20 o 50 datos por página. Esta opción se puede observar en el la esquina inferior izquierda de la tabla (véase Figura 5.10).




Figura 5.10: Detalle de Filas por Página.

En la Figura 5.11 se muestra un ejemplo de la tabla de pacientes priorizados configurado para que muestre 20 filas por páginas.

CAPÍTULO 5. IMPLEMENTACIÓN DE LA INTERFAZ DE LA PLATAFORMA DE PRIORIZACIÓN

	ID	Fecha Firma	Edad	BI-RADS	Prioridad
▼	TGTU76258497286118	2022-07-20 13:52:45	49	4	3
▼	EVXX19000216253529	2022-07-19 14:36:09	48	6	3
▼	NFHX80876093234902	2022-07-18 14:54:14	60	5	3
▼	LWKM11768981521245	2022-07-15 15:18:33	40	4	3
▼	ALCM31612277790745	2022-07-15 15:12:57	44	6	3
▼	XLDN03678184193964	2022-07-15 13:24:59	63	6	3
▼	XLDN03678184193964	2022-07-15 13:22:41	63	6	3
▼	IBNM43942812784748	2022-07-15 10:50:58	46	4	3
▼	EMWD33108393830995	2022-07-14 14:54:47	61	5	3
▼	LJVD69286272706920	2022-07-14 12:39:58	55	4	3
▼	WQFT47953846104639	2022-07-14 09:34:03	54	4	3
▼	TCDF79417564851435	2022-07-13 15:28:43	49	4	3
▼	GHKB15448422092069	2022-07-13 15:11:18	61	4	3
▼	IQBG94636441713646	2022-07-12 10:59:32	38	6	3
▼	HZFT64663250328574	2022-07-12 09:49:12	58	5	3
▼	GFTP74352104020165	2022-07-11 11:08:25	62	4	3
▼	PFLC83664918219688	2022-07-11 09:40:30	52	5	3
▼	MXRV81095963368633	2022-07-08 12:35:43	56	4	3
▼	VACN59780367140766	2022-07-07 10:43:54	72	6	3
▼	FUWX12250475005152	2022-07-06 13:09:07	72	4	3

Filas (20) 1-20 of 20583

Figura 5.11: Tabla Configurada para 20 Filas por Página.

Capítulo 6

Conclusiones

La utilidad que ofrece una plataforma para la priorización de pacientes resulta de gran valor al tomar decisiones sobre quiénes deben ser atendidos primero, permitiendo la posibilidad de brindar tratamientos curativos que mejoren su calidad de vida.

Durante el desarrollo de la solución para abordar el desafío propuesto, se llevaron a cabo diversas exploraciones que pusieron de manifiesto la amplia gama de enfoques posibles para resolver un problema de esta índole, adaptándose a las condiciones específicas de cada caso. En este proyecto la utilización de herramientas de manejo de datos a través de *Python*, aprendizaje supervisado de *sklearn* y una interfaz utilizando *React* fueron la decisión acertada.

Este trabajo ha logrado exitosamente desarrollar una plataforma integral que aborda la visualización y priorización de pacientes con cáncer de mama, cumpliendo con las expectativas y requisitos de la FALP. Esta plataforma consta de tres módulos fundamentales diseñados para gestionar, priorizar y presentar los datos de manera eficiente.

El primer módulo se encarga de realizar una limpieza exhaustiva de los informes médicos proporcionados, así como de extraer los valores de BI-RADS contenidos en ellos. El segundo módulo tiene la tarea de predecir el valor de BI-RADS en aquellos casos donde no se hace mención de este. Una vez obtenida esta predicción, se procede a priorizar a los pacientes en función de la información disponible en los informes.

El tercer módulo, es el componente clave que integra los módulos mencionados anteriormente. A través de una interfaz visual intuitiva, este módulo gestiona todo el proceso, desde la administración de archivos de datos hasta la presentación de la lista completa de pacientes priorizados.

