



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
ESCUELA DE POSTGRADO Y EDUCACIÓN CONTINUA
DEPARTAMENTO DE INGENIERÍA CIVIL INDUSTRIAL

**IMPLEMENTACIÓN Y APLICACIONES DE UN SISTEMA DE
CODIFICACIÓN AUTOMÁTICA DE LA LISTA DE ESPERA CHILENA**

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIA DE DATOS

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

FELIPE ANDRÉS ARIAS TAPIA

PROFESOR GUÍA:
MARCELO OLIVARES ACUÑA

PROFESORA CO-GUÍA:
JOCELYN DUNSTAN ESCUDERO

COMISIÓN:
SUSANA MONDSCHHEIN PRIETO

Este trabajo ha sido parcialmente financiado por:
Proyecto Fondecyt 11201250 y CMM ANID BASAL FB210005

SANTIAGO DE CHILE

2023

IMPLEMENTACIÓN Y APLICACIONES DE UN SISTEMA DE CODIFICACIÓN AUTOMÁTICA DE LA LISTA DE ESPERA CHILENA

El Procesamiento del Lenguaje Natural (NLP, por sus siglas en inglés) tiene diversas aplicaciones en medicina, incluyendo la clasificación de texto, la extracción de conceptos clínicos y la codificación automática de enfermedades. Aunque los diagnósticos médicos representan una gran proporción de los registros clínicos de pacientes, su análisis se ve dificultado por el uso extensivo de abreviaturas y la variabilidad del lenguaje clínico en las distintas especialidades médicas, lo que limita su uso en proyectos que buscan apoyar la toma de decisiones clínicas.

La Organización Mundial de la Salud (OMS) creó un estándar internacional llamado Clasificación Internacional de Enfermedades (CIE) que se usa en todo el mundo para generar estadísticas sobre enfermedades y mortalidad. La CIE permite a los profesionales de la salud, investigadores y formuladores de políticas comprender mejor las tendencias en la salud y tomar decisiones informadas. En Chile, los registros electrónicos de lista de espera no-GES están disponibles en el Sistema Informático de Gestión de Tiempos de Espera (SIGTE). Sin embargo, los diagnósticos presentes en estos registros no cuentan con una codificación formal, ya que están en texto libre y cada servicio de salud actúa de manera independiente para reportar estos registros. En promedio, la codificación a nivel nacional es baja, con un 26,5 % y una mediana de 1,61 % de diagnósticos codificados por servicio de salud.

En esta tesis, se emplea un enfoque combinado de aprendizaje profundo y el conocimiento experto para codificar automáticamente diagnósticos en registros electrónicos de pacientes en Chile. Se utiliza un modelo de reconocimiento de entidades nombradas (NER, por sus siglas en Inglés) basado en redes neuronales profundas para detectar enfermedades en el texto y se asocian con su código CIE más probable mediante técnicas de *Entity Linking*. Para evaluar la efectividad del sistema, se comparó su rendimiento con la codificación manual de expertos clínicos en tres subconjuntos de interconsultas no-GES, logrando un rendimiento de 0.83 en base a la métrica MAP, similar al de otros estudios previos en la literatura.

El uso del sistema de codificación permitió registrar 14.247.782 diagnósticos, con un incremento del 26,5 % al 74,23 % en promedio y del 1,61 % al 77,64 % en mediana de la codificación de diagnósticos por servicio de salud. Para asegurar la continuidad de la investigación, se propuso un flujo de trabajo para implementar el sistema de codificación en los nuevos registros de lista de espera y almacenarlos en los servidores del Departamento de Estadística del Ministerio de Salud de Chile, para su uso en futuros análisis.

En relación al sistema de codificación previamente descrito, y con el fin de demostrar la relevancia de la información producida a partir de datos no estructurado, se han llevado a cabo dos aplicaciones de estudios sobre la lista de espera: la primera ha examinado el perfil sociodemográfico de los pacientes en función de las enfermedades más frecuentes en la lista, y la segunda se ha analizado la gestión del sistema de salud mediante los tiempos de espera para la atención de estos pacientes.

A mi familia

Agradecimientos

Primero que todo, quiero agradecer a mi madre María y mi padre Víctor por su amor y entrega para que siempre tuviéramos lo mejor. También a mi hermana Cristina por su ayuda siempre cuando lo necesitaba y mis hermanos Víctor y Luis por su compañía y apoyo.

Quiero agradecer a la profesora Jocelyn por ser quien me invitó al mundo de la investigación y mostrarme que se puede generar un cambio y apoyo al sector público, especialmente en la hermosa y delicada área de la salud pública. También quiero agradecer al profesor Marcelo y profesora Susana quienes llegaron en un punto crucial de esta tesis para apoyarme con su gran experiencia y consejos para poder guiar de la mejor manera este trabajo. Agradezco enormemente al grupo de investigación PLN CMM, por poder contar con un equipo con gran experiencia, multidisciplinario y con grandes personas, especialmente al Mati y Fabian con quienes tuve la suerte de trabajar mano a mano y siempre me brindaron su apoyo y conocimientos.

Agradecer a la gente de DEIS quienes participaron de manera activa en todo este proceso brindándome su tiempo, su gran experiencia y buena voluntad. También a Amparo de Armadillo Lab quien sin ella no podría haber escrito este trabajo.

Gracias a mis amigos que tuve la suerte de conocer a lo largo de mi paso por la universidad. Mis amigos Pablo y Carlos quien conocí desde el primer día de la u y no nos separamos mas, los amigos que conocí en mi corto paso por el DIM, Benja, Guti, Jota, Caro, Pedro, Gonza y tanto mas. Mis amigos del DII, Diego, Consu, Violeta y Claudio y mi amigo Mati del MDS.

Quiero agradecer a mis amigos de toda la vida Gato, Chine, Seba y Javier. También a los que pude conocer en los últimos años, Angelo, Ricky y Fabio por su gran amistad y infinita compañía.

Finalmente, agradezco el financiamiento recibido por el Proyecto Fondecyt 11201250 y del Centro de Modelamiento Matemático (CMM) a través del Proyecto Basal FB210005.

Tabla de Contenido

1. Introducción	1
1.1. Problema	2
1.2. Hipótesis	4
1.3. Objetivos	4
1.3.1. Objetivo general	4
1.3.2. Objetivo específicos	4
1.3.3. Metodología	5
1.4. Organización de la tesis	5
2. Antecedentes y trabajos afines	6
2.1. Antecedentes	6
2.1.1. Sistema de salud de Chile	6
2.1.2. Atención pública en Chile	8
2.1.3. Proceso de atención ambulatoria	8
2.1.4. Inteligencia Artificial	10
2.1.5. Aprendizaje automático	11
2.1.6. Redes neuronales	11
2.1.7. Aprendizaje profundo	12
2.1.8. Procesamiento del lenguaje natural y reconocimiento de entidades . .	13
2.1.9. <i>Entity Linking</i>	13
2.2. Trabajos afines	14
2.2.1. Modelos basados en reglas	15
2.2.2. Modelos basados en redes neuronales	15
3. Materiales y Métodos	17
3.1. Análisis descriptivo	18
3.2. Análisis de variables categóricas	20
3.3. Modelamiento del problema	22
3.3.1. Primer modulo: Reconocimiento automático de enfermedades	23
3.3.2. Segundo modulo: Codificación automática de enfermedades	24
3.4. Creación de <i>Gold Standard</i> y rendimiento humano	25
3.5. Métricas utilizadas	25
3.5.1. <i>Intersection Over Union</i> (IoU)	26
3.5.2. <i>Mean Average Precision</i> (MAP)	26
3.6. Despliegue	27
4. Resultados	28
4.1. <i>Gold Standard</i> y acuerdo humano	28

4.1.1.	Primer experimento	28
4.1.2.	Segundo experimento	29
4.1.3.	Tercer experimento	29
4.2.	Resultado de los modelos	29
4.2.1.	Primer experimento	31
4.2.2.	Segundo experimento	32
4.2.3.	Tercer experimento	33
4.3.	Limitaciones	35
4.4.	Despliegue	36
5.	Aplicaciones	39
5.1.	Propuestas de aplicaciones en cáncer	39
5.1.1.	Cáncer en el mundo y en Chile	39
5.1.2.	Lista de espera histórica codificada	40
5.1.3.	Propuesta 1: Perfil sociodemográfico de pacientes en Lista de Espera	41
5.1.4.	Propuesta 2: Gestión del sistema de salud en Lista de Espera	44
5.2.	Un caso de aplicación: Dashboard DEIS	48
6.	Conclusiones, trabajo futuro y contribuciones	50
6.1.	Conclusiones	50
6.2.	Trabajo futuro	51
6.3.	Contribuciones	51
	Bibliografía	52
	Anexo	56

Índice de Tablas

3.1.	Conjunto de atributos utilizados de SIGTE.	17
3.2.	Tabla de atributos formulados para el análisis.	18
3.3.	Cantidad de CNE por año en SIGTE.	19
3.4.	Distribución del top 10 de las especialidades médicas presentes en lista de espera histórica.	20
3.5.	Top 10 especialidades con mas tokens por oración.	21
3.6.	Top 10 especialidades con menos tokens por oración.	21
4.1.	Acuerdo entre codificadoras para el primer experimento.	28
4.2.	Acuerdo entre codificadoras para el segundo experimento.	29
4.3.	Ejemplo del sistema de codificación automática.	30
4.4.	Estado del arte actual en codificación automática. Tabla extraída de [43].	31
4.5.	Métricas de la muestra 1 y 2 y su versión Gold Standard del primer experimento.	32
4.6.	Métricas de la muestra 1 y 2 y su versión Gold Standard del segundo experimento.	32
4.7.	Métricas de la muestra Gold Standard del tercer experimento.	33
4.8.	Top 10 especialidades con mejor rendimiento.	34
4.9.	Top 10 especialidades con peor rendimiento.	35
4.10.	Resultados en prestaciones oncológicas.	35
4.11.	Ejemplo de problemas del modelo con respecto a los datos de entrada.	36
4.12.	Ejemplo de problemas del modelo con respecto que falta criterio médico.	36
5.1.	Ejemplo de registro SIGTE.	46
.1.	Actualidad de la codificación en lista de espera histórica.	56
.2.	Distribución de la especialidad médica presente en lista de espera histórica - Parte 1.	57
.3.	Distribución de la especialidad médica presente en lista de espera histórica - Parte 2.	58
.4.	Cantidad de palabras por oración a nivel de especialidad en interconsultas CNE en lista de espera histórica - Parte 1.	59
.5.	Cantidad de palabras por oración a nivel de especialidad en interconsultas CNE en lista de espera histórica - Parte 2.	60
.6.	Rendimiento de las especialidades médicas - Parte 1.	61
.7.	Rendimiento de las especialidades médicas - Parte 2.	62
.8.	Codificación automática en lista de espera histórica.	63

Índice de Ilustraciones

1.1.	Ejemplo formato de códigos CIE-10, tanto a nivel de categoría y subcategoría.	3
2.1.	Proceso de referencia - contrarreferencia.	9
2.2.	Esquema de inteligencia artificial.	10
2.3.	Esquema de una red neuronal.	12
2.4.	Ejemplo de codificación automática de una interconsulta de la lista de espera no-GES.	14
3.1.	Cantidad de interconsultas por tipo de prestación.	19
3.2.	Propuesta de codificación automática de enfermedades.	22
3.3.	Propuesta de modelo de reconocimiento de enfermedades. Extraído de [38].	23
3.4.	Ejemplo de los dos niveles de precisión utilizados para calcular la métrica IoU y MAP.	26
4.1.	Tabla con las codificaciones a nivel de entidades por cada interconsulta.	36
4.2.	<i>workflow</i> de codificación de lista de espera	37
5.1.	Cantidad de diagnósticos codificados automáticamente de la lista histórica CNE.	40
5.2.	Evolución de los 10 grupos de códigos más frecuentes asociados a cáncer en lista de espera CNE entre los años 2016-2021.	41
5.3.	Frecuencia de C15-C26 en lista de espera CNE por sexo entre los años 2016-2021.	42
5.4.	Frecuencia de C15-C26 en lista de espera CNE por sexo y grupo etario entre los años 2016-2021.	42
5.5.	Tasa de presencia de C15-C26 cada 100.000 habitantes por región para el año 2016, 2018 y 2020	43
5.6.	Co-ocurrencia de diagnósticos de cáncer en pacientes de lista de espera entre los años 2016-2021.	44
5.7.	Distribución de la mediana de los tiempos de espera para diagnósticos C15-C26 por región para el año 2016, 2018 y 2020. Se excluye la región de Tarapacá.	45
5.8.	Algoritmo para la creación de episodio en lista de espera no- GES.	47
5.9.	Dashboard interactivo desarrollado por DEIS con sistema de codificación automática de diagnósticos.	48
5.10.	Tabla dinámica de diagnósticos codificados.	49
5.11.	Tabla de diagnósticos reales.	49

Capítulo 1

Introducción

Es esencial contar con registros médicos estandarizados, especialmente en lo que respecta a los diagnósticos médicos, para permitir una comunicación efectiva y segura entre los profesionales de la salud y facilitar el intercambio de información tanto entre las instituciones sanitarias como con los pacientes. Para lograr esto, es fundamental implementar estándares, ya sean internacionales o no, que permitan el intercambio estructurado de datos y aseguren la interoperabilidad semántica [1]. De esta manera, es posible reducir los errores médicos, disminuir los costos y mejorar la calidad de la atención al paciente, lo que lleva a un manejo exitoso de los desafíos en la atención médica [2].

El Procesamiento del Lenguaje Natural (NLP, por sus siglas en inglés) es el campo de la inteligencia artificial que se encarga de la interacción entre humanos y máquinas a través del lenguaje [3]. En medicina, las aplicaciones típicas de NLP son la clasificación de texto [4], la extracción automática de conceptos clínicos [5], la codificación automática de enfermedades [6] o la anonimización de registros de salud electrónicos [7]. Lo que demuestra que el NLP es una herramienta valiosa para el campo de la medicina y tiene el potencial de mejorar significativamente los registros médicos.

En términos generales en el área de la medicina, la codificación de diagnósticos médicos es un desafío importante debido al uso extensivo de abreviaturas y la variabilidad del lenguaje clínico entre las diferentes especialidades médicas. Estas dificultades se intensifican en el actual sistema chileno de salud pública, puesto que se utiliza la codificación manual de enfermedades a partir de texto no estructurado. Además, las tareas habituales del personal médico demandan competencias en cuanto a reglas de codificación y terminología especializada, lo que exige tiempo y desarrollo de habilidades analíticas. A pesar de estos desafíos, la implementación de sistemas computacionales basados en técnicas de NLP para la codificación automática de enfermedades puede ayudar a abordar estos problemas de manera eficiente [8].

En este trabajo, se propone un sistema de codificación automática de enfermedades basado en dos módulos. En el primero, se aborda la extracción automática de enfermedades mediante el uso de un modelo basado en técnicas de NLP. Posteriormente, mediante el uso de un motor de búsqueda, se identifica el código más probable para cada una de las enfermedades identificadas. Con el fin de garantizar la continuidad de la investigación, se propone un flujo de trabajo para implementar el sistema de codificación en los nuevos registros de la lista de espera y almacenarlos en los servidores del Departamento de Estadísticas e Información de

Salud (DEIS) del Ministerio de Salud de Chile, para que puedan ser utilizados en análisis futuros.

A partir del sistema de codificación automática detallado anteriormente y con el propósito de evidenciar la pertinencia de la información generada a través de datos no estructurados, se realizarán dos aplicaciones estadísticas. La primera se centrará en el perfil sociodemográfico de los pacientes con las enfermedades más comunes en la lista de espera histórica. Por su parte, la segunda aplicación se enfocará en la gestión del sistema de salud expresada a través de los tiempos de espera de los pacientes para su atención.

1.1. Problema

La Organización Mundial de la Salud (OMS) utiliza la Clasificación Internacional de Enfermedades (CIE) en una amplia variedad de aplicaciones para brindar información crucial sobre el alcance, las causas y las consecuencias de las enfermedades humanas y la muerte en todo el mundo. Cada enfermedad se asigna a un código específico dentro de la estructura jerárquica de la CIE, que consta de capítulos, secciones, categorías y subcategorías. La versión actual del CIE es la CIE-10, que contiene más de 14.000 códigos únicos para enfermedades, síntomas y causas externas de lesiones. El formato jerárquico de la CIE-10 consta de cuatro niveles: capítulo, sección, categoría y subcategoría, tal como se muestra a continuación:

- **Capítulo:** La CIE-10 consta de 22 capítulos, cada uno de los cuales se centra en una categoría general de enfermedades, como las enfermedades infecciosas, las neoplasias o las enfermedades del sistema nervioso. Cada capítulo se identifica con una letra del alfabeto (por ejemplo, C para las neoplasias).
- **Sección:** Cada capítulo se divide en secciones que corresponden a grupos específicos de enfermedades. Cada sección se identifica con dos dígitos (por ejemplo, C15-C26 para los tumores malignos de los órganos digestivos).
- **Categoría:** Cada sección se divide en categorías que se centran en enfermedades específicas. Cada categoría se identifica con tres dígitos (por ejemplo, C22 para el tumor maligno del hígado y de las vías biliares intrahepáticas).
- **Subcategoría:** Cada categoría se puede subdividir en subcategorías para permitir una mayor especificidad de la enfermedad. Cada subcategoría se identifica con un dígito adicional (por ejemplo, C22.0 para el describir exactamente el carcinoma de células hepáticas).

Los términos médicos codificados con CIE son la base fundamental para el registro de la salud y las estadísticas sobre enfermedades en la atención primaria, secundaria y terciaria, así como para los informes de defunción. Estos datos y estadísticas apoyan los sistemas de pago, la planificación de servicios, la gestión de calidad y seguridad, y la investigación en el campo de la salud. La orientación diagnóstica relacionada con las categorías de la CIE también normaliza la recopilación de datos y permite investigaciones a gran escala [9].

En el sistema público de salud chileno, se utiliza la codificación CIE-10 para estandarizar el proceso de codificación de enfermedades y causas externas¹. Actualmente, existen diagnósticos codificados correspondientes a egresos hospitalarios para la morbilidad y defunciones para la mortalidad. En el caso de la codificación de la morbilidad, los equipos de la red de estadísticas sanitarias y los Grupos Relacionados por el Diagnóstico (GRD) de los centros de salud son responsables de codificar estos datos. En cambio, la oficina de Acontecimientos Vitales del DEIS se encarga de la codificación de la mortalidad.

Por otro lado, el Sistema de Gestión de Tiempos de Espera (SIGTE) alberga los registros electrónicos de la lista de espera no-GES, que es la lista de espera con mayor cantidad de pacientes en Chile para la consulta con especialistas [10]. Estos datos proporcionados por los 29 servicios de salud contienen información sobre los diagnósticos médicos de los pacientes, pero no están estandarizados necesariamente bajo la codificación CIE-10.

En la sección Anexos, se encuentra la tabla .1, la cual muestra de forma cuantitativa el porcentaje de codificación actual en SIGTE para 18.716.629 interconsultas, también conocidas como Consultas Nuevas de Especialidad (CNE) de lista de espera, correspondientes a datos hasta noviembre del 2022. Estas interconsultas se corresponden a la derivación de pacientes para recibir atención especializada. Dentro de ellas, aproximadamente 5.760.750 tienen asociado algún código CIE-10. Es importante destacar que el Servicio de Salud de Coquimbo presenta una codificación del 99,96 % de los diagnósticos, mientras que el Servicio de Salud Aconcagua solo tiene un 0,07 % de codificación. En promedio, la codificación a nivel nacional por servicio de salud es baja, con un 26,5 %, y la mediana es de 1,61 %. Para realizar este cálculo, se utilizó una expresión regular que busca el formato de un código CIE-10 en los campos de diagnóstico de texto libre, el cual consta de una letra seguida de dos números obligatorios, y la posibilidad de un tercer número con o sin un punto. Dicha estructura se muestra en la siguiente figura.



Figura 1.1: Ejemplo formato de códigos CIE-10, tanto a nivel de categoría y subcategoría.