Es importante destacar que, si bien la FALP dispone de un extenso conjunto de datos médicos de pacientes con cáncer de mama, pero que a la vez presenta diversos desafíos. Los datos no están balanceados, lo que significa que la mayoría de las muestras se refieren a casos con clasificaciones BI-RADS de 3 o inferiores, mientras que hay una cantidad extremadamente baja de casos con clasificaciones por encima de 3, que son de mayor interés para este proyecto. La información entregada por la FALP está acotada por la naturaleza de los datos y está afecta a la intervención humana, y dado que la forma de acatar el cáncer de mama es a través de carácter preventivo, es natural que los datos estén inclinados hacia pacientes sanos mayoritariamente.

6.1. Trabajo Futuro

A partir de las distintas exploraciones llevadas a cabo durante el desarrollo de esta memoria es posible identificar algunos puntos de interés para futuras exploraciones dentro que conciernen a este tema y podrían ser de gran utilidad:

- **La utilización de herramientas para trabajar con NLP:** usar MedSpaCy en un principio se veía como una alternativa muy tentadora, pero el hecho de estar en inglés exclusivamente trae consigo un desafío adicional que el equipo de trabajo no puede resolver pues trata de una tarea de traducción de términos médicos. Esta debería realizarse con la asistencia de traductores que dominen el idioma y médicos que identifiquen correctamente los términos del inglés al español y viceversa. No es un trabajo sencillo que el equipo podía realizar dado que no cuentan con los conocimientos necesarios para realizar esta labor y, por ende, este trabajo queda como un desafío pendiente pues MedSpaCy muestra ser una alternativa prometedora para la identificación de términos importantes dentro de textos médicos, permitiendo una priorización que tomara una mayor cantidad de variables mas que el clasificador BI-RADS.
- **Priorización de Pacientes:** este punto tiene relación también con el problema descrito en el punto anterior, donde una mejora que podría implementarse corresponde a una mejor priorización. Esto pues el conjunto de informes no es homogéneo y los datos obtenidos a través de éstos varían en gran magnitud, donde existen informes que indican el historial médico del paciente y se detallan los hallazgos encontrados en la mamografía, como también existen informes que no mencionan el BI-RADS, la edad del paciente o no hacen comentarios sobre hallazgos en la mamografía. Dada esta ambigüedad en el dataset, se asume que la gran mayoría de los informes no cuentan con un alto detalle de información y, por lo mismo, se decide utilizar el BI-RADS como principal discriminador para priorizar a los pacientes. Una alternativa para resolver este

problema se asocia con el segundo trabajo a futuro mencionado, donde el dataset no sólo debe tener una mayor cantidad de datos y un balance entre las clases, sino que también la calidad de este dataset debe ser mejorada. Esto quiere decir que los informes médicos sean homogéneos y tengan una estructura similar respecto a la información que contienen, para así poder integrar otros aspectos a la hora de priorizar a los pacientes con el fin de evitar sesgar los casos con una baja cantidad de discriminadores, pudiendo entregar una priorización eficiente y más acorde a la situación de cada paciente.

Bibliografía

- [1] Instituto Nacional de Estadísticas. *Anuario de Estadísticas Vitales, 2019*. URL: https://www.ine.gob.cl/docs/default-source/nacimientos-matrimonios-y-defunciones/publicaciones-y-anuarios/anuarios-de-estad%C3%ADsticas-vitales/anuario-de-estad%C3%ADsticas-vitales-2019.pdf?sfvrsn=97729b7b_5.
- [2] *International Agency for Research on Cancer*. URL: <https://gco.iarc.fr/today/home>.
- [3] Jeremy Hurst y Luigi Siciliani. "Tackling excessive waiting times for elective surgery: a comparison of policies in twelve OECD countries". En: (2003).
- [4] Ilana N Ackerman, Kim L Bennell y Richard H Osborne. "Decline in health-related quality of life reported by more than half of those waiting for joint replacement surgery: a prospective cohort study". En: *BMC Musculoskeletal Disorders* 12 (2011).
- [5] David C Hador, Steering Committee of the Western Canada Waiting List Project et al. "Setting priorities for waiting lists: defining our terms". En: *Cmaj* 163.7 (2000).
- [6] CW Wallesch. "Prioritization: the clinical perspective". En: *Die Rehabilitation* 51.2 (2012).
- [7] Tom W Noseworthy, John J McGurran, David C Hadorn y Steering Committee of the Western Canada Waiting List Project. "Waiting for scheduled services in Canada: development of priority-setting scoring systems". En: *Journal of evaluation in clinical practice* 9.1 (2003).
- [8] Katherine E Harding, Nicholas F Taylor y Sandra G Leggat. "Do triage systems in healthcare improve patient flow? A systematic review of the literature". En: *Australian Health Review* 35.3 (2011).
- [9] Katherine E Harding, Nicholas F Taylor, Sandra G Leggat y Vicki L Wise. "Prioritizing patients for community rehabilitation services: do clinicians agree on triage decisions?" En: *Clinical rehabilitation* 24.10 (2010).

- [10] Laura A Passalent, Michel D Landry y Cheryl A Cott. “Wait times for publicly funded outpatient and community physiotherapy and occupational therapy services: implications for the increasing number of persons with chronic conditions in Ontario, Canada”. En: *Physiotherapy Canada* 61.1 (2009).
- [11] Mark C Taylor, David C Hadorn, Steering Committee of the Western Canada Waiting List Project et al. “Developing priority criteria for general surgery: results from the Western Canada Waiting List Project”. En: *Canadian journal of surgery* 45.5 (2002).
- [12] David C Hahorn. “Developing priority criteria for magnetic resonance imaging: results from the Western Canada Waiting List Project”. En: *Canadian Association of Radiologists Journal* 53.4 (2002).
- [13] Derryck H Smith, David C Hadorn, Steering Committee of the Western Canada Waiting List Project et al. “Lining up for children’s mental health services: A tool for prioritizing waiting lists”. En: *Journal of the American Academy of Child & Adolescent Psychiatry* 41.4 (2002).
- [14] Hannah Eyre, Alec B Chapman, Kelly S Peterson, Jianlin Shi, Patrick R Alba, Makoto M Jones, Tamara L Box, Scott L DuVall y Olga V Patterson. “Launching into clinical space with medspaCy: a new clinical text processing toolkit in Python”. En: *AMIA Annual Symposium Proceedings*. Vol. 2021. American Medical Informatics Association. 2021.
- [15] Omar D. Castrillón, Eduardo Castaño, Luis F. Castillo. “Sistema Predictivo Bayesiano para Detección del Cáncer de Mama”. En: *Información Tecnológica* 29.3 (2018). DOI: 10.4067/S0718-07642018000300257.
- [16] A Bonk, H Siebert, A Seekamp y R Hoffmann. “Triage-Systeme in der Zentralen Notfallaufnahme”. En: *Der Unfallchirurg* 4.112 (2009).
- [17] LA Wallis, SB Gottschalk, D Wood, S Bruijns, S De Vries y C Balfour. “The cape triage score-a triage system for South Africa”. En: *South African Medical Journal* 96.1 (2006), págs. 53-56.
- [18] SR Bruijns, LA Wallis y VC Burch. “Effect of introduction of nurse triage on waiting”. En: ().
- [19] Robert Beveridge, Barbara Clarke, Laurie Janes, Nancy Savage, Jim Thompson, Graham Dodd, Michael Murray, Cheri Nijssen Jordan, David Warren y Alain Vadeboncoeur. “Implementation guidelines for the Canadian emergency department Triage & Acuity Scale (CTAS)”. En: *Canadian association of emergency physicians* (1998), págs. 1-32.
- [20] *Emergency Severity Index, Version 4: Implementation Handbook*. URL: https://www.sgnor.ch/fileadmin/user_upload/Dokumente/Downloads/Esi_Handbook.pdf.
- [21] Rachel J Hunter, Nicholas Buckley, Eve L Fitzgerald, Andrew D MacCormick y Tim W Eglinton. “General surgery prioritization tool: a pilot study”. En: *ANZ journal of surgery* 88.12 (2018).