Actualmente, en el sistema de salud público chileno, la codificación de enfermedades a partir de textos no estructurados se realiza de forma manual por parte de expertos clínicos, lo que no es óptimo por dos razones esenciales. En primer lugar, dado que este proceso está sujeto a errores, se requiere que el personal médico posea una competencia significativa en las reglas de codificación y un conocimiento profundo de la terminología especializada, en este caso CIE-10. En otras palabras, el personal experto en codificación debe estar familiarizado con el campo clínico, ser analítico y enfocado, manejar habilidades fundamentales para inspeccionar y analizar textos altamente especializados. En segundo lugar, la codificación manual demanda mayor tiempo, el cual podría ser optimizado mediante un sistema de apoyo que permita redistribuir este tiempo a otras tareas relevantes para la decisión clínica.

¹ Para mayor detalle de la Norma Técnica, se sugiere revisar el siguiente enlace: <https://www.bcn.cl/leychile/navegar?i=1112064&f=2017-12-06>

Estas dificultades pueden abordarse de manera eficiente mediante el uso de sistemas computacionales capaces de llevar a cabo la tarea de codificación de forma automática, utilizando tecnologías de procesamiento del lenguaje natural (NLP). De esta forma, se puede dar una utilidad adicional a la información no estructurada de los diagnósticos médicos, que puede ser utilizada para el desarrollo de políticas públicas enfocadas en mejorar el sistema de salud.

1.2. Hipótesis

Este trabajo plantea como hipótesis que la implementación de un sistema de codificación automática podría ser una solución eficiente y efectiva para mejorar la normalización de los registros nacionales de lista de espera. Asimismo, se sugiere que el uso de un modelo de inteligencia artificial podría permitir la realización de estudios estadísticos más precisos y detallados sobre las enfermedades presentes en la lista de espera, así como generar indicadores más precisos del tiempo de espera de los pacientes. Con esta investigación se busca demostrar la importancia de la tecnología en la mejora de procesos de registros médicos.

1.3. Objetivos

1.3.1. Objetivo general

El objetivo de este trabajo es investigar la viabilidad de un modelo de inteligencia artificial (IA) para la codificación automática de diagnósticos en registros nacionales de lista de espera no-GES. Además, generar propuestas para realizar estadísticas precisas sobre las enfermedades presentes en la lista de espera, y producir visualizaciones para la gestión de estos registros.

1.3.2. Objetivo específicos

1. Evaluar la calidad de la codificación de diagnósticos en los registros históricos de lista de espera no-GES en Chile, con énfasis en las prestaciones de consulta médica denominadas Consulta Nueva de Especialidad (CNE).
2. Implementar un modelo para la codificación automática de enfermedades.
3. Comparar la clasificación de diagnósticos automática con un *Gold Standard* establecido por profesionales de la salud expertos en codificación.
4. Aplicar el modelo de enfermedades en CNE presentes en la lista de espera histórica con algoritmos de IA con los mejores parámetros.
5. Proponer un flujo de trabajo del sistema de codificación que sea utilizado por profesionales del Departamento de Estadística del Ministerio de Salud (DEIS).
6. Generar propuestas de estudios estadísticos sobre los diagnósticos en la lista de espera histórica no-GES.

1.3.3. Metodología

En base a los objetivos planteados anteriormente, se detalla la metodología propuesta para la siguiente investigación. En concreto, los pasos a seguir son los siguientes:

1. Explorar el perfil de las interconsultas en lista de espera a partir de las opciones de interconsulta, la prestación otorgada, la especialidad derivada y las variables sociodemográficas de las personas. A través de expresiones regulares, determinar cuántos diagnósticos presentes en las interconsultas tienen una estructura similar a la codificación CIE-10.
2. Implementar un sistema de IA con enfoque dos pasos para la codificación de enfermedades en la lista de espera histórica.
3. Realizar tres pruebas con diferentes enfoques mediante la extracción de muestras de lista de espera no-GES, con el que se establecerá un *Gold Standard* por profesionales del DEIS. Este sistema se comparará a partir de las métricas adecuadas para este tipo de tareas.
4. Realizar la codificación de enfermedades de la lista de espera histórica de prestaciones de CNE con el sistema con las modificaciones con mejor rendimiento encontrado en las etapas anteriores.
5. Implementar en el DEIS un flujo de trabajo mediante herramientas utilizadas por ellos para la codificación de nuevas interconsultas, las cuales serán guardadas en su *datawarehouse* y procesadas para cualquier personal del DEIS pueda consumir estos datos y apoyar la gestión.
6. Proponer estudios que permitan analizar el comportamiento de las enfermedades presentes en la lista de espera no-GES en la población chilena. La primera propuesta de estudio se enfocará en el análisis de las variables sociodemográficas de los pacientes para determinar cómo afectan el comportamiento de las enfermedades en la población. La segunda propuesta de estudio consistirá en el análisis de la gestión del sistema de salud, a través de la representación de los tiempos de espera por enfermedad.

1.4. Organización de la tesis

La tesis está organizada de la siguiente manera: en el Capítulo 2 se exponen los antecedentes prácticos y teóricos necesarios para comprender el origen de los datos, la implementación y aplicación llevada a cabo, así como los trabajos relacionados con la codificación automática de enfermedades. El Capítulo 3 describe el análisis de datos, el modelado del problema, los experimentos realizados y la implementación del sistema de codificación automática. En el Capítulo 4, se presenta la validación de la efectividad del sistema de codificación automática utilizando métricas adecuadas, se describe el flujo de trabajo utilizado en su implementación y las limitaciones del sistema. En el Capítulo 5, se exponen propuestas de aplicaciones sobre las enfermedades presentes en los datos de lista de espera histórica no-GES. Finalmente, el último capítulo resume las conclusiones obtenidas, comenta sobre las futuras líneas de aplicación de la investigación y la contribución de este trabajo a la literatura.

Capítulo 2

Antecedentes y trabajos afines

2.1. Antecedentes

En el presente capítulo, con la finalidad de entender la importancia de mejorar los registros médicos de la lista de espera no-GES en Chile y cómo el procesamiento de lenguaje natural puede ayudar en esta tarea, es necesario comprender la magnitud de los datos disponibles y los modelos más relevantes en esta disciplina. En primer lugar, para entender la importancia que representa esta tarea, a continuación se hará referencia a la magnitud de la población del sistema de salud en Chile. Posteriormente, se detallará la independencia que tienen los servicios de salud al momento de proporcionar atención médica y sus niveles de especialización. Finalmente, se revisarán las particularidades del proceso de atención ambulatoria, lo que termina generando el registro médico del paciente en lista de espera. Este dato específico es el trabajado en la presente investigación.

En segundo lugar, para comprender los modelos más relevantes en esta disciplina, es importante entender el concepto de inteligencia artificial y cómo los ordenadores generan aprendizaje a partir de los datos, así como los enfoques utilizados en el método del aprendizaje automático. Además, se detallará con mayor profundidad la estructura utilizada, que corresponde a las redes neuronales y cómo esta estructura da paso a los modelos de la técnica de aprendizaje profundo. Estos modelos tienen la capacidad de procesar grandes cantidades de texto y permiten la interacción entre seres humanos y ordenadores a través del lenguaje, lo que se denomina procesamiento del lenguaje natural. En particular, esta investigación utiliza modelos de reconocimiento de entidades para identificar menciones y clasificarlas en textos médicos, como nombres de medicamentos, diagnósticos y procedimientos. Posteriormente, estas menciones se asocian a una estructura estandarizada mediante técnicas de *Entity Linking*. A continuación se detallarán los puntos anteriormente señalados.

2.1.1. Sistema de salud de Chile

El sistema de salud de Chile es un conjunto de instituciones, servicios y políticas encargados de proteger y mejorar la salud de la población. El sistema de salud de Chile está organizado de manera descentralizada, lo que significa que está dividido en regiones y que cada una de ellas tiene cierta autonomía para administrar los servicios de salud.

Los componentes principales del sistema de salud de Chile incluyen:

- Ministerio de Salud: encargado de formular y coordinar políticas y planes de salud a nivel nacional.
- Instituciones públicas de salud: hospitales, centros de salud y otros establecimientos que brindan servicios de salud de manera gratuita a la población.
- Instituciones privadas de salud: hospitales, clínicas y otros establecimientos que brindan servicios de salud a cambio de un pago.
- Profesionales de la salud: médicos, enfermeros, farmacéuticos y otros trabajadores de la salud que prestan servicios de atención médica.
- Sistemas de seguridad social: sistema de seguridad social obligatorio y los sistemas de seguridad social privados. Estos sistemas financian la atención médica y otros servicios de salud para los trabajadores y sus familias.

El sistema de salud chileno según la Superintendencia de Salud [11] cuenta con un sistema de salud mixto, que se compone de instituciones públicas y privadas, y tiene como objetivo ofrecer una cobertura universal de salud a toda la población. La división pública esta integrada por el Fondo Nacional de Salud (FONASA), entidad que, para el año 2022 cuenta con un universo de más de 15 millones de beneficiarios, cifra correspondiente al 77 % de la población chilena". Esta atención es cubierta por medio del. Sistema Nacional de Servicios de Salud (SNSS) y sus 29 servicios a lo largo del territorio nacional. La división privada corresponde a las instituciones de Salud Previsional (ISAPRE) las cuales tienen cerca de 3.2 millones de beneficiarios correspondiente a un 17 % aproximadamente de la población. El resto de la población se divide en el sistema de salud de Fuerzas Armadas con un 3 %, los que no están en ningún sistema con un 2 % y un 1 % que se desconoce.

El sistema de salud presenta dos componentes, uno es un componente de complejidad social, y otro un componente asistencial. Por un lado, el primero de ellos busca abordar los determinantes sociales de la salud, como la pobreza, el desempleo, la vivienda precaria y la falta de acceso a la educación y otros servicios básicos. Para enfrentar estos desafíos, el país ha implementado diversas políticas y programas, como el Plan GES (Garantías Explícitas en Salud), que tiene como objetivo reducir las inequidades en el acceso a la atención médica y mejorar la calidad de los servicios para todos los chilenos. Además, Chile ha promovido el desarrollo de programas de prevención y promoción de la salud, como el Programa de Salud Cardiovascular, el Programa de Salud Oral y el Programa de Salud Mental, entre otros.

Por otro lado, el segundo componente que forma parte del sistema de salud se enfoca en la atención médica y la gestión de los servicios de salud. En el país, los centros de salud públicos se clasifican en diferentes niveles de complejidad, y ofrecen servicios ambulatorios (abiertos) y hospitalarios (cerrados). Estos servicios se interconectan mediante un sistema de referencia y contrarreferencia [12], en el que los pacientes pueden ser remitidos a servicios especializados dentro de la misma red de atención médica. Esto permite una mejor coordinación entre los diferentes niveles de atención médica y busca asegurar que los pacientes reciban el tratamiento adecuado en el momento adecuado.

2.1.2. Atención pública en Chile

En Chile, la salud pública es responsabilidad del Ministerio de Salud y se divide en 29 Servicios de Salud que cubren diferentes regiones del país. Cada uno de estos servicios está a cargo de la planificación, gestión y supervisión de los servicios de salud en su área geográfica. Los Servicios de Salud también supervisan la implementación de políticas de salud a nivel regional y coordinan la atención médica en los distintos niveles de atención [13], los cuales se explicarán a continuación.

- **Nivel Primario:** enfocado en la prevención, promoción y tratamiento de enfermedades comunes. Los centros de salud primarios son la principal fuente de atención médica para la población chilena. Según un informe del Ministerio de Salud, en el año 2020 había más de 1.300 centros de salud primarios en todo el país [13], que brindaban servicios de atención médica, odontología, enfermería y atención maternal y infantil.
- **Nivel Secundario:** conformado por hospitales y clínicas especializadas que ofrecen servicios de mayor complejidad, como cirugía y atención de emergencia. En Chile, hay 80 hospitales públicos, que brindan atención a una amplia gama de enfermedades y afecciones.
- **Nivel Terciario:** conformado por los servicios más avanzados y complejos, como los trasplantes de órganos y la atención de enfermedades raras. En Chile, los servicios de atención terciaria están altamente especializados y se concentran en un número limitado de centros médicos.

2.1.3. Proceso de atención ambulatoria

En Chile, el proceso de atención ambulatoria es el conjunto de actividades y servicios que se prestan a los pacientes en un centro de salud, sin necesidad de hospitalización. Este tipo de atención es importante para la detección temprana de enfermedades, el control de enfermedades crónicas, la prevención de enfermedades y la atención de emergencias.

El proceso de atención ambulatoria comienza con la programación de una cita en un centro de salud, donde el paciente es evaluado por un médico general. En esta primera consulta, se realiza una evaluación inicial para determinar las necesidades de atención médica del paciente. Se realiza una historia clínica detallada, que incluye antecedentes médicos, alergias y medicamentos que esté tomando el paciente. Una vez completada la evaluación inicial, el médico puede solicitar exámenes diagnósticos adicionales, como análisis de sangre, radiografías o ecografías, si se considera necesario. Estos exámenes se realizan en el mismo centro de salud o en otro lugar de la red de atención médica.

En la atención ambulatoria en Chile, el médico generalmente es el primer punto de contacto. En caso de requerirse una atención especializada, el profesional deriva al paciente a un especialista. Esta acción genera en el registro médico una estructura de dato denominada interconsulta. Después de llegar al diagnóstico en la interconsulta, se establece un plan de tratamiento y se proporciona al paciente la medicación necesaria o se le remite a un especialista para continuar su tratamiento.

Cuando se deriva a un paciente a un especialista, el proceso puede variar dependiendo de si el diagnóstico es de una patología cubierta por el GES o no. Si corresponde a una patología cubierta por el GES, la derivación se hace mediante un departamento especializado. En el caso de patologías no cubiertas por el GES, la derivación se realiza utilizando una de las cinco opciones de interconsulta disponibles: Consulta Nueva de Especialidad (CNE), Consulta repetida o de seguimiento (CCE), Procedimiento diagnósticos (Proc), Intervención Quirúrgica (IQ) e Intervención Quirúrgica Compleja (IQC). Cualquier opción de interconsulta genera un registro nuevo para la lista de espera no-GES.

El proceso anteriormente descrito corresponde al sistema de referencia - contrarreferencia, el cual es fundamental en la atención ambulatoria, ya que permite una mejor coordinación entre los diferentes niveles de atención médica y asegura que los pacientes reciban el tratamiento adecuado en el momento adecuado. La complejidad y algunos actores principales del proceso se representan de manera simplificada en la figura 2.1.

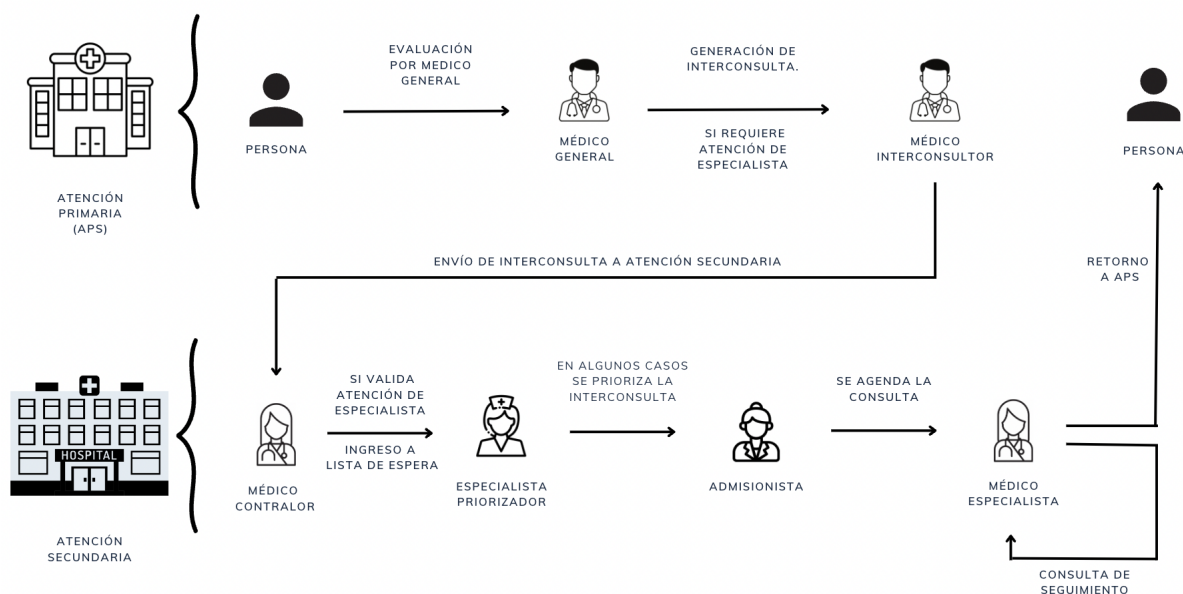


Figura 2.1: Proceso de referencia - contrarreferencia.

Los registros de lista de espera no-GES están disponibles en el Sistema Informático de Gestión de Tiempos de Espera (SIGTE), el cual cada servicio de salud reportan un conjunto mínimos de datos que van nutriendo este sistema. En específico, los diagnósticos médicos presentes en SIGTE representan una proporción significativa de los registros clínicos de los pacientes y, comúnmente, se encuentran en un formato libre, sin estructura definida.

En el estudio, Baez et al. [14] señalan la importancia de identificar la dinámica en la que se registra la información clínica del paciente en una plataforma de ficha clínica electrónica. En términos generales, estas plataformas se alimentan tanto información estructurada como no estructurada. En esta distribución, los autores reconocen que el 40 % corresponde a información no estructurada o texto libre. Mientras la información estructurada es de fácil análisis y comprensión, aunque omite información relevante en ocasiones; el texto libre puede contener

errores y dificultar su análisis, pero es de gran relevancia, puesto que remite a información detallada sobre enfermedades y su sintomatología. En este sentido, el uso de técnicas de Inteligencia Artificial podría agilizar tareas como la implementación de criterios de prioridad, la realización de estadísticas de derivación, la identificación de factores de riesgo y la búsqueda de relaciones con antecedentes familiares en la resolución del problema de lista de espera no-GES.

2.1.4. Inteligencia Artificial

La Inteligencia Artificial (IA) se define como “el estudio y diseño de agentes inteligentes” [15], es decir, sistemas capaces de realizar tareas que antes solo podían ser realizadas por seres humanos. Estas tareas incluyen el reconocimiento de voz y de imágenes, la toma de decisiones y la resolución de problemas complejos [16]. La IA utiliza diversas técnicas y herramientas, como el aprendizaje automático, el procesamiento del lenguaje natural y la visión por computadora, para analizar grandes cantidades de datos y extraer patrones útiles [17]. En su conjunto, estas permiten a los sistemas de IA aprender y mejorar su desempeño a medida que se les proporciona más información.

La IA tiene aplicaciones en una amplia variedad de campos, como la medicina, la robótica y la industria tecnológica, entre otros. Estas técnicas y herramientas se relacionan de manera general como se representa en la figura 2.2.

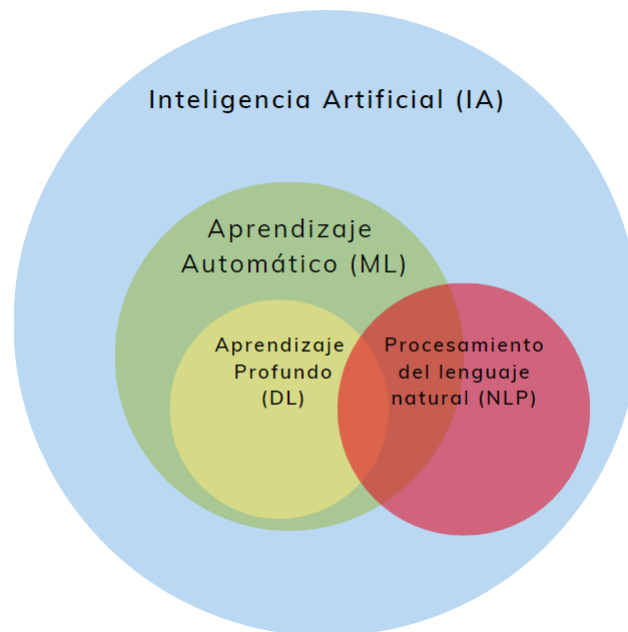


Figura 2.2: Esquema de inteligencia artificial.

A pesar de los beneficios que ofrece la IA, esta no se encuentra ajena de desafíos y preocupaciones, como la posible eliminación de empleos y la necesidad de proteger la privacidad y la seguridad de los datos personales [18]. La comunidad de la IA debe tomar en cuenta estas preocupaciones y trabajar en soluciones que permitan un uso sostenible y beneficioso de esta tecnología para la sociedad [19]. Este panorama general en el contexto médico exige que los desarrolladores y los usuarios de la IA trabajen juntos para garantizar que esta tecnología se utilice de manera responsable y ética el uso del dato del paciente.