- [22] J Dery, A Ruiz, F Routhier, MP Gagnon, A Cote, D Ait-Kadi y ME Lamontagne. *Patient prioritization tools and their effectiveness in non-emergency healthcare services: A systematic review protocol. Systematic Reviews*, 8, 78. 2019.
- [23] Andrew D McCormick, Wayne G Collecutt y Bryan R Parry. “Prioritizing patients for elective surgery: a systematic review”. En: *ANZ Journal of Surgery* 73.8 (2003).
- [24] Steven Globerman, Nadeem Esmail, Brian Day y David Henderson. “Reducing wait times for health care: what Canada can learn from theory and international experience”. En: *Fraser Institute*, October (2013).
- [25] Colin M Feek. “Rationing healthcare in New Zealand: the use of clinical guidelines.” En: *The Medical Journal of Australia* 173.8 (2000).
- [26] *Waiting List: Average Waiting Time (weeks) By Priority as of 31 March 2023*. URL: <https://www.countiesmanukau.health.nz/for-health-professionals/waiting-list/>.
- [27] *Auckland algorithm improves equity of waitlists*. URL: <https://www.hinz.org.nz/news/642771/Auckland-algorithm-improves-equity-of-waitlists.htm>.
- [28] Adjei Peter Darko y Decui Liang. “Probabilistic linguistic WASPAS method for patients’ prioritization by developing prioritized Maclaurin symmetric mean aggregation operators”. En: *Applied Intelligence* (2022).
- [29] Cheng Zhang, Xingli Wu, Di Wu, Huchang Liao, Li Luo y Enrique Herrera-Viedma. “An intuitionistic multiplicative ORESTE method for patients’ prioritization of hospitalization”. En: *International Journal of Environmental Research and Public Health* 15.4 (2018).
- [30] Meimei Xia, Zeshui Xu y Huchang Liao. “Preference relations based on intuitionistic multiplicative information”. En: *IEEE Transactions on Fuzzy Systems* 21.1 (2012).
- [31] Giuseppe Curigliano, Maria Joao Cardoso, Philip Poortmans, Oreste Gentilini, Gabriella Pravettoni, Ketti Mazzocco, Nehmat Houssami, Olivia Pagani, Elzbieta Senkus y Fatima Cardoso. “Recommendations for triage, prioritization and treatment of breast cancer patients during the COVID-19 pandemic”. En: *The Breast* 52 (2020). ISSN: 0960-9776. DOI: <https://doi.org/10.1016/j.breast.2020.04.006>. URL: <https://www.sciencedirect.com/science/article/pii/S096097762030093X>.
- [32] *Coronavirus disease 2019 (COVID-19) pandemic: increased transmission in the EU/EEA and the UK – seventh update, 25 March 2020*. Stockholm: ECDC; 2020. URL: <https://www.ecdc.europa.eu/en/publications-data/rapid-risk-assessment-coronavirus-disease-2019-covid-19-pandemic>.