2.1.5. Aprendizaje automático

El Aprendizaje Automático es un subcampo de la Inteligencia Artificial que utiliza algoritmos estadísticos para reconocer patrones en los datos y enseñar a las computadoras a aprender sin una programación explícita [20]. Estos algoritmos se han aplicado en diversas áreas, como el procesamiento de imágenes, el procesamiento del lenguaje natural, la detección de fraudes y la recomendación de productos [21]. Según Alpaydin [17], el Aprendizaje Automático se divide en tres categorías principales: Aprendizaje Supervisado, Aprendizaje No Supervisado y Aprendizaje por Refuerzo. Cada uno de estos tiene sus propias ventajas y desventajas: el enfoque de aprendizaje supervisado es adecuado cuando se tienen datos etiquetados para aprender y hacer predicciones, mientras que el aprendizaje no supervisado es más útil para descubrir patrones no evidentes y el aprendizaje por refuerzo es efectivo para la toma de decisiones en tiempo real [22].

En la práctica, dependiendo del problema que se está abordando y de los datos disponibles, se utilizan diferentes combinaciones de aprendizaje supervisado y no supervisado, así como otras técnicas de aprendizaje automático. Es importante seleccionar la técnica adecuada para el problema específico y adaptarla según sea necesario. En general, el aprendizaje automático sigue evolucionando y mejorando con el tiempo, y ha demostrado ser una herramienta valiosa en una amplia gama de aplicaciones.

En el desarrollo de este trabajo, se ha adoptado un enfoque supervisado. Lo anterior se debe a que los modelos utilizados han sido entrenados con texto clínico de lista de espera que ha sido previamente etiquetado por profesionales médicos. Este enfoque es ideal para problemas en los que se cuenta con datos etiquetados, ya que permite que el modelo aprenda a partir de los ejemplos proporcionados.

2.1.6. Redes neuronales

Las redes neuronales son un modelo de aprendizaje automático inspirado en el cerebro humano, compuestas por nodos interconectados llamados neuronas artificiales, encargadas de procesar y transmitir información. Cada neurona en una red neuronal recibe entradas en la capa de entrada y realiza una operación matemática para generar una salida. Estas salidas son utilizadas como entradas en la siguiente capa, en un proceso repetitivo a través de varias capas ocultas que permiten que la red aprenda patrones cada vez más complejos. La estructura de una red neuronal varía según el problema que se aborda y produce una salida final en la capa de salida, que puede ser una clasificación, predicción o respuesta continua. En general, las redes neuronales siguen el esquema presentado en la figura 2.3.




Figura 2.3: Esquema de una red neuronal.

Un modelo de redes neuronales se entrena utilizando técnicas de aprendizaje supervisado, ajustando los pesos y parámetros para minimizar el error entre las predicciones y las respuestas reales. Este procedimiento se realiza utilizando un conjunto de datos etiquetados. Una vez entrenado, el modelo puede utilizarse para hacer predicciones sobre nuevos datos de entrada.

2.1.7. Aprendizaje profundo

El Aprendizaje Profundo es una técnica de aprendizaje automático que utiliza redes neuronales artificiales para modelar y resolver problemas complejos, permitiendo procesar grandes cantidades de datos no estructurados y producir resultados precisos [23]. Además, según Bengio et al. [24], el Aprendizaje Profundo es un campo en constante evolución que está experimentando un rápido crecimiento debido a los avances en el hardware y el software. Este tipo de aprendizaje ha sido aplicado con éxito en una variedad de áreas, incluyendo el procesamiento de imágenes, el procesamiento del lenguaje natural, la robótica y la visión por computadora.

El Aprendizaje Profundo utiliza modelos de redes neuronales profundas capaces de aprender características y patrones complejos de los datos, lo que ha demostrado ser efectivo en la identificación y clasificación de objetos en imágenes, en la traducción automática del lenguaje natural y en la identificación de emociones en el habla y el texto [23]. LeCun et al. [25] explican que el Aprendizaje Profundo se beneficia de grandes cantidades de datos y del poder de procesamiento de las unidades de procesamiento gráfico (GPU). Asimismo, destacan que la capacidad del Aprendizaje Profundo para aprender automáticamente características complejas de los datos ha llevado a avances significativos en el reconocimiento de objetos, el procesamiento del lenguaje natural y la visión por computadora.

2.1.8. Procesamiento del lenguaje natural y reconocimiento de entidades

El Procesamiento del Lenguaje Natural (NLP) es una rama de la inteligencia artificial que se ocupa de la interacción entre los seres humanos y el lenguaje natural. Una tarea importante en NLP es el reconocimiento de entidades, acción que implica la identificación y clasificación de entidades en un texto, como personas, lugares, organizaciones, fechas, entre otros. El reconocimiento de entidades se utiliza en muchas aplicaciones de NLP, como la extracción de información, la búsqueda de información y la traducción automática [3].

Para el Reconocimiento de Entidades Nombradas (NER, por sus siglas en Inglés) se han desarrollado muchos enfoques basados en reglas y aprendizaje automático. Enfoques más tradicionales utilizan reglas y patrones lingüísticos para identificar las entidades, mientras que los enfoques más recientes utilizan técnicas de aprendizaje automático, como las redes neuronales para mejorar la precisión y la escalabilidad.

Uno de los enfoques más comunes para el reconocimiento de entidades en NLP es el uso de modelos de secuencia. Estos se enfocan en la tarea de asignar etiquetas a cada palabra del texto para identificar si esa palabra es una entidad, de ser así, es necesario identificar qué tipo de identidad. Los modelos más populares son los modelos basados en *Conditional Random Fields* (CRF) y *Long Short-Term Memory* (LSTM), que han demostrado una alta precisión en varias tareas de reconocimiento de entidades.

Por ejemplo, Huang, Xu, y Yu [26] presentan un enfoque basado en LSTM-CRF, que combina las ventajas de los modelos LSTM y CRF. Este enfoque ha demostrado tener un desempeño superior a otros modelos de referencia en varias tareas de reconocimiento de entidades. La utilización conjunta de estos modelos puede mejorar la precisión de la tarea, manejar secuencias de longitud variable, mejorar la robustez del modelo, mejorar la capacidad de generalización y permitir el aprendizaje profundo.

2.1.9. *Entity Linking*

Entity Linking es una técnica de procesamiento de lenguaje natural que busca identificar entidades mencionadas en un texto y conectarlas con sus representaciones en una base de conocimiento. Según Cornolti et al. [27] el objetivo de la técnica es “mejorar la calidad y la precisión de las búsquedas semánticas, la extracción de información, la recuperación de documentos y otras aplicaciones de procesamiento de lenguaje natural”.

Esta técnica utiliza algoritmos de aprendizaje automático y modelos probabilísticos que analizan el texto y las características de las entidades para determinar su identidad y relevancia en el contexto del documento. Según Hoffart et al. [28], la técnica se divide en tres etapas principales: reconocimiento de entidades, desambiguación de entidades y vinculación de entidades.

El reconocimiento de entidades implica identificar las entidades mencionadas en el texto, mientras que la desambiguación de entidades busca determinar la identidad correcta de cada entidad. Finalmente, la vinculación de entidades conecta las entidades mencionadas en el texto con sus representaciones en la base de conocimiento.

2.2. Trabajos afines

El proceso de codificación consiste en transformar textos clínicos comúnmente escritos por médicos en un formato libre en una lista de códigos siguiendo una terminología médica. Como se mencionó anteriormente, este problema no es trivial y suele ser realizado de forma manual por expertos clínicos. En la figura 2.4 se muestra un ejemplo de codificación automática.




Figura 2.4: Ejemplo de codificación automática de una interconsulta de la lista de espera no-GES.

La codificación automática es una técnica de NLP que se ha utilizado cada vez más en la industria de la salud para automatizar la tarea de codificar registros clínicos en un formato legible por la máquina. Esta técnica utiliza algoritmos de aprendizaje de máquina para analizar los registros médicos y extraer información importante como los diagnósticos, tratamientos y procedimientos realizados durante la atención médica.

La codificación automática tiene muchos beneficios para la industria de la salud. En primer lugar, permite a los médicos y profesionales de la salud dedicar más tiempo a la atención directa del paciente en lugar de pasar horas revisando y codificando manualmente los registros médicos. Además, también puede ayudar a mejorar la precisión y consistencia en la codificación, lo que puede conducir a una mejor gestión y calidad de la atención médica.

La codificación automática también puede tener un impacto significativo en la investigación médica y los estudios estadísticos. Al automatizar el proceso de codificación, los investigadores pueden acceder a grandes cantidades de datos clínicos estructurados de manera más eficiente, lo que les permite realizar análisis más detallados y descubrir patrones y tendencias que pueden ser útiles en la identificación y prevención de enfermedades, y el desarrollo de nuevas terapias.

En el estado del arte se pueden identificar dos grandes grupos de modelos computacionales utilizados para resolver la codificación automática. El primero de ellos es el modelo basado en reglas; mientras que el segundo corresponde al modelo basado en redes neuronales.

2.2.1. Modelos basados en reglas

Este enfoque consiste en la creación y programación de reglas manuales que permitan representar y simular el flujo que siguen los expertos clínicos al momento de asignar códigos a las enfermedades. La mayoría de los estudios pertenecientes a esta categoría se basan en el uso de expresiones regulares, expresiones lógicas y palabras claves para poder transformar enfermedades encontradas en el texto en sus respectivos códigos. El problema de este enfoque es que extender estos algoritmos a cientos y miles de reglas no es viable, ya que consume mucho tiempo y es complejo capturar de forma manual todas las relaciones existentes entre textos y códigos.

Para solucionar el problema, se han propuesto distintos enfoques basados en aprendizaje de máquinas. De esta manera, a las reglas manuales se incorporan características extraídas a partir de modelos estadísticos como árboles de decisión, máquinas de soporte vectorial, entre otros [29–31]. Otro de los métodos utilizados comúnmente es construir una lista de sinónimos y descripciones similares al texto original de manera que pueda ser utilizado para calcular una distancia de palabras con respecto a las descripciones de códigos de la terminología. A pesar de sus desventajas, estos métodos han permitido obtener resultados altos en la literatura, apoyando efectivamente la codificación manual realizada por los humanos [32].

2.2.2. Modelos basados en redes neuronales

En los últimos años, la tarea de codificación automática ha obtenido importantes mejoras gracias al uso de métodos basados en aprendizaje profundo [33]. La ventaja de utilizar estos modelos es que no se requiere de conocimiento experto ni de programar reglas complejas manualmente. Por el contrario, estos métodos son capaces de construir automáticamente características lo suficientemente potentes para capturar las relaciones que existen entre las entradas (textos) y las salidas (códigos).

La mayor parte de los modelos propuestos se basan en plantear el problema como una clasificación de texto multi-etiqueta [34]. Esto quiere decir, que la entrada del algoritmo será un texto, mientras que la salida puede ser una o más etiquetas, que corresponden a los códigos de las enfermedades. A diferencia de los problemas tradicionales de clasificación de texto, este es considerado como una clasificación extrema, dado que la cantidad de posibles etiquetas a predecir asciende a miles (dependiendo de la terminología), lo que no es común en los problemas clásicos de clasificación.

La principal desventaja de utilizar este método es que la codificación manual requiere de la incorporación de reglas específicas del contexto, como prioridad de códigos, suposiciones médicas, el uso de la definición de códigos, sinónimos, entre otro tipo de información que permite mejorar el rendimiento de los sistemas. En el caso del aprendizaje profundo, nada de esto es utilizado ya que generalmente los sistemas son creados de forma *end-to-end*, esto significa que no se involucra el conocimiento humano al momento de crear las características ni tampoco al momento de realizar las predicciones.

Para solucionar el problema anterior, se ocupa otro enfoque utilizado en la literatura, el cual consiste en mezclar los enfoques anteriores mediante dos pasos secuenciales; el primero hace uso de algoritmos de aprendizaje profundo, mientras que el segundo nos permite la incorporación del conocimiento médico al sistema computacional. Primero, se implementa un modelo capaz de reconocer de forma automática secuencias de palabras en el texto que estén asociadas a enfermedades, tarea más conocida como NER. Luego, cada una de las enfermedades encontradas se asocia a su código CIE-10 más probable, tarea más conocida como Entity Linking [35, 36]. Para crear el módulo de NER los métodos más utilizados están basados en redes neuronales profundas, mientras que para crear el segundo módulo una técnica frecuente es utilizar algoritmos de distancias o motores de búsqueda para comparar las enfermedades encontradas con las descripciones de códigos de la terminología.

Capítulo 3

Materiales y Métodos

Para el desarrollo de esta tesis, se utilizaron datos no anonimizados extraídos de lista de espera no-GES en SIGTE. Estos datos corresponden a la lista de espera histórica comprendida entre los años 2016 a noviembre 2022. Para la obtención de estos datos, se realizó un convenio para el desarrollo del proyecto llamado “Extracción automática de información clave dentro de la lista de espera no-GES” entre el Centro de Modelamiento Matemático (CMM) de la Universidad de Chile y el Departamento de Estadística del Ministerio de Salud (DEIS).

A partir de los 73 atributos disponibles en la base de datos, se seleccionaron y distribuyeron en dos conjuntos atributos específicos. El primero de estos conjuntos corresponden a los atributos asociados a la persona, mientras que el segundo corresponde a la información administrativa referente a la interconsulta. Ambos conjuntos de atributos quedan representados en la siguiente tabla:

Tabla 3.1: Conjunto de atributos utilizados de SIGTE.

Conjunto	Atributo	Descripción
Persona	RUN	Identificador único de la persona
	FECHA_NAC	Fecha de nacimiento de la persona
	SEXO	Sexo de la persona
Interconsulta	TIPO_PREST	Prestación general asociada a la interconsulta.
	PRESTA_MIN	Prestación MINSAL asociada a la derivación de la interconsulta Fuente REM 07 y Arancel FONASA.
	PRESTA_MIN_SALIDA	Prestación MINSAL entregada asociada a la interconsulta.
	ESPECIALIDAD_MEDICA	Especialidad médica de la prestación entregada asociada a la interconsulta.
	ESPECIALIDAD_ODON	Especialidad odontológica de la prestación entregada asociada a la interconsulta.
	F_ENTRADA	Fecha de entrada a los registros de Lista de Espera para la consulta de nueva especialidad, procedimiento o la intervención médica.
	C_SALIDA	Indica las causales de salida de los registros de lista de espera definidas en la norma técnica de la Lista de Espera N° 118 [37].
	F_SALIDA	Fecha de realización de la atención para las causales médicas exceptuando causal de salida 0 (GES). Corresponde también a la fecha en que el establecimiento tomo conocimiento de la ocurrencia de la causal administrativa que fundamenta el egreso, excepto la causal 9 (fallecimiento) que se aplica la fecha de fallecimiento de la persona según lo indicado en el Registro Civil.
	SERV_SALUD_ORIG	Servicio de salud de origen asociada a la interconsulta.
	ESTAB_ORIG	Establecimiento de origen asociada a la interconsulta.
	SERV_SALUD_DEST	Servicio de salud de destino asociada a la interconsulta.
	ESTAB_DEST	Establecimiento de destino asociada a la interconsulta.
	SOSPECHA_DIAG	Corresponde al campo de diagnóstico del documento que origina el ingreso de la persona a la Lista de Espera.
CONFIRMACION_DIAG	Corresponde al campo de diagnóstico del documento que origina el ingreso de la persona a la Lista de Espera.	

A partir de los atributos expuestos en la tabla 3.1 y con la finalidad de: a) estudiar el perfil sociodemográfico de los pacientes, y b) analizar la gestión del sistema de salud a través de los tiempos de espera; se formularon nuevos atributos de interés, los cuales quedan representados en la siguiente tabla:

Tabla 3.2: Tabla de atributos formulados para el análisis.

Atributo	Descripción
EDAD	Edad en años al momento de entrar a los registros de Lista de Espera. Atributo calculado en base a los años entre la fecha de entrada (F_ENTRADA) y la fecha de nacimiento de la persona (FEC_NAC).
TIEMPO_ESPERA	Tiempo de espera en días para la consulta médica, procedimiento o intervención quirúrgica en base a la norma técnica de la Lista de Espera N° 118 [37]. Atributo calculado en base a los días que existe entre la fecha de salida (F_SALIDA) y la fecha de entrada (F_ENTRADA) asociada a la interconsulta.

En las tablas 3.1 y 3.2 se muestran los atributos que fueron utilizados para el proceso de análisis de datos. Uno de ellos es el RUN, el cual se empleó con fines estadísticos para evitar la duplicación de diagnósticos por persona. Además, se incluyeron variables sociodemográficas con el objetivo de identificar tendencias y distribuciones de enfermedades a nivel nacional. Esta información se presenta con detalle en los siguientes capítulos, y contribuye a obtener una mejor comprensión del perfil epidemiológico de la población.

3.1. Análisis descriptivo

El conjunto de datos disponibles corresponden a 25.374.491 de interconsultas de la lista de espera con cinco tipo de prestaciones, las cuales corresponden a:

1. Tipo 1 - Consulta Nueva de Especialidad (CNE): primer encuentro médico generado por un episodio de enfermedad, durante el cual se puede o no resolver un problema de salud.
2. Tipo 2 - Consulta repetida o de seguimiento (CCE): atención de especialidad necesaria para resolver el problema de salud por el cual el paciente ingresó al tratamiento. El paciente puede tener varias CCE, lo cual se debe a las sesiones que sean necesarias para dar el alta.
3. Tipo 3 - Procedimiento diagnósticos (Proc): acciones de salud identificadas por prestaciones individuales o grupos de prestaciones que se otorgan a un paciente con fines diagnósticos o terapéuticos. Pueden requerir el uso de equipos, instrumentos, instalaciones o salas específicas.
4. Tipo 4 - Intervención Quirúrgica (IQ): procedimientos quirúrgicos simples y de corta duración, realizados en estructuras de fácil acceso.
5. Tipo 5 - Intervención Quirúrgica Compleja (IQC): procedimientos quirúrgicos complejos que involucran la manipulación de órganos vitales y/o requieren una incisión para acceder a grandes cavidades (incluye cirugía maxilofacial).

La distribución de las interconsultas por tipo de prestación quedan representadas en la figura 3.1. En particular, las interconsultas de interés para este trabajo son las interconsultas CNE, las cuales constituyen la principal fuente de información sobre las enfermedades presentes en los pacientes.

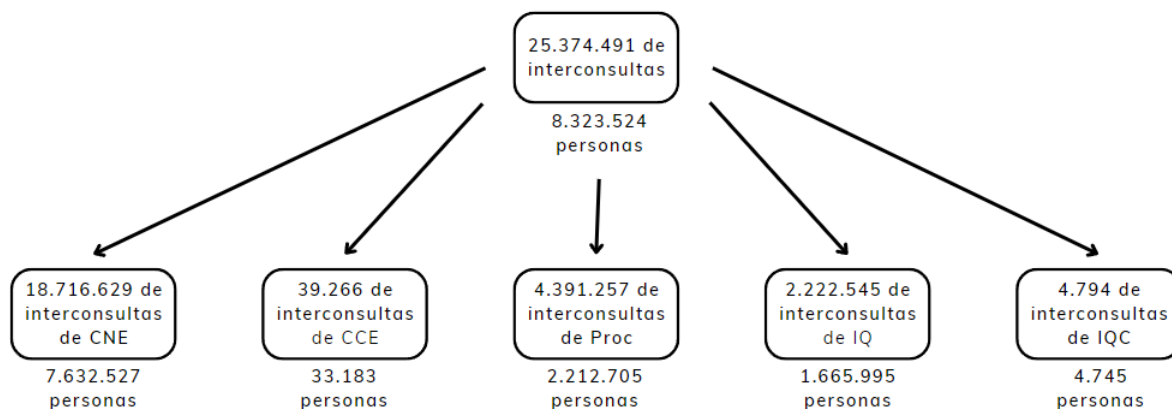


Figura 3.1: Cantidad de interconsultas por tipo de prestación.

Se cuenta con un total de 18.716.629 interconsultas CNE correspondientes a 7.632.527 personas. Para la realización de este trabajo se han considerado también los datos anteriores a 2016, los cuales corresponden a la migración del Repositorio Nacional de Lista de Espera (RNLE) al sistema SIGTE. La magnitud de los datos disponibles de interconsultas de CNE se representa en la tabla 3.3.

Tabla 3.3: Cantidad de CNE por año en SIGTE.