- [33] Andrea Remuzzi y Giuseppe Remuzzi. “COVID-19 and Italy: what next?” En: *The lancet* 395.10231 (2020).
- [34] *GLOSA 06: Lista de Espera No Ges, Garantías de Oportunidad GES Retrasadas y Análisis Epidemiológicos y Causas de Muerte de Personas Fallecidas estand en Lista de Espera No Ges*. URL: <https://www.minsal.cl/wp-content/uploads/2021/02/ORD-353-DIGERA-Glosa-06.pdf>.
- [35] C Mitrano y F Peñafiel. “Estratificación de riesgo (Triage) en el Servicio de Urgencia”. En: *Rev Chilena de Med intensiva* 30.2 (2015).
- [36] Nicola Parenti, Maria Letizia Bacchi Reggiani, Primiano Iannone, Daniela Percudani y Dawn Dowding. “A systematic review on the validity and reliability of an emergency department triage scale, the Manchester Triage System”. En: *International journal of nursing studies* 51.7 (2014), págs. 1062-1069.
- [37] Alejandro Letelier y Gustavo Cifuentes. “Situación y abordaje de lista de espera en un establecimiento de salud público en Santiago de Chile”. En: *Medwave.[Internet]* 14.6 (2014).
- [38] Diego A Martinez, Haoxiang Zhang, Magdalena Bastias, Felipe Feijoo, Jeremiah Hinson, Rodrigo Martinez, Jocelyn Dunstan, Scott Levin y Diana Prieto. “Prolonged wait time is associated with increased mortality for Chilean waiting list patients with non-prioritized conditions”. En: *BMC public health* 19.1 (2019), págs. 1-11.
- [39] C Serra, R Martinez, S Mimica y S Aguayo. “Is it possible to decrease breast cancer mortality in Chile? An analytical study”. En: *REVISTA CHILENA DE CIRUGIA* 62.4 (2010).
- [40] Enea Parimbelli, Szymon Wilk, Ronald Cornet, Pawel Sniatala, K Sniatala, SLC Glaser, Itske Fraterman, Annelies H Boekhout, Manuel Ottaviano y Mor Peleg. “A review of AI and Data Science support for cancer management”. En: *Artificial Intelligence in Medicine* 117 (2021), pág. 102111.
- [41] Pei-Hao Wu, Avon Yu, Ching-Wei Tsai, Jia-Ling Koh, Chin-Chi Kuo y Arbee LP Chen. “Keyword extraction and structuralization of medical reports”. En: *Health Information Science and Systems* 8 (2020), págs. 1-25.
- [42] Kento Sugimoto, Toshihiro Takeda, Jong-Hoon Oh, Shoya Wada, Shozo Konishi, Asuka Yamahata, Shiro Manabe, Noriyuki Tomiyama, Takashi Matsunaga, Katsuyuki Nakanishi et al. “Extracting clinical terms from radiology reports with deep learning”. En: *Journal of Biomedical Informatics* 116 (2021), pág. 103729.
- [43] Guillaume Lample, Miguel Ballesteros, Sandeep Subramanian, Kazuya Kawakami y Chris Dyer. “Neural architectures for named entity recognition”. En: *arXiv preprint arXiv:1603.01360* (2016).

- [44] Mostafa Boroumandzadeh y Elham Parvinnia. “Automated classification of BI-RADS in textual mammography reports”. En: *Turkish Journal of Electrical Engineering and Computer Sciences* 29.2 (2021), págs. 632-647.
- [45] Kai Hu, Qing Luo, Kunlun Qi, Siluo Yang, Jin Mao, Xiaokang Fu, Jie Zheng, Huayi Wu, Ya Guo y Qibing Zhu. “Understanding the topic evolution of scientific literatures like an evolving city: Using Google Word2Vec model and spatial autocorrelation analysis”. En: *Information Processing & Management* 56.4 (2019), págs. 1185-1203.
- [46] Ashwin Ittoo y Gosse Bouma. “Term extraction from sparse, ungrammatical domain-specific documents”. En: *Expert Systems with Applications* 40.7 (2013), págs. 2530-2540.
- [47] Sergio M Castro, Eugene Tseytlin, Olga Medvedeva, Kevin Mitchell, Shyam Visweswaran, Tanja Bekhuis y Rebecca S Jacobson. “Automated annotation and classification of BI-RADS assessment from radiology reports”. En: *Journal of biomedical informatics* 69 (2017), págs. 177-187.
- [48] *What is natural language processing?* URL: <https://www.ibm.com/topics/natural-language-processing>.
- [49] Neeraj Agarwal. *The Ultimate Guide To Different Word Embedding Techniques In NLP*. URL: <https://www.kdnuggets.com/2021/11/guide-word-embedding-techniques-nlp.html>.
- [50] Sujana Subendran. “Using Natural Language Processing to Detect Breast Cancer Recurrence in Clinical Notes: A Hierarchical Machine Learning Approach”. En: *UWSpace* (2021). DOI: <http://hdl.handle.net/10012/16903>.
- [51] Apache cTAKESTM. URL: <https://ctakes.apache.org/index.html>.
- [52] Zhilin Yang, Zihang Dai, Yiming Yang, Jaime Carbonell, Ruslan Salakhutdinov and Quoc V Le. “XLNet: Generalized Autoregressive Pretraining for Language Understanding”. En: *arXiv* (2020). DOI: <https://doi.org/10.48550/arXiv.1906.08237>.
- [53] Jacob Devlin, Ming-Wei Chang, Kenton Lee and Kristina Toutanova. “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”. En: *arXiv* (2019). DOI: <https://doi.org/10.48550/arXiv.1810.04805>.
- [54] Rani Horev. *BERT Explained: State of the art language model for NLP*. URL: <https://towardsdatascience.com/bert-explained-state-of-the-art-language-model-for-nlp-f8b21a9b6270>.
- [55] Zihang Dai, Zhilin Yang, Yiming Yang, Jaime Carbonell, Quoc V Le y Ruslan Salakhutdinov. “Transformer-xl: Attentive language models beyond a fixed-length context”. En: *arXiv preprint arXiv:1901.02860* (2019).

- [56] G. McGoldrick, Y. Cao and S. Prince. *Understanding XLNet*. URL: <https://www.borealisai.com/en/blog/understanding-xlnet/>.
- [57] Sicheng Zhou, Liwei Wang, Nan Wang, Hongfang Liu and Rui Zhang. “CancerBERT: a BERT model for Extracting Breast Cancer Phenotypes from Electronic Health Records”. En: *arXiv* (2022). DOI: <https://doi.org/10.48550/arXiv.2108.11303>.
- [58] Kexin Huang, Abhishek Singh, Sitong Chen, Edward T. Moseley, Chih-ying Deng, Naomi George and Charlotta Lindvall. “BERT Explained: State of the art language model for NLP”. En: *arXiv* (2019). DOI: <https://doi.org/10.48550/arXiv.1912.11975>.
- [59] C. Friedman, P. Alderson, J. Austin, J. Cimino, S. Johnson. “A general natural-language text processor for clinical radiology”. En: (1994). DOI: <https://doi.org/10.1136/jamia.1994.95236146>.
- [60] National Center for Biomedical Computing I2B2. *Health Information Text Extraction*. URL: https://www.i2b2.org/software/projects/hitex/hitex_manual.html.
- [61] Cunningham H, Humphreys K, Gaizauskas R, Wilks Y. *General Architecture for Text Engineering*. URL: <https://gate.ac.uk/>.
- [62] Hossein Naseri, Kamran Kafi, Sonia Skamene, Marwan Tolba, Mame Daro Faye, Paul Ramia, Julia Khriugian y John Kildea. “Development of a generalizable natural language processing pipeline to extract physician-reported pain from clinical reports: Generated using publicly-available datasets and tested on institutional clinical reports for cancer patients with bone metastases”. En: *Journal of Biomedical Informatics* 120 (2021), pág. 103864. ISSN: 1532-0464. DOI: <https://doi.org/10.1016/j.jbi.2021.103864>.
- [63] Olivier Bodenreider. “The Unified Medical Language System (UMLS): integrating biomedical terminology”. En: *Nucleic Acids Research* 32.suppl_1 (ene. de 2004), págs. D267-D270. ISSN: 0305-1048. DOI: 10.1093/nar/gkh061.
- [64] Alan R Aronson y François-Michel Lang. “An overview of MetaMap: historical perspective and recent advances”. En: *Journal of the American Medical Informatics Association* 17.3 (mayo de 2010), págs. 229-236. ISSN: 1067-5027. DOI: 10.1136/jamia.2009.002733. URL: <https://doi.org/10.1136/jamia.2009.002733>.
- [65] *spaCy 3: Natural language understanding with Bloom embeddings, convolutional neural networks and incremental parsing*. URL: <https://spacy.io/>.
- [66] A.E. Johnson, T.J. Pollard, L. Shen, L.W.H. Lehman, M. Feng, M. Ghassemi, B. Moody, P. Szolovits, L. Anthony Celi, R.G. Mark. “MIMIC-III, a freely accessible critical care database”. En: *Sci. Data* 3 (2016), págs. 1-9. DOI: 10.1038/sdata.2016.35.