Año	Cantidad de CNE
Ene - Nov 2022	1.767.360
2021	2.028.732
2020	1.365.320
2019	2.618.894
2018	2.522.063
2017	2.484.150
2016	2.213.824
2015	2.027.736
1979 - 2014	1.688.550

Es relevante señalar que en el desarrollo de esta tesis se emplea la información diagnóstica del paciente, la cual se encuentra disponible en dos columnas de la base de datos de SIGTE: **SOSPECHA_DIAG** y **CONFIRMACION_DIAG**. Dichas columnas contienen el diagnóstico del paciente expresado en texto libre en diversas etapas del proceso de lista de espera.

3.2. Análisis de variables categóricas

Para el análisis de las variables categóricas, en primer lugar, se estudiará la distribución de las especialidades médicas a las que pertenecen las interconsultas CNE. Para ello, se presenta en el Anexo las tablas .2 y .3. A modo de ejemplo, se considerarán las diez primeras especialidades presentes en dicha tabla:

Tabla 3.4: Distribución del top 10 de las especialidades médicas presentes en lista de espera histórica.

Especialidad	Conteo
Oftalmología	3.352.203
Otorrinolaringología	1.270.563
Traumatología y Ortopedia	1.066.814
Ginecología	991.166
Cirugía General	982.500
Dermatología	762.758
Medicina Interna	703.844
Endodoncia	662.607
Rehabilitación Oral Prótesis Removible	652.604
Urología	605.425

En la tabla 3.4, se puede observar que las especialidades médicas con mayor lista de espera en el sistema público son oftalmología, seguida de otorrinolaringología y traumatología y ortopedia. Esta información es relevante ya que nos permite tener una idea clara de cuáles son las áreas de la medicina que requieren mayor atención en el sistema público de salud, lo que podría ayudar a priorizar la asignación de recursos para mejorar la atención médica.

Dentro de las especialidades mencionadas anteriormente en las tablas .4 y .5 en la sección de Anexos, se puede apreciar la estadística que tienen los diagnósticos de las aproximadamente 70 especialidades presentes en interconsultas CNE. Para cualquiera de estas especialidades, en la presente investigación se considerará un diagnóstico a partir de dos casos: si es que estos atributos de **SOSPECHA_DIAG** y **CONFIRMACION_DIAG** son diferentes, se unen los atributos; en caso contrario, al ser iguales los atributos solo se consideraría uno de estos como diagnóstico.

Tabla 3.5: Top 10 especialidades con mas tokens por oración.

Especialidad	Cantidad de tokens (std)	Cantidad de oraciones (std)	Cantidad de tokens por oraciones
Infectología	28,60 (48,05)	1,50 (1,61)	18,95
Oncología Médica	20,10 (42,13)	1,15 (0,67)	17,40
Diabetología	19,03 (33,07)	1,34 (1,32)	14,22
Reumatología Pediátrica	15,06 (30,96)	1,19 (0,75)	12,61
Patología Oral	14,55 (24,52)	1,18 (0,69)	12,34
Neonatología	12,93 (31,31)	1,10 (0,56)	11,66
Hemato-oncología Pediátrica	12,71 (26,75)	1,16 (0,75)	10,94
Cirugía Plástica y Reparadora Pediátrica	12,14 (16,34)	1,11 (0,51)	10,89
Ginecología Pediátrica y de la Adolescencia	13,01 (22,61)	1,22 (0,83)	10,61
Traumatología y Ortopedia Pediátrica	12,27 (18,40)	1,16 (0,74)	10,56

Se puede observar que diagnósticos de las especialidades presentes en la tabla 3.5 presentan una mayor cantidad de tokens por oraciones, es decir, las interconsultas de especialidades como infectología, oncología médica y diabetología son en promedio mas extensos a la hora de escribir un diagnostico para las personas.

En primer lugar, esta extensión en los diagnósticos asociados a estas especialidades suelen tratar enfermedades complejas y crónicas que requieren un mayor nivel de detalle en la descripción del diagnóstico. Por ejemplo, una interconsulta de oncología médica puede incluir información sobre la localización del tumor, su tamaño, el grado de diferenciación celular, entre otros aspectos relevantes. En segundo lugar, estas especialidades pueden tener una mayor cantidad de factores de riesgo o comorbilidades asociadas a la enfermedad. En el caso de la diabetología, por ejemplo, se debe considerar no solo el control de la glucemia, sino también la prevención de complicaciones a largo plazo como enfermedades cardiovasculares, neuropatías, retinopatías, entre otras. Asimismo, es importante destacar que la alta desviación estándar en el conteo de palabras y oraciones de los diagnósticos médicos indica una gran variabilidad en su longitud y complejidad, lo que debe ser considerado en su análisis y comparación.

Tabla 3.6: Top 10 especialidades con menos tokens por oración.

Especialidad	Cantidad de tokens	Cantidad de oraciones	Cantidad de tokens por oraciones
Operatoria	7,59 (7,42)	1,09 (0,38)	6,99
Oftalmología	7,97 (9,61)	1,16 (0,51)	6,88
Endodoncia	8,15 (8,93)	1,19 (0,57)	6,87
Cirugía Digestiva	7,40 (13,56)	1,12 (0,45)	6,81
Nutriólogo Pediátrico	7,63 (9,54)	1,12 (0,56)	6,80
Periodoncia	8,41 (11,62)	1,24 (0,68)	6,78
Medicina Familiar	7,82 (14,70)	1,16 (0,51)	6,76
Cirugía Bucal	7,66 (6,45)	1,14 (0,47)	6,72
Imagenología Oral y Maxilofacial	5,21 (2,55)	1,02 (0,21)	5,11
Salud Ocupacional	4,16 (1,41)	1,01 (0,11)	4,12

En contraste, según se observa en la tabla 3.6, las interconsultas de especialidades como cirugía bucal, imagenología oral y maxilofacial, y salud ocupacional presentan diagnósticos más cortos en promedio en términos de la cantidad de tokens por oración. En el caso de cirugía bucal, los diagnósticos suelen estar relacionados con intervenciones quirúrgicas más específicas y limitadas en su alcance, como extracciones dentales o cirugías de implante, que no requieren de una descripción extensa. En la imagenología oral y maxilofacial, los diagnósticos se enfocan en describir los hallazgos radiográficos u otras técnicas de diagnóstico por imagen, los cuales pueden ser relevantes para el tratamiento de la patología oral, pero no necesariamente requieren una descripción extensa desde el punto de vista clínico. En el caso de la salud ocupacional, los diagnósticos están relacionados con enfermedades o accidentes laborales, que aunque pueden tener consecuencias significativas para la salud de los trabajadores, no siempre requieren una descripción detallada en términos clínicos.

En resumen, la longitud de los diagnósticos puede estar influenciada por varios factores, incluyendo la complejidad de la patología y la variabilidad en la terminología y enfoque utilizado por los médicos de diferentes especialidades. Sin embargo, lo más importante es que el diagnóstico contenga la información necesaria y relevante para el tratamiento del paciente. Es crucial que los médicos se centren en proporcionar una documentación precisa y detallada que permita tomar decisiones informadas y diseñar planes de tratamiento efectivos, independientemente de la longitud del diagnóstico.

3.3. Modelamiento del problema

La figura 3.2 muestra un esquema del flujo de la propuesta del modelo de codificación automática, y a continuación se explica en detalle los dos módulos principales del modelo; el NER y el motor de búsqueda (ElasticSearch).

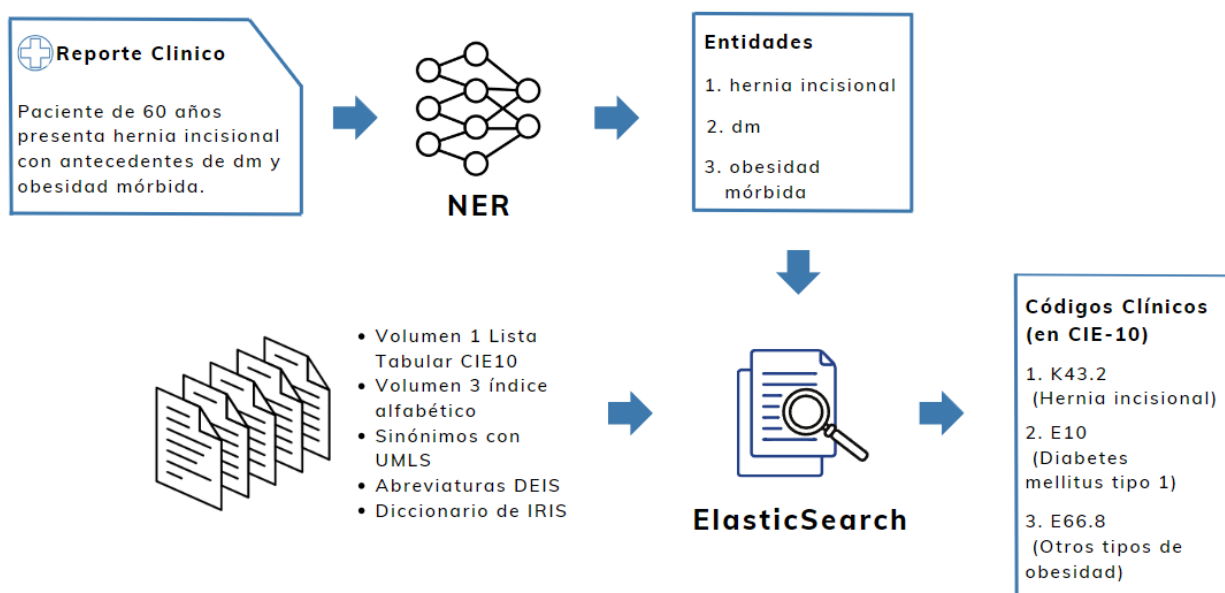


Figura 3.2: Propuesta de codificación automática de enfermedades.

3.3.1. Primer modulo: Reconocimiento automático de enfermedades

Como se muestra en la parte izquierda de la figura 3.2, la entrada del sistema es la interconsulta escrita por el médico en forma de texto libre. Estos textos se utilizan como entrada para el modelo de reconocimiento automático de enfermedades. En particular, este modelo NER está basado en el trabajo propuesto de Rojas [38], donde se introduce una arquitectura simple pero altamente efectiva para el reconocimiento de entidades médicas. Esta arquitectura consiste en una red neuronal profunda compuesta de tres módulos principales, poniendo énfasis en la creación de buenas representaciones numéricas para la secuencia de palabras que entra al modelo.

Como se muestra en la figura 3.3, la primera capa denominada “Stacked embedding layer”, se encarga de transformar los textos asociados a los diagnósticos a una representación vectorial para que los algoritmos puedan operar con ellos. Luego, en la capa de codificación, se utiliza una red neuronal recurrente para obtener largas dependencias entre palabras en la oración, obteniendo así un mejor contexto con el fin de mejorar las representaciones de la capa anterior. Finalmente, la capa de clasificación se encarga de asignar la etiqueta más probable a cada palabra del diagnóstico, logrando identificar qué partes del texto corresponden a una enfermedad.

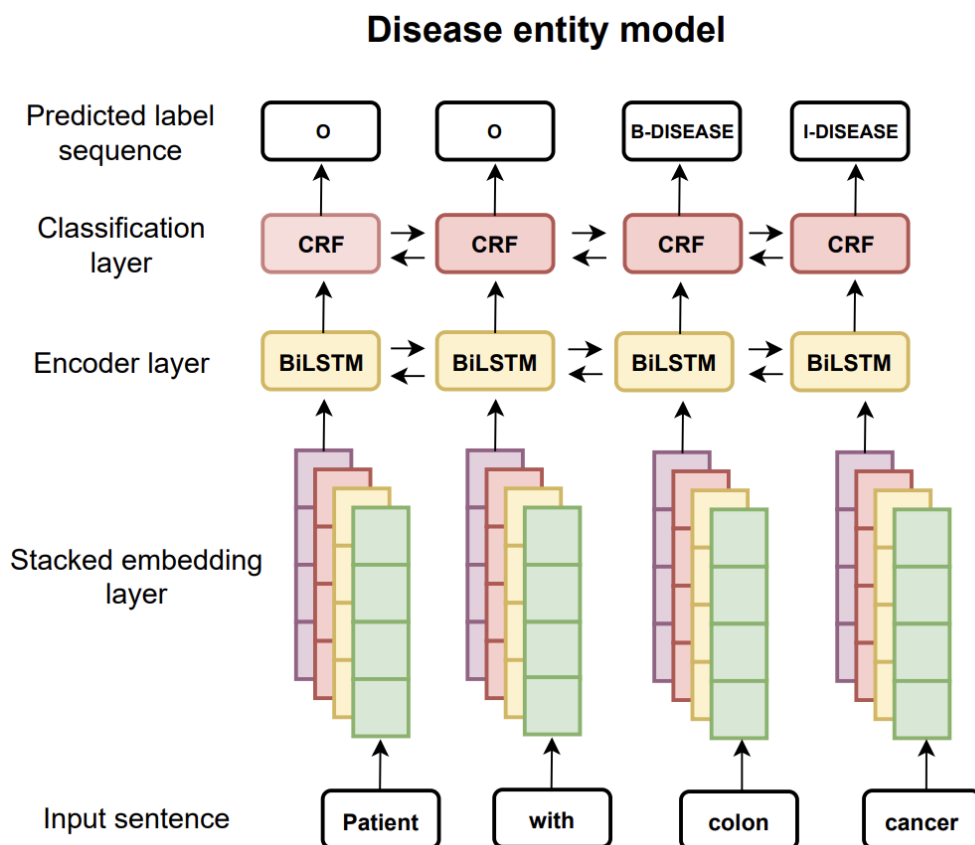


Figura 3.3: Propuesta de modelo de reconocimiento de enfermedades. Extraído de [38].

3.3.2. Segundo módulo: Codificación automática de enfermedades

Como se mencionó, el resultado del primer módulo del sistema es una lista que contiene todas las menciones de enfermedades en la interconsulta. En este segundo módulo, le asignaremos un código de la nomenclatura CIE-10 a cada una de estas menciones, el cuál puede ser utilizado posteriormente para decisiones clínicas o gestión.

La asignación del código CIE-10 se realiza utilizando un motor de búsqueda que encuentra similitudes entre la mención de la enfermedad y los códigos en la lista tabular de la CIE-10. Este sistema se basa en Apache Elasticsearch, un motor de búsqueda y análisis de código abierto mantenido por la Apache Foundation ². Este proceso ayuda a automatizar la asignación de códigos y reduce el tiempo y el esfuerzo necesarios para asignar manualmente los códigos a cada mención de enfermedad.

A diferencia de los algoritmos de comparación de distancia entre palabras como por ejemplo en el trabajo de Rojas et al. [39] donde se utiliza el algoritmo de distancia de Levenshtein, este motor de búsqueda cuenta con un índice que contiene a cada una de las enfermedades CIE-10 representadas a través de una serie de oraciones sinónimas extraídas desde distintas fuentes de información, simulando de mejor forma el proceso que siguen los expertos clínicos para determinar el código de una enfermedad. Las fuentes de información utilizadas para la extracción de definiciones sinónimas de las enfermedades fueron las siguientes:

1. Lista Tabular de la CIE-10, Volumen 1: base de datos que contiene la clasificación de enfermedades y problemas de salud relacionados, presentada en un formato alfanumérico jerárquico, diseñada para facilitar la identificación y codificación de enfermedades y procedimientos médicos.
2. Índice Alfabético de la CIE-10, Volumen 3: base de datos que contiene la herramienta de referencia que proporciona una lista alfabética de términos médicos y de salud relacionados, junto con los códigos correspondientes de la clasificación CIE-10. Esta base de datos se obtuvo de manera no oficial utilizando la técnica “web scraping” desde el sitio web del Ministerio de Sanidad de España³.
3. Diccionario de IRIS: mapeo de oraciones en lenguaje natural hacia un código de la CIE-10. Este diccionario fue construido con los procesos de codificación de mortalidad realizadas en el DEIS.
4. Abreviaturas DEIS: abreviaciones DEIS: Lista de abreviaturas construida manualmente y sus expansiones por equipo del DEIS.
5. UMLS: definiciones en español desde múltiples vocabularios extraídos desde el metatesauro UMLS⁴.

² Motor de búsqueda Elasticsearch en el siguiente enlace: <https://www.elastic.co/es/elasticsearch/>

³ Índice Alfabético CIE-10 en el siguiente enlace: https://eciemaps.mscbs.gob.es/ecieMaps/browser/index_10_2008.html

⁴ Metatesauro de UMLS en el siguiente enlace: https://www.nlm.nih.gov/research/umls/knowledge_sources/metathesaurus/index.html

Por ejemplo, en el índice se puede encontrar el código “K021”, el cual contiene la descripción explícita según la glosa “Caries de la dentina”, pero también múltiples definiciones sinónimas, tales como “Caries dental que se extiende hasta la dentina” y “Caries de dentina”. Esto es importante ya que las menciones de enfermedades encontradas en diagnósticos no estructurados pocas veces serán equivalentes a la definición exacta.

3.4. Creación de *Gold Standard* y rendimiento humano

Dado que los sistemas implementados se basan en modelos de inteligencia artificial, es importante realizar experimentos que permitan evaluar la precisión del modelo en comparación con las decisiones tomadas por un experto clínico, y medir el acuerdo entre los expertos. Con este fin, se llevarán a cabo tres experimentos en los que se utilizará una muestra de interconsultas no-GES por cada uno de estos para que sean codificadas manualmente por un equipo de codificadoras expertas. A continuación, se detallarán todos los aspectos del proceso de experimentación y los pasos de validación del sistema.

1. **Primer experimento:** muestra de 230 diagnósticos de interconsultas de la lista de espera de tipo IQ. Para esto, se seleccionarán 130 interconsultas para que cada una de las expertas en identificación y codificación de patologías las codifiquen. De estas, 30 interconsultas serán comunes entre ellas.
2. **Segundo experimento:** muestra de 500 diagnósticos de interconsultas de lista de espera de tipo CNE. Con el fin de determinar el nivel de acuerdo entre las expertas en la identificación y codificación de las patologías, cada una tendrá acceso a la misma muestra de diagnósticos, presentada en un orden diferente.
3. **Tercer experimento:** muestra de diez diagnósticos aleatorios por cada especialidad médica entre las aproximadamente 70 especialidades presentes en las interconsultas de CNE.

La codificación de cada experimento se llevará a cabo mediante la entrega de un archivo Excel que tendrá una columna en la que se detallarán uno o varios diagnósticos presentes en los campos de texto libre. Esto permitirá comparar el modelo y el acuerdo entre las codificadoras.

3.5. Métricas utilizadas

Dentro de las métricas a utilizar para realizar un análisis más granular del rendimiento de los modelos, se realizará un estudio con dos niveles de precisión descritos en la figura 3.4.

- Acierto a nivel de categoría de la lista tabular de CIE-10, es decir, acierto a la primera letra más dos dígitos de especificidad.
- Acierto del modelo a nivel de subcategoría de la lista tabular de CIE-10, es decir, acierto a la primera letra más tres dígitos de especificidad.

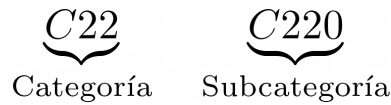


Figura 3.4: Ejemplo de los dos niveles de precisión utilizados para calcular la métrica IoU y MAP.

A continuación se presentan en detalle las métricas utilizadas comúnmente para el desarrollo de la tarea de codificación automática, las cuales corresponden a *Intersection Over Union* (IoU) y el *Mean Average Precision* (MAP).

3.5.1. *Intersection Over Union* (IoU)

Una de las métricas oficiales utilizada para la codificación automática, es el llamado *Intersection Over Union* (IoU) o también conocido como Índice de Jaccard. Esta métrica lo que hace es calcular el grado de similitud que existe entre dos conjuntos, mediante el cálculo de la intersección de elementos y también la unión. La fórmula matemática para su cálculo es la siguiente:

$$IoU(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (3.1)$$

Como a modo de ejemplo, se quiere comparar el nivel de similitud entre una lista de enfermedades entregada por Alicia versus la lista de enfermedades entregada por Sofía. Supongamos que la codificadora Alicia encuentra las siguientes enfermedades en el diagnóstico:

{Hipertensión, Diabetes, Obesidad, Depresión}

mientras que Sofía encuentra las siguientes enfermedades:

{Hipertensión, Diabetes, Obesidad, Bipolaridad}

En este caso la intersección entre ambos conjuntos sería:

{Hipertensión, Diabetes, Obesidad}

Con una cardinalidad de tamaño 3, mientras que la unión es:

{Hipertensión, Diabetes, Obesidad, Depresión, Bipolaridad}

Con una cardinalidad de tamaño 5. Así la métrica IoU para este ejemplo sería $\frac{3}{5} = 0.6$. Este mismo razonamiento puede ser aplicado para comparar una lista de códigos entregada por el sistema versus la lista entregada por la codificadora.