- [67] Daniel T. Heinze, Mark L. Morsch, Brian C. Potter y Jr Sheffer Ronald E. “Medical i2b2 NLP Smoking Challenge: The A-Life System Architecture and Methodology”. En: *Journal of the American Medical Informatics Association* 15.1 (ene. de 2008), págs. 40-43. ISSN: 1067-5027. DOI: 10.1197/jamia.M2438. URL: <https://doi.org/10.1197/jamia.M2438>.
- [68] Charles E. Kahn Jr, Linda M. Roberts, Katherine A. Shaffer, Peter Haddawy. “Construction of a Bayesian network for mammographic diagnosis of breast cancer”. En: *Computers in Biology and Medicine* 27.1 (1997). DOI: 10.1016/S0010-4825(96)00039-X.
- [69] Bird S, Klein E, Loper E. *Natural Language Processing with Python*. O’Reilly Media Inc, 2009.
- [70] Hannah Eyre, Alec B Chapman, Kelly S Peterson, Jianlin Shi, Patrick R Alba, Makoto M Jones, Tamara L Box, Scott L DuVall y Olga V Patterson. “Launching into clinical space with medspaCy: a new clinical text processing toolkit in Python”. En: *AMIA Annual Symposium Proceedings 2021*. (in press, n.d.) URL: <http://arxiv.org/abs/2106.07799>.
- [71] Hannah Eyre, Alec B Chapman, Kelly S Peterson, Jianlin Shi, Patrick R Alba, Makoto M Jones, Tamara L Box, Scott L DuVall y Olga V Patterson. “Launching into clinical space with medspaCy: a new clinical text processing toolkit in Python”. en. En: *AMIA Annu. Symp. Proc.* 2021 (2021).
- [72] *John Snow Labs: NLP & AI in Healthcare*. URL: <https://www.johnsnowlabs.com/>.
- [73] *Spark NLP: State of the Art Natural Language Processing*. URL: <https://nlp.johnsnowlabs.com/>.
- [74] *Detect tumor morphology in Spanish texts*. URL: https://nlp.johnsnowlabs.com/2021/07/23/cantemist_scielowiki_es.html.
- [75] A Miranda-Escalada, E Farré y M Krallinger. “Named entity recognition, concept normalization and clinical coding: Overview of the cantemist track for cancer text mining in spanish, corpus, guidelines, methods and results”. En: *Proceedings of the Iberian Languages Evaluation Forum (IberLEF 2020), CEUR Workshop Proceedings*. 2020.
- [76] Alishah Mawji, Edmond Li, Clare Komugisha, Samuel Akech, Dustin Dunsmuir, Matthew O Wiens, Niranjana Kissoon, Nathan Kenya-Mugisha, Abner Tagoola, David Kimutai et al. “Smart triage: triage and management of sepsis in children using the point-of-care Pediatric Rapid Sepsis Trigger (PRST) tool”. En: *BMC health services research* 20.1 (2020), págs. 1-13.
- [77] Amy Franklin, Swaroop Gantela, Salsawit Shifarrow, Todd R Johnson, David J Robinson, Brent R King, Amit M Mehta, Charles L Maddow, Nathan R Hoot, Vickie Nguyen et al. “Dashboard visualizations: Supporting real-time throughput decision-making”. En: *Journal of biomedical informatics* 71 (2017), págs. 211-221.