3.5.2. *Mean Average Precision* (MAP)

El *Mean Average Precision* (MAP) es una medida ampliamente utilizada para evaluar la calidad de los resultados de un sistema de recuperación de información, como un motor de búsqueda. Un ejemplo del uso de esta métrica es la competencia CodiEsp [40], que consistía en la codificación automática de enfermedades y procedimientos médicos en español. El

MAP representa la media aritmética de la precisión en todas las consultas relevantes en un conjunto de datos de evaluación, esta se define de la siguiente manera:

$$AveP = \frac{\sum(P(k) \cdot rel(k))}{\text{numero de documentos relevantes}} \quad (3.2)$$

Donde $P(k)$ representa la precisión en la posición k , y $rel(k)$ es una función indicadora igual a 1 si el elemento en el rango k es un documento relevante y 0 en caso contrario.

El MAP se calcula utilizando la implementación en Python de la herramienta de evaluación TREC, *trectools*, de Palotti et al. [41], donde se aplicó una adaptación, en la que los diagnósticos codificados deben ordenarse en base a un ranking, que para este trabajo se considera el orden en el que se encontró la mención y posteriormente se asignó el código.

3.6. Despliegue

Con base en el sistema de codificación automática a implementar mediante el primer módulo de “Reconocimiento automático de enfermedades” y el segundo módulo de “Codificación automática de enfermedad” mencionados anteriormente, la comunicación con ambos módulos se realizara a través de un servicio web. Para el primer módulo se diseñara un servicio web específico, mientras que para el segundo módulo, ElasticSearch ya contaba con un servicio web integrado.

Ambos módulos serán desplegados en contenedores en la máquina local de DEIS, utilizando el programa Docker sobre la capa de compatibilidad de Subsistema de Windows para Linux (WSL). Además, se utilizara el programa KNIME para implementar el flujo de trabajo de codificación automática que toma las consultas no codificadas y las codifica mediante el servicio web mencionado anteriormente. Los diagnósticos codificados serán alojados en el *datawarehouse* del DEIS para su posterior consumo. Para esto se tiene disponible un computador local las siguientes especificaciones:

- Intel Xeon W-2265, 3.50GHz, 12 nucleos y 24 hilos
- NVIDIA RTX A4000, 6144 núcleos CUDA
- RAM 64 GB
- Sistema Operativo Windows 11

Capítulo 4

Resultados

4.1. *Gold Standard* y acuerdo humano

Considerando que la fuente de verdad utilizada para medir el rendimiento del modelo es la codificación realizada por las expertas, es importante medir el nivel de concordancia que existe entre ellas, ya que esto daría un indicio del grado de dificultad que presenta esta tarea, incluso para los propios expertos. Al medir el nivel de acuerdo, se pueden generar las muestras *Gold Standard* y realizar una comparación más cercana al rendimiento del modelo de codificación.

4.1.1. Primer experimento

Se considero 230 diagnósticos de casos abiertos de la lista de espera de IQ codificados manualmente, 130 para la primera codificadora (muestra 1) y 130 para la segunda codificadora (muestra 2), con 30 diagnósticos en común. Se presenta el acuerdo que hay entre las codificadoras mediante las métricas IoU y MAP, lo cual se refleja en la siguiente tabla:

Tabla 4.1: Acuerdo entre codificadoras para el primer experimento.

Nivel especificidad	IoU	MAP
Nivel Subcategoría	0,73	0,75
Nivel Categoría	0,85	0,86

Dentro los 30 diagnósticos que se tenían en común, se observó en la tabla 4.1 una gran cantidad de procedimientos médicos registrados en campos de texto libre. Sin embargo, estos procedimientos no pudieron ser codificados en CIE-10 ya que no representan una enfermedad en sí misma y existió desacuerdo entre las codificadoras. Además, se observó que en la codificación manual, cuando se buscó un alto nivel de especificidad de tres dígitos, el acuerdo según la métrica de MAP fue solo del 0,75. Por otro lado, si se relajaba el nivel de especificidad y se consideraban solo dos dígitos, el acuerdo aumentaba al 0,86.

4.1.2. Segundo experimento

Se considero una muestra de 500 interconsultas de CNE, las cuales con la ayuda de las dos codificadoras se les asignaron códigos CIE-10 asociados a esta muestra. En este experimento las codificadoras expertas codificaron la misma muestra de 500 diagnósticos pero en distinto orden. Se presenta el acuerdo que hay entre las codificadoras mediante las métricas IoU y MAP, lo cual se refleja en la siguiente tabla:

Tabla 4.2: Acuerdo entre codificadoras para el segundo experimento.

Nivel especificidad	IoU	MAP
Nivel Subcategoría	0.66	0.75
Nivel Categoría	0.83	0.83

La tabla 4.2 muestra que el acuerdo entre las codificadoras a nivel de tres dígitos fue del 0.75 en MAP. Sin embargo, cuando se consideraron dos dígitos, este valor aumentó a 0.83. Es importante destacar que, en comparación con el experimento anterior, el nivel de acuerdo entre las codificadoras disminuyó en el segundo experimento. Este cambio puede estar relacionado con el hecho de que las interconsultas CNE utilizadas en este experimento no presentaban un nivel significativo de procedimientos en los diagnósticos médicos, según lo reportado por el equipo de expertas en codificación.

4.1.3. Tercer experimento

Se seleccionó una muestra de diez interconsultas por cada especialidad médica de entre las aproximadamente 70 especialidades presentes en las interconsultas de CNE, lo que resultó en una muestra total de alrededor de 688 diagnósticos, con un equilibrio por especialidad médica. Es importante mencionar que debido a la limitación de personal experto y tiempo disponible, en este experimento solo se realizó la codificación manual con una experta, por lo que no se puede medir el acuerdo entre humanos.

4.2. Resultado de los modelos

En acuerdo con el DEIS, se determinó que la métrica MAP a maximizar sería la codificación a nivel de categoría, es decir, que el modelo sea capaz de reconocer el primer carácter y los siguientes 2 dígitos con una gran precisión, ya que tiene un mayor impacto en la gestión de la lista de espera y cualquier resultado que se tenga con mas dígitos este sera truncado. A modo de ejemplo del funcionamiento del modelo, se presenta la tabla 4.3, donde la primera columna incluye ejemplos reales de diagnósticos médicos en texto libre, seguida del código asignado por el sistema de codificación automática y, finalmente, la descripción del código.

Tabla 4.3: Ejemplo del sistema de codificación automática.

Texto Libre	Código	Descripción
tu anexial der	C574	Tumor maligno de los anexos uterinos, sin otra especificación
ca papilar de tiroides	C73	Tumor maligno de la glándula tiroides
tu via urinaria	C689	Tumor maligno de órgano urinario no especificado
nodulo pulmonar lsd	C341	Tumor maligno del lóbulo superior, bronquio o pulmón
cancer gastrico antral	C163	Tumor maligno del antro pilórico
cancer de colon izq	C186	Tumor maligno del colon descendente
tu metastasico	C799	Tumor maligno secundario de sitios no especificados
carcinomatosis peritoneal	C786	Tumor maligno secundario del peritoneo y del retroperitoneo
metastasis	C798	Tumor maligno secundario de otros sitios especificados
cacu	C539	Tumor maligno del cuello del útero, sin otra especificación

Para saber qué tan buenos son estos resultados, es importante tener como punto de comparación los resultados de codificación automática actuales en la literatura. En otras palabras, se revisa el nivel de error que tienen actualmente los mejores modelos, los que han obtenido el estado del arte en distintos datasets de codificación en Español. Esto permite saber que tantas mejoras se podrían realizar al sistema y también confirmar si es que los resultados obtenidos de forma teórica pueden ser replicados en la práctica o existentes factores externos que no se están considerando.

Actualmente, los principales datasets en Español que se utilizan para evaluar el rendimiento de modelos de codificación de enfermedades y procedimientos son los siguientes:

- **CodiEsp**⁵ [40]: Corpus compuesto por 1.000 casos clínicos anotados manualmente utilizando las directrices *ICD10-Clinical Modification* y *ICD10-Procedure*. Este conjunto de datos se utilizó para dos tareas compartidas: CodiEsp Diagnostics (CodiEsp-D) y CodiEsp Procedures (CodiEsp-P).
- **CANTEMIST**⁶ [42]: Corpus compuesto por 1.301 informes de casos clínicos oncológicos anotados utilizando los códigos CIE-O-3.

A continuación, se presenta una tabla resumen correspondiente al estado del arte actual en la codificación automática, extraída del trabajo de Barros et al. [43]. Se puede apreciar que los mejores resultados obtenidos hasta la fecha en problemas similares al de la lista de espera oscilan entre 0.6 y 0.8, de acuerdo con las métricas MAP y F1-Score (semejantes a IoU).

⁵ Corpus de diagnósticos y procedimientos en español de CodiEsp en el siguiente enlace: <https://zenodo.org/record/3837305>

⁶ Corpus de diagnósticos oncológicos en español de CANTEMIST en el siguiente enlace: <https://zenodo.org/record/3978041>

Tabla 4.4: Estado del arte actual en codificación automática. Tabla extraída de [43].

Modelo	CodiEsp-D		CodiEsp-P		CANTEMIST	
	MAP	F ₁	MAP	F ₁	MAP	F ₁
IXA-AAA [44]	0.593	0.009	0.425	0.008	-	-
IAM [45]	0.521	0.687	0.493	0.522	-	-
FLE [46]	0.519	0.679	0.443	0.514	-	-
The Mental Stokers [47]	0.517	0.591	0.445	0.488	-	-
Vicomtech [48]	-	-	-	-	0.847	0.855
ICB-UMA [49]	0.482	0.009	-	-	0.847	0.013
Clinical Transformers - Best [50]	0.616	-	0.514	-	0.862	-
Clinical Transformers - Ensemble [50]	0.662	-	0.544	-	0.884	-
Divide and Conquer (DAC) [43]	0.665	0.746	0.545	0.553	0.788	0.712
Divide and Conquer - Ensemble (DAC-E) [43]	0.682	0.744	0.562	0.560	0.804	0.695

La tarea de codificación de enfermedades en registros médicos es compleja, especialmente si las codificaciones manuales no coinciden al 100%. Esta variabilidad puede afectar la precisión y confiabilidad de los modelos de codificación automática, ya que incluso pequeñas diferencias pueden tener un impacto significativo en la calidad de los resultados. Estos errores pueden influir directamente en la toma de decisiones clínicas. Por tanto, es importante considerar la variabilidad en la codificación manual al desarrollar y evaluar modelos automáticos. Cabe destacar que, aunque el acuerdo entre las codificadoras es mayor que lo obtenido actualmente en la literatura con modelos automáticos, sigue reafirmando la complejidad de esta tarea.

Los resultados de cada experimento serán presentados de manera separada, ya que cada uno de ellos evaluó diferentes aspectos del sistema de codificación automática. Es importante tener en cuenta que estos resultados no deben considerarse comparables en magnitud con los valores presentados en la tabla 4.4, ya que el modelo propuesto no se pudo poner a prueba con los datasets utilizados en esos estudios, es decir, CodiEsp-D, CodiEsp-P y CANTEMIST, ya que tienen un tipo de codificación diferente y están diseñados para contextos específicos del país en el que se desarrollaron. Además, los sistemas de codificación automática utilizados en otros estudios pueden tener diferentes algoritmos y configuraciones, lo que hace que las comparaciones sean aún más difíciles de hacer y el sistema de codificación propuesto están orientados a la realidad chilena.

4.2.1. Primer experimento

Para llevar a cabo el primer experimento de codificación automática, se tomó en cuenta una lista tabular del volumen 1 del CIE-10, así como el índice alfabético de la misma clasificación. Además, se utilizaron sinónimos obtenidos de otras nomenclaturas a través de UMLS, abreviaciones extraídas automáticamente de revistas médicas y abreviaturas realizadas por profesionales del DEIS.

Los resultados de la codificación se presentan para cada muestra y se incluye una versión modificada de cada muestra con las correcciones realizadas mediante codificación manual en los diagnósticos en común. Estas muestras son consideradas como el *Gold Standard* para

comparar la precisión del modelo. A continuación, se presenta una tabla con los resultados obtenidos.

Tabla 4.5: Métricas de la muestra 1 y 2 y su versión Gold Standard del primer experimento.

	Muestra 1		Muestra 2		Muestra 1 (Gold Standard)		Muestra 2 (Gold Standard)	
	IoU	MAP	IoU	MAP	IoU	MAP	IoU	MAP
Nivel Subcategoría	0.50	0.71	0.39	0.51	0.50	0.73	0.41	0.58
Nivel Categoría	0.61	0.81	0.55	0.76	0.61	0.81	0.56	0.77

En la tabla 4.5 se puede observar que el rendimiento del sistema de codificación es distinto para la muestra 1 y en la muestra 2, según la métrica MAP. Es decir, se logra una tasa de acierto del 0.71 para la muestra 1 y 0.51 para la muestra 2 cuando se busca una especificidad de tres dígitos. Por otro lado, si se considera una especificidad de dos dígitos, se obtiene un 0.81 de acierto para la muestra 1 y un 0.76 para la muestra 2. Sin embargo, estos valores no presentan un cambio significativo cuando se usan muestras del *Gold Standard*.

Es importante destacar que los resultados mencionados están entre los redimientos del estado del arte, el cual se describen en la tabla 4.4. Por esta razón, se analizaron los diagnósticos que presentaron una codificación con un IoU menor a 0.5, dado que esta métrica es mas sencilla de comprender y se compartieron con las profesionales expertas en codificación, en donde también se comento en una primera instancia que los diagnósticos estudiados tenían una gran presencia de procedimientos los cuales no tiene un código CIE-10 asociado. Los comentarios recibidos fueron considerados para los siguientes experimentos.

4.2.2. Segundo experimento

Para el segundo experimento, se consideraron 500 diagnósticos de interconsultas CNE. Cada experta codificó la misma muestra, la cual denominaremos como muestra 1 y muestra 2. Se seleccionaron interconsultas de CNE para analizar el comportamiento del sistema de codificación automática en una muestra que debería contener solo diagnósticos y no procedimientos, como se observó en el primer experimento. Debido a este enfoque, en la siguiente tabla se presentan los resultados para la muestra 1 y 2. Al igual que en el experimento anterior, se llevó a cabo la corrección por parte de las expertas para generar la muestra *Gold Standard*.

Tabla 4.6: Métricas de la muestra 1 y 2 y su versión Gold Standard del segundo experimento.

	Muestra 1		Muestra 2		Muestra (Gold Standard)	
	IoU	MAP	IoU	MAP	IoU	MAP
Nivel Subcategoría	0,43	0,59	0,46	0,61	0,45	0,63
Nivel Categoría	0,65	0,81	0,60	0,78	0,64	0,82

En la tabla 4.6, se muestran los resultados obtenidos en un experimento que evaluó la capacidad del modelo con distintas muestras para la codificación de enfermedades con diferentes niveles de especificidad. Los resultados indican que, al considerar una especificidad de tres dígitos, se obtuvo un 0,59 de acierto en la métrica MAP para la muestra 1 y un 0,61 para la muestra 2. Por otro lado, al considerar una especificidad de dos dígitos, el acierto aumentó a un 0,81 para la muestra 1 y un 0,78 para la muestra 2. Además, es importante destacar que los resultados obtenidos con la muestra de *Gold Standard* no presentaron un gran cambio en comparación con los resultados de la muestra 1, donde se obtuvo un 0,63 en MAP a nivel de tres dígitos y un 0,82 a nivel de dos dígitos.

Es importante destacar que estos resultados muestran un ligero aumento en los dos niveles de especificidad en comparación con el experimento anterior, lo que sugiere que este sistema está mejorando su capacidad para codificar enfermedades con mayor precisión, según el perfil de la muestra utilizada. Además, se debe tener en cuenta que esta muestra presenta un desequilibrio en cuanto a la distribución de especialidades médicas, siendo las especialidades odontológicas las más representadas.

4.2.3. Tercer experimento

Para obtener una retroalimentación más precisa del poder predictivo del modelo en relación a las especialidades médicas, se seleccionó una muestra de 688 diagnósticos de interconsultas CNE, aproximadamente 10 por cada una de las 70 especialidades médicas. Los resultados del rendimiento del sistema de codificación en comparación con la codificación realizada por la experta se presentan en la siguiente tabla.

Tabla 4.7: Métricas de la muestra Gold Standard del tercer experimento.

	Muestra (Gold Standard)	
	IoU	MAP
Nivel Subcategoría	0,52	0,64
Nivel Categoría	0,69	0,83

La tabla 4.7 muestra que, a nivel de tres dígitos de especificidad, se obtiene un MAP de 0,64, mientras que al considerar dos dígitos de especificidad, esta aumenta a 0,83. Se observa un leve aumento en base a las métricas de rendimiento mostradas en las tablas 4.5 y 4.6. Es importante mencionar que, la principal diferencia entre el tercer experimento y el segundo experimento fue el equilibrio de las especialidades médicas disponibles. En el experimento dos, se tenía una gran presencia de especialidades odontológicas donde tanto la codificación automática como la manual presentaron problemas en su codificación. Por lo tanto, en el tercer experimento se tuvo cuidado en seleccionar un conjunto más equilibrado de especialidades médicas para tener una muestra más representativa. Los resultados sugieren que un equilibrio en las especialidades médicas puede tener un impacto positivo en el rendimiento del sistema de codificación automática y ver posibles mejoras o casos en particular por especialidad.

En base a lo mencionado anteriormente, se estudió la métrica IoU por especialidad médica para poder observar qué especialidades tienen un mejor rendimiento y cuáles no. Este

análisis permitió identificar las áreas de oportunidad para posibles mejoras en la codificación automática. Es importante destacar que la métrica IoU proporciona una medida de superposición entre los códigos predichos y los códigos reales, lo que permite evaluar de manera más detallada el rendimiento del sistema de codificación automática. Los resultados del análisis de la métrica IoU por especialidad médica se presentan en las tablas .6 y .7 en la sección de Anexos. Este análisis proporciona información valiosa sobre las especialidades médicas en las que el sistema de codificación automática tiene un buen desempeño y aquellas en las que se necesitan mejoras para obtener un mejor rendimiento.

A modo de resumen, en las tablas 4.8 y 4.9 se muestran las 10 prestaciones médicas en donde se obtuvieron mejores y peores resultados. Los principales hallazgos encontrados son los siguientes:

- En los diagnósticos correspondientes a la tabla 4.8, existe alto nivel de acierto principalmente dada la forma en que están escritos los diagnósticos; textos muy específicos que omiten información poco relevante.
- Los peores resultados presentes en la tabla 4.9 coinciden con las interconsultas que en vez de presentar un diagnóstico, presentan un texto clínico con antecedentes mórbidos y solicitudes de evaluaciones, dificultando su análisis. Además, se observó discordancia entre la especialidad a la que se derivaba y el diagnóstico.

Tabla 4.8: Top 10 especialidades con mejor rendimiento.

ESPECIALIDAD	IoU Nivel Categoría	MAP Nivel Categoría	Frecuencia Relativa en porcentaje
Operatoria	1.00	1.0	0.58
Otorrinolaringología	1.00	1.0	1.45
Endodoncia	1.00	1.0	1.45
Imagenología Oral y Maxilofacial	1.00	1.0	0.58
Nutriólogo Pediátrico	0.95	1.0	1.45
Psiquiatría Adulto	0.90	1.0	1.45
Rehabilitación Oral Prótesis Fija	0.90	1.0	1.45
Nefrología Adulto	0.90	1.0	1.45
Urología Pediátrica	0.90	1.0	1.45
Medicina Física y Rehabilitación Pediátrica	0.90	1.0	1.45

Tabla 4.9: Top 10 especialidades con peor rendimiento.