- [78] Diane R Mould, Richard N Upton y Jessica Wojciechowski. “Dashboard systems: implementing pharmacometrics from bench to bedside”. En: *The AAPS journal* 16 (2014), págs. 925-937.
- [79] TW Felton, JA Roberts, TP Lodise, M Van Guilder, E Boselli, MN Neely y WW Hope. “Individualization of piperacillin dosing for critically ill patients: dosing software to optimize antimicrobial therapy”. En: *Antimicrobial agents and chemotherapy* 58.7 (2014), págs. 4094-4102.
- [80] C Wong, SS Kumar, GG Graham, EJ Begg, PKL Chin, J Brett, JE Ray, DJE Marriott, KM Williams y RO Day. “Comparing dose prediction software used to manage gentamicin dosing”. En: *Internal Medicine Journal* 43.5 (2013), págs. 519-525.
- [81] MJ Garcia, R Gavira, D Santos Buelga y A Dominguez-Gil. “Predictive performance of two phenytoin pharmacokinetic dosing programs from nonsteady state data”. En: *Therapeutic drug monitoring* 16.4 (1994), págs. 380-387.
- [82] Mitali Mohan, Kevin T Batty, Jennifer A Cooper, Richard E Wojnar-Horton y Kenneth F Ilett. “Comparison of gentamicin dose estimates derived from manual calculations, the Australian ‘Therapeutic Guidelines: Antibiotic’ nomogram and the SeBA-GEN and DoseCalc software programs”. En: *British journal of clinical pharmacology* 58.5 (2004), págs. 521-527.
- [83] Muhammad Usman, Muhammad Ashraf, Muhammad Imran Khokhar, Bilal Ashiq, Muhammad Irfan Masood, Shehryar Afzal, Ovais Omer, Mohsin Ali y M Imran Qadir. “Comparative pharmacokinetics of levofloxacin in healthy volunteers and in patients suffering from typhoid fever”. En: *Iranian Journal of Pharmaceutical Research: IJPR* 12.1 (2013), págs. 147.
- [84] Jeffrey S Barrett, John T Mondick, Mahesh Narayan, Kalpana Vijayakumar y Sundararajan Vijayakumar. “Integration of modeling and simulation into hospital-based decision support systems guiding pediatric pharmacotherapy”. En: *BMC medical informatics and decision making* 8 (2008), págs. 1-12.
- [85] SD Holford, NHG Holford y BJ Anderson. *Online dose calculation tool for determining dosing regimens in the very young*. 2014.
- [86] Diane R Mould, B Moyer, S Amur y A Mukherjee. “The impact of new technologies on the science of clinical care and drug development”. En: *AAPS Magazine December* 67 (2013).
- [87] Mengdie Zhuang, David Concannon y Ed Manley. “A framework for evaluating dashboards in healthcare”. En: *IEEE Transactions on Visualization and Computer Graphics* 28.4 (2022), págs. 1715-1731.
- [88] *Instituto Oncológico FALP: Historia de FALP*. URL: <https://www.institutoncologicofalp.cl/fundacion/historia-de-falp/>.

- [89] *Informe Análisis de Tendencias Mortalidad y AVPP por cáncer 2000-2019*. URL: http://epi.minsal.cl/wp-content/uploads/2023/04/Informe_Tendencia_Mortalidad_AVPP_Cancer_2000_2019_Marzo_2023.pdf.
- [90] Albin Sabani, Anna Landsmann, Patryk Hejduk, Cynthia Schmidt, Magda Marcon, Karol Borkowski, Cristina Rossi, Alexander Ciritsis y Andreas Boss. “BI-RADS-based classification of mammographic soft tissue opacities using a deep convolutional neural network”. En: *Diagnostics* 12.7 (2022).
- [91] CJ D’Orsi, EA Sickles, EB Mendelson, EA Morris et al. “American College of Radiology breast imaging reporting and data system BI-RADS”. En: *American College of Radiology, Reston, VA* 5 (2013).