ESPECIALIDAD	IoU Nivel Categoría	MAP Nivel Categoría	Frecuencia Relativa en porcentaje
Inmunología	0.50	0.67	1.45
Neurología Adulto	0.70	0.64	1.45
Geriatría	0.50	0.6	1.45
Gastroenterología Pediátrica	0.41	0.58	1.45
Cirugía de Tórax	0.53	0.53	1.45
Radioterapia Oncológica	0.30	0.5	1.45
Diabetología	0.38	0.47	1.45
Medicina Familiar del Niño	0.33	0.45	1.45
Hematología	0.38	0.38	1.45
Traumatología y Ortopedia Pediátrica	0.40	0.33	1.45

Tabla 4.10: Resultados en prestaciones oncológicas.

ESPECIALIDAD	IoU Nivel Categoría	MAP Nivel Categoría	Frecuencia Relativa en porcentaje
Hemato-oncología Pediátrica	0.85	0.93	1.45
Oncología Médica	0.52	0.79	1.45
Radioterapia Oncológica	0.30	0.5	1.45

Por otro lado, se analiza el rendimiento del modelo para las especialidades médicas oncológicas, que son prioritarias durante el desarrollo de este trabajo. Estos resultados se resumen en la tabla 4.10. En el caso de estas especialidades, el problema para lograr un match entre la codificación del modelo y la codificación manual de la experta radicaba en las abreviaciones que se utilizan para escribir implícitamente el diagnóstico, tales como “ca”, “tu” y “neo”. El modelo inicialmente no lograba capturar estas abreviaciones, lo cual es fácilmente corregible.

4.3. Limitaciones

El uso del sistema de codificación en el presente estudio permitió incrementar el registro de diagnósticos en CIE-10, además de mejorar la calidad del dato. Sin embargo, es importante señalar que los modelos de codificación automática de enfermedades también pueden tener limitaciones. Una de ellas es su dependencia respecto de la calidad de los datos de entrada. Si los datos de entrenamiento son incompletos, inconsistentes o sesgados, el modelo de codificación automática puede no ser capaz de aprender correctamente y producir resultados inexactos. Además, los modelos de codificación automática de enfermedades pueden tener dificultades para identificar enfermedades poco frecuentes o complejas que no se encuentran en los datos de entrenamiento. A modo de ejemplo se presenta la tabla 4.11 en la cual se presentan diagnósticos reales los cuales el modelo tiene errores, esto dado ya que los datos de entrada son inespecíficos (primeras tres filas) o están mal escritos (ultima fila).

Tabla 4.11: Ejemplo de problemas del modelo con respecto a los datos de entrada.

Texto Libre	Código real	Código modelo
MACROADENOMA	-	D352
NODULO PANCREAS	-	D377
REFRACCION	-	-
GANGLINN - DIAGNNSTICO PRINCIPAL	M674	-

Una segunda limitación radica en que los modelos de codificación automática de enfermedades pueden no ser capaces de capturar toda la complejidad del diagnóstico humano. En algunos casos, la información necesaria para realizar una codificación precisa puede ser sutil o subjetiva, y puede ser difícil para un modelo de codificación automática identificar esta información. A modo de ejemplo se tienen los casos presentados en la tabla 4.12, donde el problema radica es que se puede codificar pero con conocimiento médico, lo cual el modelo no puede capturar.

Tabla 4.12: Ejemplo de problemas del modelo con respecto que falta criterio médico.

Texto libre	Código real	Código modelo
HIPERACTIVIDAD	R463/F901	R463
HERNIA NUCLEO PULPOSO LUMBAR	M518	M511
TRASTORNO ALIMENTARIO ANOREXIA	F500	F509

Es importante tener en cuenta estas limitaciones al utilizar un modelo de codificación automática de enfermedades en el análisis estadístico de datos históricos. Si bien estos modelos pueden ser útiles en muchos escenarios, no deben utilizarse como una solución única y completa para el análisis de datos de salud. En su lugar, deben ser considerados como una herramienta complementaria para mejorar la eficiencia y precisión del análisis.

4.4. Despliegue

Con respecto al despliegue y la utilización de este sistema de codificación automática, se desarrollo una base de datos para que guarde la codificación de enfermedades presentes en las interconsultas, esta corresponde a una tabla llamada **menciones** y que está alojada en la base de datos **CMM** en el *datawarehouse* del DEIS.

menciones	
123	SIGTE_ID
123	mention_index
ABC	mention
ABC	code

Figura 4.1: Tabla con las codificaciones a nivel de entidades por cada interconsulta.

Como se muestra en la figura 4.1, esta tabla utiliza como llave primaria el **SIGTE_ID** y el **mention_index**. El primer atributo corresponde a la identificación de la interconsulta con SIGTE, mientras que el segundo indica el orden de la entidad encontrada en esa interconsulta por el modelo de reconocimiento de entidades. El atributo **mention** corresponde a la mención encontrada y el atributo **code** corresponde al código CIE-10 asignado a esa entidad. Para generar esta tabla, se utilizó un *workflow* disponible en el programa KNIME, que se representa en la siguiente figura:

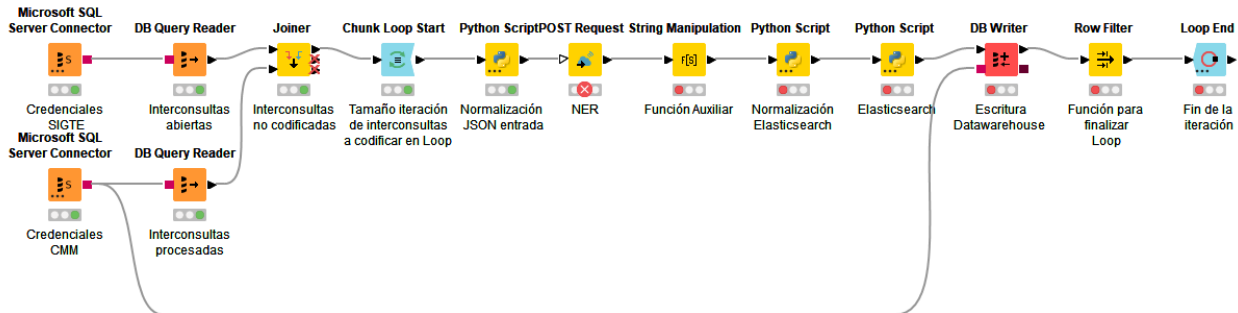


Figura 4.2: *workflow* de codificación de lista de espera

Este *workflow* contiene 9 nodos, los que se detallaran a continuación:

1. Credenciales SIGTE: conexión SQL Server con la base de datos de SIGTE.
2. Interconsultas abiertas: tabla creada a través de una query en SIGTE para extraer los casos abiertos de lista de espera.
3. Credenciales CMM: conexión con la cuenta disponible para la escritura en la base de datos CMM.
4. Interconsultas procesadas: tabla creada a través de una query en CMM para extraer los casos ya codificados.
5. Interconsultas no codificadas: tabla creada con un left antijoin de las interconsultas abiertas y las interconsultas ya codificadas para que se codifiquen las interconsultas nuevas.
6. Tamaño iteración de interconsultas a codificar en Loop: tamaño del bloque a codificar, se consideran 100 interconsultas por default.
7. Normalización JSON entrada: tabla con el preprocesamiento de los campos de texto libre en formato json.
8. NER: tabla creada con consulta POST al servicio web disponible en el DEIS, donde está alojado el modelo de reconocimiento de enfermedades.
9. Función Auxiliar: tabla creada aplicando una función auxiliar para el procesamiento de las entidades encontradas.

10. Normalización Elasticsearch: tabla creada con el preprocesamiento para normalizar la entrada para el programa ElasticSearch.
11. Elasticsearch: tabla creada con una consulta GET para la codificación de las entidades, alojado en el servicio web en el DEIS.
12. Escritura Datawarehouse: proceso de UPDATE a la tabla menciones disponible en la base de datos CMM.
13. Función para finalizar Loop: nodo auxiliar necesario para que se ejecute el final del nodo de Loop.
14. Fin de la iteración: Final del bloque de interconsultas a codificar e inicia el siguiente bloque de interconsultas.

La idea principal de este flujo de trabajo es permitir la codificación masiva de nuevos casos de Lista de Espera, así como de nuevas interconsultas que puedan surgir. Además, cualquier archivo que contenga la estructura presente en la lista de espera puede ser codificado utilizando este flujo de trabajo.

Es importante destacar que la lista de espera se generan datos y se generan cortes mensuales con los que trabajan los equipos del MINSAL. Para los cortes mensuales de la lista de espera, si los datos no están disponibles en la base de datos de SIGTE, se puede considerar una base de datos de Excel. Estos datos pueden ser ingresados mediante un nodo de lectura de Excel o CSV disponible en KNIME, reemplazando los nodos de SIGTE y QUERY SIGTE. Para ello, es necesario asegurarse de que los campos de texto libre contengan los mismos nombres, aunque también pueden ser modificados en el archivo original de KNIME.

Capítulo 5

Aplicaciones

5.1. Propuestas de aplicaciones en cáncer

En este capítulo se presentan los beneficios de la codificación automática de diagnósticos mediante propuestas de aplicaciones, lo que permite el análisis estadístico de datos históricos no etiquetados. Con el objetivo de generar nuevos estudios en el área de la salud pública, se propone un análisis estadístico relacionado con el cáncer en la lista de espera histórica de Chile. Para esto se describirá la relevancia de la enfermedad a nivel mundial y en el país. Luego, se detallarán los datos que se utilizarán para el análisis y, por último, se presentarán las propuestas para el análisis estadísticos.

Es importante destacar que el cáncer es una enfermedad de gran impacto a nivel mundial, y su estudio es crucial para la prevención, diagnóstico y tratamiento efectivo. Por lo tanto, se justifica la necesidad de analizar los datos de una lista de espera histórica relacionados con esta enfermedad en particular. El análisis estadístico de una lista de espera histórica relacionada con el cáncer puede proporcionar información valiosa para mejorar la atención médica y la toma de decisiones. Es importante considerar la relevancia de la enfermedad, los datos a utilizar y las técnicas estadísticas apropiadas para obtener resultados precisos y útiles.

5.1.1. Cáncer en el mundo y en Chile

A nivel mundial, el cáncer es una de las principales causas de mortalidad. Según la Organización Mundial de la Salud (OMS), el cáncer es la segunda causa principal de muerte en todo el mundo, después de las enfermedades cardiovasculares. En el año 2020, el Centro Internacional de Investigaciones sobre el Cáncer (IARC, por sus siglas en inglés) publicó el Globocan 2020 [51]. En este documento se precisa un aumento de 19,3 millones de casos nuevos de cáncer y 10 millones de muertes a causa de esta enfermedad. A partir de las tasas de crecimientos, los cambios en el estilo de vida y el envejecimiento de la población se proyecta que habrá un incremento del 60 % de nuevos casos, llegando a 22,2 millones de casos para el año 2030 [52].

El cáncer en Chile también es una causa importante de mortalidad. Según el Ministerio de Salud de Chile, el cáncer es la segunda causa principal de muerte en el país, después de las enfermedades cardiovasculares. En específico, el Globocan 2020 declara que en Chile se registraron 54.227 casos nuevos de cáncer y 28.584 muertes a causa de esta enfermedad en el

año 2020 [53].

En Chile existen varias iniciativas para la detección temprana y prevención del cáncer, como el Programa Nacional de Cáncer de Mama, Cáncer de Próstata, Cáncer de Colon, Cáncer Cervicouterino y campañas de prevención y detección temprana de cáncer de piel. Estas iniciativas son de gran importancia para la salud de la población y pueden ser complementadas con la ayuda de un sistema de codificación automática que pueda identificar patrones en grandes cantidades de datos médicos. Este tipo de sistema puede ayudar a identificar factores de riesgo, prever la aparición de enfermedades y desarrollar nuevos planes de prevención y tratamiento. La combinación de iniciativas de detección temprana y prevención del cáncer junto con tecnologías de análisis de datos puede tener un gran impacto en la salud de la población.

5.1.2. Lista de espera histórica codificada

En la sección 1.1, se mencionó que había un total de 18.716.629 interconsultas de CNE, de las cuales aproximadamente 5.760.750 tenían un código CIE-10. Después de utilizar el sistema de codificación automática, se identificó que alrededor de 14.247.782 interconsultas de CNE se les asignó un código CIE-10.

Con la finalidad de tener una muestra significativa para realizar un estudio estadístico, en la tabla .8 en la sección de Anexos, muestra que en términos generales, la codificación aumentó de un promedio del 26,5 % a un 74,23 % , y de un 1,61 % a un 77,64 % en la mediana por servicio de salud.

De las interconsultas codificadas, 533.453 diagnósticos están asociados al cáncer. Esta distribución de diagnósticos de cáncer codificados de lista de espera queda representado en la figura 5.1.

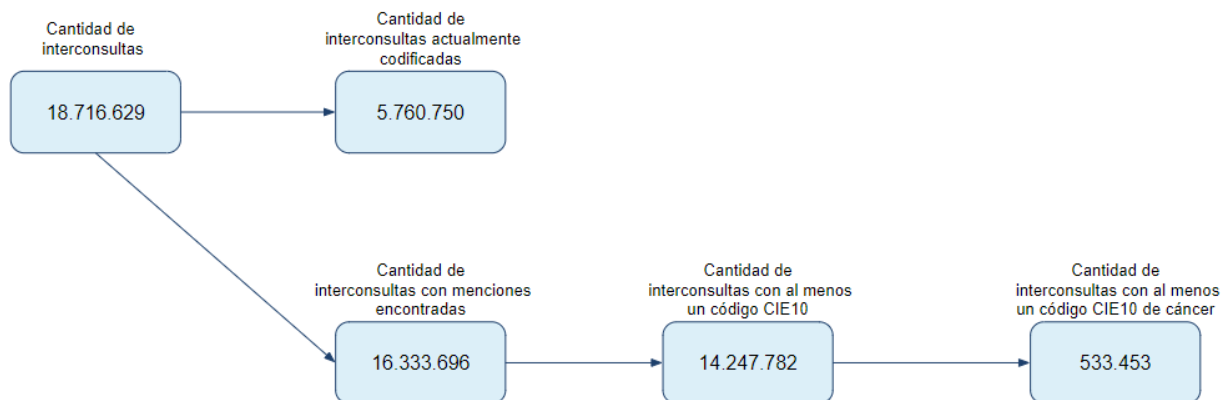


Figura 5.1: Cantidad de diagnósticos codificados automáticamente de la lista histórica CNE.

5.1.3. Propuesta 1: Perfil sociodemográfico de pacientes en Lista de Espera

Una de las ventajas que brinda la codificación automática es la posibilidad de estudiar la presencia de diagnósticos en la población chilena y su evolución a lo largo del tiempo. Para llevar a cabo este análisis, se utilizaron las 14.247.782 interconsultas codificadas centrándose únicamente en aquellos que comienzan con la letra C, lo cual dio como resultado 533.435 interconsultas asociadas a la enfermedad de cáncer. Cabe señalar que las figuras presentadas a continuación no incluyen las interconsultas con causales de salida numeradas como 15, 18 o 99, las cuales se asocian con errores o datos duplicados.

Es importante complementar este análisis con otros aspectos. Por ejemplo, se puede estudiar la edad, el género y la ubicación geográfica de los pacientes afectados por cáncer para identificar patrones y tendencias en su incidencia. Este tipo de análisis puede proporcionar información valiosa para el diseño e implementación de políticas públicas enfocadas en la prevención y tratamiento del cáncer. Por ejemplo, si se descubre que una región específica del país tiene una mayor prevalencia de cáncer de pulmón, se pueden establecer medidas de prevención específicas para esa zona, como campañas de concientización sobre el tabaquismo y programas de detección temprana de la enfermedad. Además, este enfoque de análisis también puede ser útil para evaluar la efectividad de las políticas y programas actuales. Por ejemplo, si se implementa una política de prevención del cáncer de cuello uterino, se pueden analizar los datos para evaluar su impacto y promover ajustes en consecuencia.

A continuación, se presenta un ejemplo aplicado de las posibilidades mencionadas anteriormente. En este caso, se analizará la evolución de los grupos de códigos de cáncer más frecuentes entre los años 2016 a 2021, los cuales quedan representados en la siguiente figura.




Figura 5.2: Evolución de los 10 grupos de códigos más frecuentes asociados a cáncer en lista de espera CNE entre los años 2016-2021.

La figura 5.2 muestra que el grupo de códigos C15-C26, relacionado con el cáncer en los órganos digestivos, ha sido el más común en los casos de cáncer en Chile durante los últimos años, incluyendo los dos años de pandemia representados en violeta. Este grupo de códigos engloba distintos tipos de cáncer en el esófago, estómago, intestino delgado, colon, recto, hígado y vías biliares. Aunque las causas precisas de su mayor incidencia aún no se comprenden del todo, se cree que puede estar relacionada con factores como la dieta, el consumo de alcohol y tabaco, la exposición a contaminantes ambientales y factores genéticos. Medir

cuantitativamente la presencia de este grupo de códigos y otros a través de la codificación automática, permite una evaluación objetiva de la prevalencia de diferentes tipos de cáncer en Chile. Esto puede ser muy útil para los profesionales de la salud en la planificación de estrategias de prevención y tratamiento más efectivas.

A partir de lo mencionado anteriormente, se realizará un análisis del perfil sociodemográfico del grupo C15-C26, asociado al cáncer digestivo en Chile, con el fin de obtener información valiosa sobre los factores de riesgo implicados.

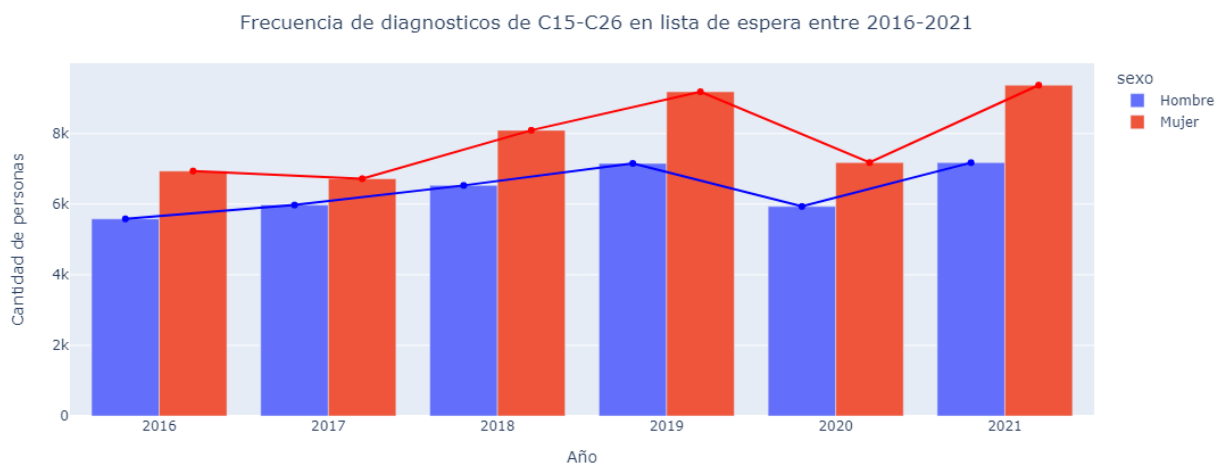


Figura 5.3: Frecuencia de C15-C26 en lista de espera CNE por sexo entre los años 2016-2021.

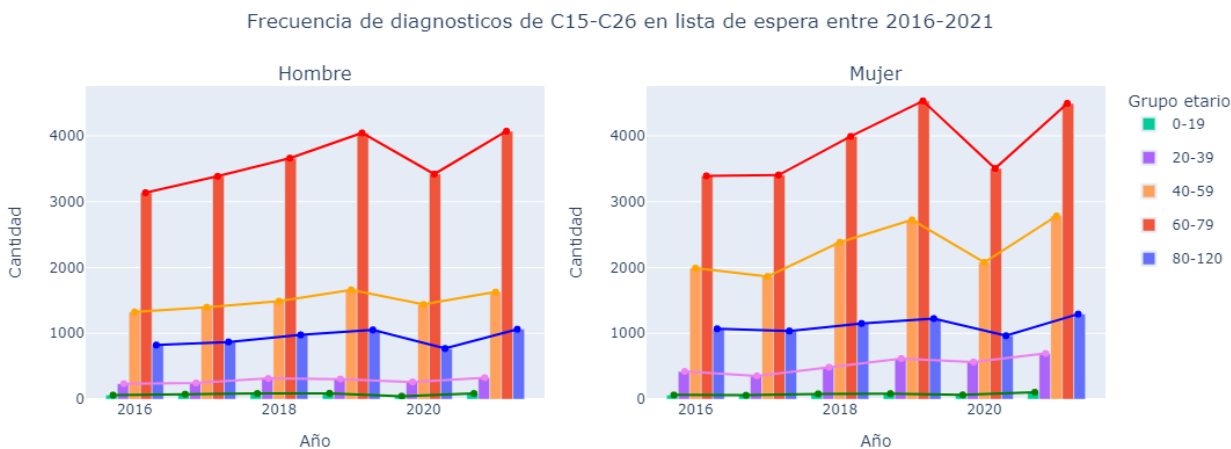


Figura 5.4: Frecuencia de C15-C26 en lista de espera CNE por sexo y grupo etario entre los años 2016-2021.

Como se puede observar en la tabla 5.3 y la tabla 5.4, durante los años 2016-2021 se ha registrado una mayor cantidad de diagnósticos de cáncer C15-C26 en mujeres en lista de espera no-GES en comparación con los hombres. Aunque estos tipos de cáncer son más comunes en

hombres que en mujeres [54], se ha observado que en los últimos años, las mujeres están siendo diagnosticadas con mayor frecuencia en comparación con años anteriores, especialmente para los grupos etarios entre 40 a 59 años y 60 a 79 años. Este fenómeno puede deberse a varios factores, como una mayor conciencia y detección temprana de los síntomas, cambios en los hábitos alimenticios y de estilo de vida, así como posibles factores ambientales y genéticos.

Es importante destacar que la mayoría de los diagnósticos en el grupo C15-C26 están cubiertos por el GES. Por lo tanto, estos datos no deberían figurar en la lista de espera que no-GES, ya que la inclusión de estas patologías en el GES se realizó en el año 2006 para cáncer gástricos y en 2013 para cáncer colorrectal. Esto podría indicar un problema en la gestión de la lista de espera.




Figura 5.5: Tasa de presencia de C15-C26 cada 100.000 habitantes por región para el año 2016, 2018 y 2020

Es necesario recalcar la ubicación geográfica de los diagnósticos mencionados anteriormente, lo cual se representa en la figura 5.5, que muestra la prevalencia de pacientes con diagnósticos del grupo C15-C26 en una tasa de 100.000 habitantes, solo en la lista de espera no-GES. A partir de esta información, se puede observar que la prevalencia de estas enfermedades ha sido baja en las regiones de Tarapacá, Magallanes y Antártica, así como en la región de Antofagasta para los años 2016, 2018 y 2020. Estas cifras permite entender la cantidad de pacientes que deben ser atendidos por los servicios de salud en cada región y ayuda a planificar y desarrollar estrategias de prevención y tratamiento específicas para las regiones con mayor prevalencia.

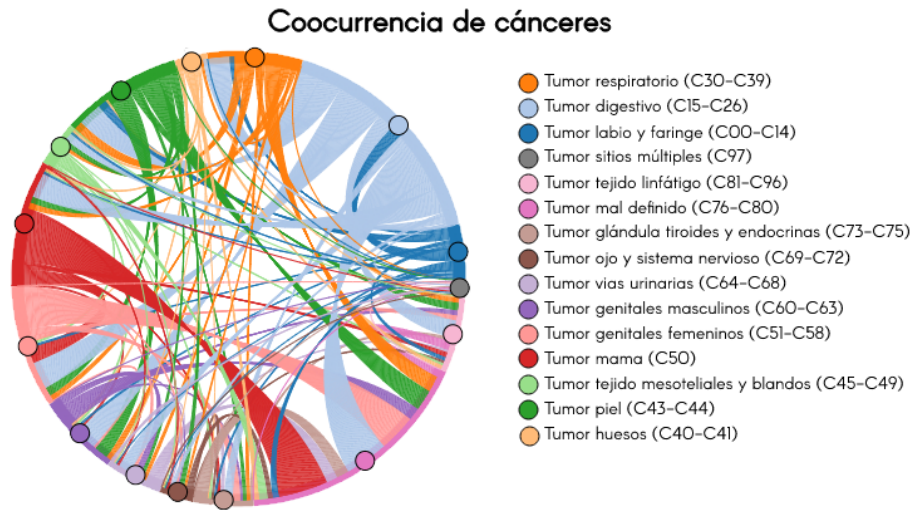


Figura 5.6: Co-ocurrencia de diagnósticos de cáncer en pacientes de lista de espera entre los años 2016-2021.

Por último, en la figura 5.6 se presenta un ejemplo de estudio de co-ocurrencia de diagnósticos de cáncer en la lista de espera, a través de una matriz que proporciona información valiosa sobre cómo las enfermedades se relacionan entre sí. Es común que los pacientes presenten simultáneamente más de una enfermedad y la identificación de las relaciones entre ellas permite comprender mejor los procesos subyacentes que contribuyen a su desarrollo y progresión. De esta manera, los profesionales de la salud pueden obtener información más completa sobre la salud general del paciente y diseñar planes de tratamiento más efectivos y adaptados a las necesidades individuales.

En la figura 5.6 se muestra que el cáncer de órganos digestivos (C15-C26) presenta una alta co-ocurrencia con otros tipos de cáncer, como los mal identificados (C76-C80) y los de órganos genitales femeninos (C51-C58) y masculinos (C60-C63). Esta información es relevante para la detección temprana y el tratamiento adecuado del cáncer, ya que la presencia de un tipo de cáncer puede ser una señal de alerta para otros tipos relacionados. Por ejemplo, un paciente con cáncer de colon (C18-C20) puede necesitar una evaluación adicional para detectar la presencia de cáncer de recto (C19-C20) u otros órganos digestivos (C15-C17, C21-C26).

El conocimiento de la co-ocurrencia de diferentes tipos de cáncer también es importante para diseñar estrategias de prevención y tratamiento. Los pacientes con cáncer de órganos digestivos pueden requerir una vigilancia más frecuente y cuidadosa para detectar la aparición de otros tipos de cáncer relacionados. Además, el desarrollo de terapias dirigidas que aborden múltiples tipos de cáncer co-ocurrentes puede mejorar significativamente la eficacia del tratamiento y la calidad de vida de los pacientes.

5.1.4. Propuesta 2: Gestión del sistema de salud en Lista de Espera

La lista de espera es una de las mayores preocupaciones para los sistemas de salud en todo el mundo debido a que compromete largos tiempos para los pacientes deben acatar para

recibir atención médica. En Chile, la lista de espera no-GES se compone de pacientes que no cumplen con los requisitos para ser considerados GES, que son un conjunto de prestaciones garantizadas por el Estado para enfermedades específicas, pero que igualmente necesitan atención médica.

Los tiempos de espera pueden variar según la especialidad médica, la región geográfica y la complejidad de la atención requerida. En la actualidad, los tiempos de espera que se reportan de manera oficial en la Cuenta Pública del MINSAL [55] o el informe de Glosa 06 del MINSAL [56] solo se pueden desagregar por la prestación otorgada, el establecimiento, entre otras variables sociodemográficas, pero ninguna de estas es a nivel de patología médica, lo cual puede no ser relevante para la toma de decisiones en la gestión pública.

Sin embargo, lo que es común en todos los casos es que una lista de espera no gestionada adecuadamente puede generar una serie de efectos negativos en los pacientes, como el deterioro de su estado de salud física y psicológica, además de una evidente disminución de su calidad de vida y, en casos extremos, el fallecimiento. Por lo tanto, es fundamental que los sistemas de salud se enfoquen en la gestión de la lista de espera no-GES para garantizar que las personas reciban la atención que necesitan en el menor tiempo posible. Para lograr esto, es importante realizar análisis periódicos de los tiempos de espera y las causas de los retrasos, a través de la identificación de los pacientes, las patologías presentes y la revisión de los procesos. De esta manera, se pueden tomar medidas correctivas que permitan mejorar la eficiencia del sistema y garantizar la calidad de atención.

Con esta motivación, se presentan dos propuestas de estudios estadísticos para el análisis de la gestión del sistema de salud. A modo de ejemplo, se seleccionó el grupo de códigos CIE-10 asociado al cáncer digestivo (C15-C26), utilizados en los ejemplos anteriores. Se presenta en la figura 5.7 la mediana de los tiempos de espera de la lista de espera separados por región.




Figura 5.7: Distribución de la mediana de los tiempos de espera para diagnósticos C15-C26 por región para el año 2016, 2018 y 2020. Se excluye la región de Tarapacá.

En la figura 5.7, se omitió la presencia de la región de Tarapacá, ya que su prevalencia es baja, como se observa en la tabla 5.5. Por lo tanto, no es representativa y genera ruido en la observación de los tiempos de espera. Como se puede apreciar, a nivel regional, la mediana de los tiempos de espera no sobrepasan los 50 días de espera o los superan levemente para

los años estudiados. Sin embargo, hay casos destacados, como el de la región de Atacama, donde se observa una prevalencia al alza para los años 2016, 2018 y 2020, pero sus tiempos de espera están disminuyendo, lo que podría ser evidencia de inversión en la zona para la atención de estos pacientes, nuevos centros médicos, entre otros. Por otro lado, la región de Aysén tiene una prevalencia a la baja y, para el año 2020, se observó un aumento importante en los tiempos de espera, con una media por encima de los 100 días, lo cual podría explicarse por los efectos de la pandemia del Covid-19.

Otra forma de medir la gestión del sistema de salud sería a través de la creación de un nuevo indicador que corresponda al tiempo de espera de un paciente por episodio médico asociado a una patología específica. La creación de este indicador responde a que en el proceso de gestión de listas de espera, los tiempos se miden de manera individual según la norma N°118 [37]. Esta medición individual puede generar algunas limitaciones en la gestión de la atención médica del paciente, ya que no permite tener una visión completa de todo el proceso de atención desde que se ingresó en la lista de espera para tratar una patología específica. Por lo tanto, es necesario contar con herramientas que permitan conocer desde cuándo el paciente está esperando su tratamiento y qué especialidades, procedimientos o cirugías se han realizado en relación con la patología en cuestión.

En este sentido, contar con un identificador de episodio puede ser de gran utilidad para mejorar la gestión de listas de espera. Con esta herramienta, se puede tener una visión global de todo el proceso de atención médica del paciente, desde que se ingresó en la lista de espera hasta la finalización del tratamiento. Esto permite una gestión más eficiente de los recursos y una atención médica más coordinada y efectiva. Además, el identificador de episodio también puede ser útil para el seguimiento y documentación del tratamiento médico a lo largo del tiempo, lo que puede mejorar la calidad de la atención médica y los resultados para el paciente.

A modo de ejemplo, se presenta la tabla 5.1, que representa un registro fidedigno de SIGTE para un paciente. Esta tabla contiene información sobre sospechas y confirmaciones de diagnósticos, códigos CIE-10 asociados a cada diagnóstico asignados por el sistema de codificación, tipo de atención médica (como CNE, IQ o procedimientos), fechas de ingreso y salida, y procedimientos médicos. En este caso, se registraron seis eventos médicos, incluyendo diagnósticos en texto libre de coleditiasis, hernia umbilical, nódulos pulmonares, cáncer de pulmón y cáncer bronquial.

Tabla 5.1: Ejemplo de registro SIGTE.

Evento	Sospecha y Confirmación Diagnostica	Código Modelo	Tipo de Prestación	Fecha de Entrada	Fecha de Salida	Prestación
1	COLELITIASIS	K809	CNE	17-5-2015	14-9-2016	CIRUGÍA GENERAL
2	HERNIA UMBILICAL	K429	IQ	25-5-2015	14-3-2017	CIRUGÍA DIGESTIVA
3	NODULO PULMONAR DERECHO	R918	CNE	7-7-2018	10-7-2018	CIRUGÍA DE TÓRAX
4	CA PULMON	C34	CNE	18-8-2018	22-11-2018	HEMATOLOGÍA
5	CANCER DE BRONQUIOS	C34	Proc	27-11-2018	19-2-2019	PROCEDIM.CARDIOLOGIA, NEUMOLOG., CARDIOVASC. Y TORAX
6	C34 TUMOR MALIGNO DE LOS BRONQUIOS Y DEL PULMON	C34	Proc	1-2-2019	15-2-2019	GASTROENTEROLOGIA / PROCEDIMIENTOS DIAGNOSTICO Y TERAPEUTICO.

En esta tabla, los eventos médicos 4, 5 y 6 podrían compartir el mismo identificador de episodio médico. Esto significa que los códigos CIE-10 correspondientes a estos eventos están relacionados entre sí. En este ejemplo, el paciente recibió una consulta de especialidad médica

(CNE) en noviembre de 2018 y esperó alrededor de tres meses. Posteriormente, se le realizaron dos procedimientos en febrero de 2019, en los cuales esperó tres meses y dos semanas, respectivamente. Sin embargo, en SIGTE, no se relacionan entre sí. Por lo tanto, el tiempo de espera para realizarse estos procedimientos se podría considerar desde que recibió la primera consulta de especialidad en la que se confirmó el diagnóstico “C34”. Es decir, alrededor de seis meses. Este tiempo puede ser relevante para comprender la estancia del paciente en todo el proceso de lista de espera por su patología.

Dado que esta tarea no es sencilla, en esta tesis se propone la creación de este identificador de episodio a través de los diagnósticos médicos codificados, las prestaciones otorgadas y la opinión de médicos expertos. Esta propuesta se describe mediante el siguiente pseudo código:

```

Input: Rut, CódigoCIE10, ListaEspera, Diags_relacionados, Prest_relacionadas, fecha_corte;
Episodio ← Lista vacía
TablaPaciente ← Inicializar ListaEspera con filtro por Rut, con C_SALIDA=[Null,1,9,16,17,19],
.
CODE=CódigoCIE10 y F_ENTRADA<fecha_corte
for iterar sobre cada fila de TablaPaciente;
| if si la columna CODE esta en Diags_relacionados;
| | if si PRESTA_MIN esta en Prest_relacionadas;
| | | Agregar SIGTE_ID a Episodio
|
end
TablaPaciente_episodio ← filtrar TablaPaciente con SIGTE_ID en Episodio y ordenar por
.
F_INGRESO de manera descendente.
if F_SALIDA es Null;
| Ult_diag ← escoger la fecha de corte
else;
| Ult_diag ← escoger la F_SALIDA de la ultima fila

Primer_diag ← escoger F_INGRESO de la primera fila
Tiempo_total ← contar los días entre las fechas Ult_diag y Primer_diag

return TablaPaciente_episodio, Tiempo_total

```

Figura 5.8: Algoritmo para la creación de episodio en lista de espera no-GES.

Para el correcto funcionamiento del algoritmo mencionado se requieren los siguientes conjuntos de datos : **ListaEspera**, **Diags_relacionados** y **Prest_relacionadas**, los cuales se describen a continuación. El primer conjunto corresponde a los datos presentes en SIGTE y contiene una columna adicional llamada **code**, la cual contiene los diagnósticos codificados por el modelo. El conjunto **Diags_relacionados** está compuesto por diagnósticos que se pueden relacionar entre sí. Por ejemplo, el cáncer de pulmón (C34) puede estar altamente relacionado con el cáncer de hígado (C20) debido a que este último produce una metástasis agresiva que afecta a los pulmones y puede desarrollarse el cáncer. Por lo tanto, el diseño de este conjunto debe ser desarrollado con la colaboración de expertos médicos con conocimiento en patologías altamente correlacionadas que puedan presentarse en los pacientes. Finalmente, el conjunto **Prest_relacionadas** corresponde a las prestaciones MINSAL que se otorgan en el sistema público y que están relacionadas entre sí. Siguiendo una idea similar al conjunto

anterior, se pueden relacionar las prestaciones oncológicas que se otorgan en consultas CNE con las prestaciones oncológicas de procedimientos y cirugías, lo cual este conjunto también tiene que ser desarrollado con médicos expertos.

5.2. Un caso de aplicación: Dashboard DEIS

Una de las principales motivaciones del presente trabajo es que pueda ser utilizado por el DEIS. Además de dar a conocer el trabajo de investigación, es importante poner a prueba el sistema de codificación con un conjunto masivo de datos y generar estadísticas confiables para los datos no estructurados. Esto permitirá demostrar la eficacia del sistema y su capacidad para procesar grandes cantidades de información de manera precisa y eficiente.

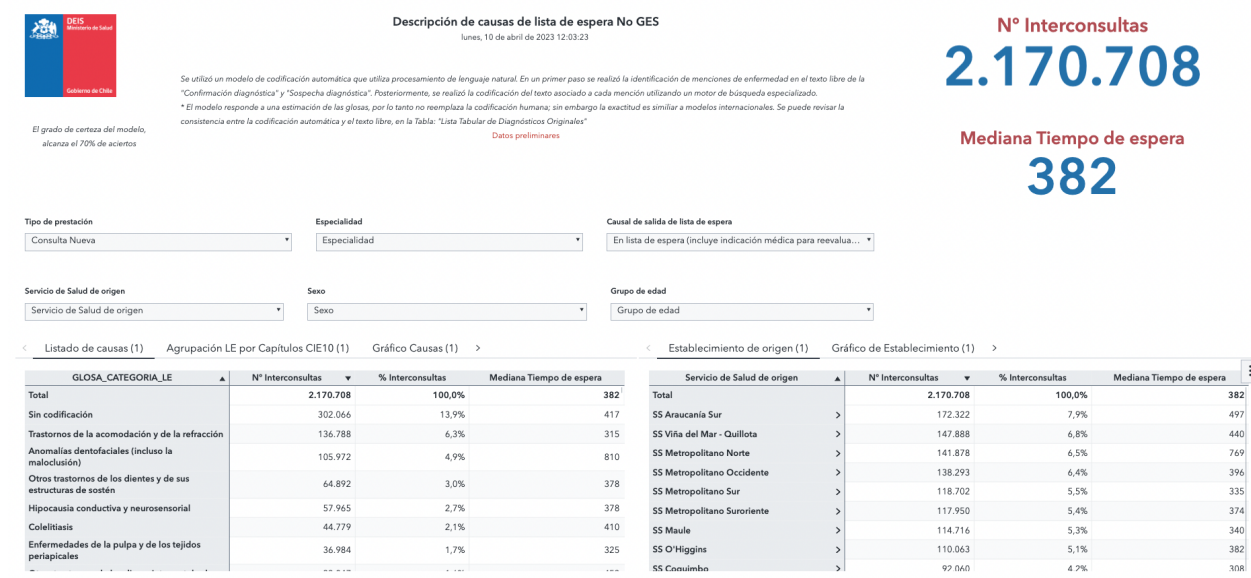


Figura 5.9: Dashboard interactivo desarrollado por DEIS con sistema de codificación automática de diagnósticos.

En la figura 5.9, se puede observar que el sistema de codificación automática de enfermedades se integra en un dashboard interactivo desarrollado por el equipo del DEIS para los datos de lista de espera abierta no-GES⁷. El funcionamiento del dashboard es sencillo: mediante una interfaz intuitiva, los usuarios pueden ingresar los parámetros correspondientes al tipo de prestación, especialidad médica, causal de egreso, servicio de salud, género y grupo etario.

El dashboard da acceso a tres tablas principales. Por un lado se destaca en la figura 5.10 la tabla que representa la cantidad de diagnósticos presentes en la lista de espera y la mediana de los tiempos de espera por cada uno de ellos. Por otro lado se tiene la figura 5.11 que representa la tabla de los diagnósticos reales de los cuales se realizó la codificación

⁷ Estos datos son preliminares y solo se presentan como ejemplo del funcionamiento del sistema de codificación. No deben considerarse como una verdad absoluta, ya que pueden estar sujetos a cambios o actualizaciones.

automática de enfermedades. Esta tabla es relevante porque permite validar el modelo y reportar casos incorrectos para su corrección.

< Listado de causas (1) Agrupación LE por Capítulos CIE10 (1) Gráfico Causas (1) >

GLOSA_CATEGORIA_LE ▲	N° Interconsultas ▼	% Interconsultas	Mediana Tiempo de espera
Total	3.631.837	100,0%	420
Sin codificación	774.852	21,3%	511
Trastornos de la acomodación y de la refracción	141.732	3,9%	319
Tumor maligno de la mama	109.029	3,0%	378
Anomalías dentofaciales (incluso la maloclusión)	108.024	3,0%	804
Colelitiasis	84.297	2,3%	442
Otros trastornos de los dientes y de sus estructuras de sostén	66.944	1,8%	386
Diabetes mellitus insulino dependiente	61.829	1,7%	410

Figura 5.10: Tabla dinámica de diagnósticos codificados.

Lista tabular de Diagnósticos originales

Glosa de Interconsultia (Sospecha diagnóstica y/o Confirmación diagnóstica)	N° Interconsultas ▼	% Interconsultas
Examen de pesquisa especial para tumor de la mama	41.728	10,7%
SIN ESPECIFICAR	31.934	8,2%
COLELITIASIS	23.502	6,0%
Diabetes mellitus no insulino dependiente	17.085	4,4%
EVALUACION POR ESPECIALISTA	14.927	3,8%
EXAMEN DE PESQUISA ESPECIAL PARA TUMOR DE LA MAMA	14.895	3,8%
VICIO REFRACCION	14.787	3,8%
Colelitiasis	14.600	3,7%
Z12.3 EXAMEN DE PESQUISA ESPECIAL PARA TUMOR DE LA MAMA	13.508	3,5%
Trastorno de la refracción, no especificado	13.411	3,4%

Figura 5.11: Tabla de diagnósticos reales.

Capítulo 6

Conclusiones, trabajo futuro y contribuciones

6.1. Conclusiones

En esta tesis, se propuso la implementación y propuesta de aplicaciones para un sistema de codificación automática de enfermedades para la lista de espera chilena. En concreto, se revisó el enfoque basado en un modelo de dos pasos para la codificación automática. Se comparó el rendimiento de este sistema mediante tres conjuntos de datos de lista de espera chilena con diferentes enfoques, y se obtuvieron resultados satisfactorios en los experimentos realizados. Esto abre la puerta a una posible implementación de un sistema de codificación automática que contribuye a la normalización y gestión de los datos no estructurados, lo que a su vez permite la generación de nuevas aplicaciones para la investigación.

La tarea de la codificación automática de enfermedades utiliza, en un primer módulo, un modelo de NER para el reconocimiento de las entidades correspondientes a enfermedades, y un segundo módulo correspondiente a un motor de búsqueda. Esta estructura nos permite realizar procesos de mejora continua para este sistema desde dos frentes. El primero es el NER para agregar nuevas entidades no vistas todavía, mientras que el segundo frente es el motor de búsqueda, donde se permiten agregar nuevas fuentes de información para simular el aprendizaje que tiene un experto en codificación clínica.

Los resultados obtenidos sugieren que el modelo de dos pasos implementado se adapta de manera satisfactoria a la tarea de codificación de enfermedades, ya que está cercano a los resultados presentes en la literatura actual para esta tarea, con la excepción de que este modelo no se pudo comparar con los datasets públicos destinados a la tarea de codificación automática, ya que el modelo se ajustó a la realidad chilena y su contexto.

La implementación exitosa del sistema de codificación automática de enfermedades mejoró la eficiencia y precisión del proceso de codificación, permitiendo desarrollar estudios más precisos sobre las enfermedades y sus tiempos de atención. La capacidad del sistema para procesar grandes cantidades de datos y su integración con un dashboard interactivo permite a los investigadores realizar aplicaciones y análisis más detallados para mejorar la gestión del sistema de salud.

6.2. Trabajo futuro

Después de la implementación y evaluación del modelo de dos pasos para la codificación automática de enfermedades en la lista de espera chilena, se identifican varias oportunidades para mejorar y expandir el sistema. A continuación, se presentan algunos trabajos futuros que pueden ser explorados:

- **Integración de múltiples fuentes de información:** El sistema de codificación automática actual utiliza un motor de búsqueda para encontrar la información relevante en múltiples fuentes de información. Una posible mejora sería integrar aún más fuentes de información, como notas clínicas, historias médicas, versiones actualizadas de los volúmenes de codificación de la OMS y otros registros, con el objetivo de aumentar la precisión y la exhaustividad del sistema.
- **Adaptación del modelo a otras listas de espera:** El modelo de dos pasos implementado en la lista de espera chilena tiene el potencial de ser adaptado a otras listas de espera en diferentes países o regiones. No obstante, es importante llevar a cabo un proceso de adaptación y validación para asegurar que el modelo sea aplicable a otros contextos y listas de espera.
- **Adaptación del modelo a otros tipos de codificaciones:** La implementación realizada está enfocada únicamente en enfermedades, pero es posible extender el modelo utilizado para el reconocimiento de entidades a la identificación de procedimientos, hallazgos médicos, partes del cuerpo, entre otros. Esto podría complementar la codificación y permitir su uso en otras normalizaciones médicas, como C09-CM para la codificación de procedimientos, *Logical Observation Identifiers Names and Codes* (LOINC) para clasificar muestras de laboratorio, SNOMED, CIE-O para la codificación de enfermedades oncológicas, o adaptarlo a CIE-11 [57], que entró en vigor en el año 2022.
- **Mejora del modelo de reconocimiento de entidades:** El modelo de reconocimiento de entidades utilizado en el primer paso del modelo de dos pasos puede ser mejorado mediante la incorporación de técnicas de aprendizaje por refuerzo y la expansión del corpus de entrenamiento.

6.3. Contribuciones

Además de esta tesis, se ha contribuido en un artículo en proceso de publicación.

- Automatic Coding at Scale: Design and Deployment of a Nationwide System for Normalizing Referrals in the Chilean Public Healthcare System (en proceso de publicación).

Bibliografía

- [1] Sachdeva, S. y Bhalla, S., “Semantic interoperability in standardized electronic health record databases,” *Journal of Data and Information Quality (JDIQ)*, vol. 3, no. 1, pp. 1–37, 2012.
- [2] Benson, T., Grieve, G., Benson, T., y Grieve, G., “Why interoperability is hard,” *Principles of Health Interoperability: FHIR, HL7 and SNOMED CT*, pp. 21–40, 2021.
- [3] Jurafsky, D. y Martin, J. H., *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition*. Prentice Hall, 2nd ed., 2008.
- [4] Hughes, M., Li, I., Kotoulas, S., y Suzumura, T., “Medical text classification using convolutional neural networks,” en *Informatics for Health: Connected Citizen-Led Wellness and Population Health*, pp. 246–250, IOS Press, 2017.
- [5] Wang, Y., Wang, L., Rastegar-Mojarad, M., Moon, S., Shen, F., Afzal, N., Liu, S., Zeng, Y., Mehrabi, S., Sohn, S., *et al.*, “Clinical information extraction applications: a literature review,” *Journal of biomedical informatics*, vol. 77, pp. 34–49, 2018.
- [6] Mullenbach, J., Wiegrefe, S., Duke, J., Sun, J., y Eisenstein, J., “Explainable prediction of medical codes from clinical text,” *arXiv preprint arXiv:1802.05695*, 2018.
- [7] Liu, Z., Tang, B., Wang, X., y Chen, Q., “De-identification of clinical notes via recurrent neural network and conditional random field,” *Journal of biomedical informatics*, vol. 75, pp. S34–S42, 2017.
- [8] Dong, H., Falis, M., Whiteley, W., Alex, B., Matterson, J., Ji, S., Chen, J., y Wu, H., “Automated clinical coding: what, why, and where we are?,” *NPJ digital medicine*, vol. 5, no. 1, p. 159, 2022.
- [9] “International Classification of Diseases (ICD),” 2022, <https://www.who.int/standards/classifications/classification-of-diseases>. Accedido: Nov. 15, 2022.
- [10] Chile. Ministerio de Salud, “Manual Proceso de Registro de Lista de Espera no GES,” 2015.
- [11] “Cómo funciona el sistema de salud en Chile,” 2023, http://www.supersalud.gob.cl/difusion/665/w3-article-17328.html#accordion_0. Accedido: Ene. 5, 2023.
- [12] Gattini, C., “Estructura organizacional del snss - observatorio chileno de salud pública,” <https://www.ochisap.cl/estructura-organizacional-del-snss>. Accedido: Ene. 8, 2023.
- [13] “Ministerio de salud,” 2023, <https://www.minsal.cl/>. Accedido: Feb. 18, 2023.
- [14] Báez, P., Arancibia, A. P., Chaparro, M. I., Bucarey, T., Núñez, F., y Dunstan, J., “Procesamiento de lenguaje natural para texto clínico en español: el caso de las listas de

- espera en chile,” *Revista Médica Clínica Las Condes*, vol. 33, no. 6, pp. 576–582, 2022.
- [15] Russell, S. J. y Norvig, P., *Artificial Intelligence: A Modern Approach*. Pearson, 2010.
- [16] Hastie, T. y Tibshirani, R., *Statistical Learning with Sparsity: The Lasso and Generalizations*. CRC Press, 2017.
- [17] Alpaydin, E., *Introduction to machine learning*. Cambridge, MA: MIT Press, 2010.
- [18] Brynjolfsson, E. y McAfee, A., “The business of artificial intelligence,” *Harvard Business Review*, vol. 95, no. 1, pp. 53–62, 2017.
- [19] Floridi, L., Cowls, J., Beltrametti, M., Chatila, R., Chazerand, P., Dignum, V., Luetge, C., Madelin, R., Pagallo, U., Rossi, F., *et al.*, “Ai4people—an ethical framework for a good ai society: opportunities, risks, principles, and recommendations,” *Minds and machines*, vol. 28, pp. 689–707, 2018.
- [20] Dönmez, P., “Introduction to machine learning, by ethem alpaydin. cambridge, ma: The mit press 2010. isbn: 978-0-262-01243-0. \$54/£ 39.95+ 584 pages.” *Natural Language Engineering*, vol. 19, no. 2, pp. 285–288, 2013.
- [21] Domingos, P., “A few useful things to know about machine learning,” *Communications of the ACM*, vol. 55, no. 10, pp. 78–87, 2012.
- [22] Jordan, M. I. y Mitchell, T. M., “Machine learning: Trends, perspectives, and prospects,” *Science*, vol. 349, no. 6245, pp. 255–260, 2015.
- [23] Goodfellow, I., Bengio, Y., y Courville, A., *Deep learning*. MIT press, 2016.
- [24] Bengio, Y., Courville, A., y Vincent, P., “Representation learning: A review and new perspectives,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 8, pp. 1798–1828, 2013.
- [25] LeCun, Y., Bengio, Y., y Hinton, G., “Deep learning,” *nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [26] Huang, Z., Xu, W., y Yu, K., “Bidirectional lstm-crf models for sequence tagging,” en *Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2015.
- [27] Cornolti, M., Ferragina, P., y Ciaramita, M., “A framework for benchmarking entity-annotation systems,” en *Proceedings of the 22nd international conference on World Wide Web*, pp. 249–260, 2013.
- [28] Hoffart, J., Yosef, M. A., Bordino, I., Fürstenau, H., Pinkal, M., Spaniol, M., Taneva, B., Thater, S., y Weikum, G., “Robust disambiguation of named entities in text,” en *Proceedings of the 2011 conference on empirical methods in natural language processing*, pp. 782–792, 2011.
- [29] Stanfill, M. H., Williams, M., Fenton, S. H., Jenders, R. A., y Hersh, W. R., “A systematic literature review of automated clinical coding and classification systems,” *Journal of the American Medical Informatics Association*, vol. 17, no. 6, pp. 646–651, 2010.
- [30] Teng, F., Liu, Y., Li, T., Zhang, Y., Li, S., y Zhao, Y., “A review on deep neural networks for icd coding,” *IEEE Transactions on Knowledge and Data Engineering*, 2022.
- [31] Farkas, R. y Szarvas, G., “Automatic construction of rule-based icd-9-cm coding systems,” en *BMC bioinformatics*, vol. 9, pp. 1–9, Springer, 2008.

- [32] Zhou, L., Cheng, C., Ou, D., y Huang, H., “Construction of a semi-automatic icd-10 coding system,” *BMC medical informatics and decision making*, vol. 20, pp. 1–12, 2020.
- [33] Kaur, R., Ginige, J., y Obst, O., “A systematic literature review of automated icd coding and classification systems using discharge summaries,” 2021.
- [34] Karimi, S., Dai, X., Hassanzadeh, H., y Nguyen, A., “Automatic diagnosis coding of radiology reports: a comparison of deep learning and conventional classification methods,” en *BioNLP 2017*, pp. 328–332, 2017.
- [35] Kraljevic, Z., Searle, T., Shek, A., Roguski, L., Noor, K., Bean, D., Mascio, A., Zhu, L., Folarin, A. A., Roberts, A., *et al.*, “Multi-domain clinical natural language processing with medcat: the medical concept annotation toolkit,” *Artificial intelligence in medicine*, vol. 117, p. 102083, 2021.
- [36] Wiegrefe, S., Choi, E., Yan, S., Sun, J., y Eisenstein, J., “Clinical concept extraction for document-level coding,” *arXiv preprint arXiv:1906.03380*, 2019.
- [37] Cordero, A., Valderrama, S., Duran, L., Santelices, P., Olave, M., Jiron, P., y Fuentes, L., “Norma técnica para el registro de las listas de espera,” 2016.
- [38] Rojas, M., Bravo-Marquez, F., y Dunstan, J., “Simple yet powerful: An overlooked architecture for nested named entity recognition,” en *Proceedings of the 29th International Conference on Computational Linguistics*, pp. 2108–2117, 2022.
- [39] Rojas, M., Barros, J., Araneda, M., y Dunstan, J., “Flert-matcher: A two-step approach for clinical named entity recognition and normalization,” 2022.
- [40] Miranda-Escalada, A., Gonzalez-Agirre, A., Armengol-Estapé, J., y Krallinger, M., “Overview of automatic clinical coding: Annotations, guidelines, and solutions for non-english clinical cases at codiesp track of clef ehealth 2020.,” *CLEF (Working Notes)*, vol. 2020, 2020.
- [41] Palotti, J., Scells, H., y Zuccon, G., “Trectools: an open-source python library for information retrieval practitioners involved in trec-like campaigns,” en *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 1325–1328, 2019.
- [42] Miranda-Escalada, A., Farré, E., y Krallinger, M., “Named entity recognition, concept normalization and clinical coding: Overview of the cantemist track for cancer text mining in spanish, corpus, guidelines, methods and results.,” *IberLEF@ SEPLN*, pp. 303–323, 2020.
- [43] Barros, J., Rojas, M., Dunstan, J., y Abeliuk, A., “Divide and conquer: An extreme multi-label classification approach for coding diseases and procedures in spanish,” en *Proceedings of the 13th International Workshop on Health Text Mining and Information Analysis (LOUHI)*, pp. 138–147, 2022.
- [44] Blanco, A., Pérez, A., y Casillas, A., “Ixa-aaa at clef ehealth 2020 codiesp. automatic classification of medical records with multi-label classifiers and similarity match coders.,” en *CLEF (Working Notes)*, 2020.
- [45] Cossin, S. y Jouhet, V., “Iam at clef ehealth 2020: Concept annotation in spanish electronic health records.,” en *CLEF (Working Notes)*, 2020.
- [46] García-Santa, N., Cetina, K., Cappellato, L., Eickhoff, C., Ferro, N., y Nevéol, A., “Fle at

- clef ehealth 2020: Text mining and semantic knowledge for automated clinical encoding.,” en CLEF (Working Notes), 2020.
- [47] Costa, J., Lopes, I., Carreiro, A. V., Ribeiro, D., y Soares, C., “Fraunhofer aicos at clef ehealth 2020 task 1: Clinical code extraction from textual data using fine-tuned bert models.,” en CLEF (Working Notes), 2020.
- [48] García-Pablos, A., Perez, N., y Cuadros, M., “Vicomtech at cantemist 2020,” en Proceedings of the Iberian Languages Evaluation Forum (IberLEF 2020), CEUR Workshop Proceedings, vol. 17, p. 25, 2020.
- [49] López-García, G., Jerez, J. M., y Veredas, F. J., “Icb-uma at cantemist 2020: Automatic icd-o coding in spanish with bert.,” en IberLEF@ SEPLN, pp. 468–476, 2020.
- [50] López-García, G., Jerez, J. M., Ribelles, N., Alba, E., y Veredas, F. J., “Transformers for clinical coding in spanish,” IEEE Access, vol. 9, pp. 72387–72397, 2021.
- [51] IARC, “Globocan 2020: New global cancer data,” 2020, <https://www.uicc.org/news/globalobocan-2020-new-global-cancer-data#>. Accedido: Mar. 10, 2023.
- [52] Bray, F., Jemal, A., Grey, N., Ferlay, J., y Forman, D., “Global cancer transitions according to the human development index (2008–2030): a population-based study,” The lancet oncology, vol. 13, no. 8, pp. 790–801, 2012.
- [53] IARC, “Chile source: Globocan 2020,” 2020, <https://gco.iarc.fr/today/data/factsheets/populations/152-chile-fact-sheets.pdf>. Accedido: Mar. 10, 2023.
- [54] Parra-Soto, S., Petermann-Rocha, F., Martínez-Sanguinetti, M. A., Leiva-Ordeñez, A. M., Troncoso-Pantoja, C., Ulloa, N., Diaz-Martínez, X., y Celis-Morales, C., “Cáncer en chile y en el mundo: una mirada actual y su futuro escenario epidemiológico,” Revista médica de Chile, vol. 148, no. 10, pp. 1489–1495, 2020.
- [55] MINSAL, “Cuenta pública 2021 ministerio de salud,” 2021, <https://www.minsal.cl/wp-content/uploads/2023/04/Cuenta-Pu\%CC%\%81blica-Final-2021.pdf>. Accedido: Mar. 20, 2023.
- [56] MINSAL, “Glosa 06 lista de espera no ges y garantías de oportunidades ges retrasadas,” 2023, <https://www.minsal.cl/wp-content/uploads/2021/05/Ord.-331-Glosa-06-IV-Tri m-2022.pdf>. Accedido: Mar. 20, 2023.
- [57] Harrison, J. E., Weber, S., Jakob, R., y Chute, C. G., “ICD-11: an international classification of diseases for the twenty-first century,” BMC medical informatics and decision making, vol. 21, no. 6, pp. 1–10, 2021.

Anexo

Tabla .1: Actualidad de la codificación en lista de espera histórica.

Servicios de Salud	Cantidad de CNE	Diagnósticos codificados	Diagnósticos no codificados	Porcentaje de codificación
Servicio de Salud Arica	370.270	237.277	132.993	64,08 %
Servicio de Salud Iquique	205.664	30.533	175.131	14,85 %
Servicio de Salud Antofagasta	420.902	4.515	416.387	1,07 %
Servicio de Salud Atacama	324.231	4.542	319.689	1,40 %
Servicio de Salud Coquimbo	910.423	910.068	355	99,96 %
Servicio de Salud Valparaíso San Antonio	531.846	513.910	17.936	96,63 %
Servicio de Salud Viña del Mar Quillota	915.537	740.328	175.209	80,86 %
Servicio de Salud Aconcagua	393.534	265	393.269	0,07 %
Servicio de Salud Metropolitano Norte	869.472	14.013	855.459	1,61 %
Servicio de Salud Metropolitano Occidente	1.106.700	3.715	1.102.985	0,34 %
Servicio de Salud Metropolitano Central	776.739	3.434	773.305	0,44 %
Servicio de Salud Metropolitano Oriente	846.481	838.778	7.703	99,09 %
Servicio de Salud Metropolitano Sur	1.046.528	897.592	148.936	85,77 %
Servicio de Salud Metropolitano Sur Oriente	1.410.769	210.334	1.200.435	14,91 %
Servicio de Salud Del Libertador B.O'Higgins	936.831	433.590	503.241	46,28 %
Servicio de Salud Del Maule	1.131.353	2.480	1.128.873	0,22 %
Servicio de Salud Ñuble	741.755	359.104	382.651	48,41 %
Servicio de Salud Concepción	1.064.778	24.172	1.040.606	2,27 %
Servicio de Salud Talcahuano	548.052	318.900	229.152	58,19 %
Servicio de Salud Biobío	478.538	5.470	473.068	1,14 %
Servicio de Salud Araucanía Sur	977.828	1.862	975.966	0,19 %
Servicio de Salud Valdivia	451.626	1.418	450.208	0,31 %
Servicio de Salud Osorno	418.179	192.194	225.985	45,96 %
Servicio de Salud Del Reloncaví	478.690	3.350	475.340	0,70 %
Servicio de Salud Aisén	184.335	828	183.507	0,45 %
Servicio de Salud Magallanes	312.159	411	311.748	0,13 %
Servicio de Salud Arauco	271.663	652	271.011	0,24 %
Servicio de Salud Araucanía Norte	357.977	747	357.230	0,21 %
Servicio de Salud Chiloé	233.769	6.268	227.501	2,68 %

Tabla .2: Distribución de la especialidad médica presente en lista de espera histórica - Parte 1.

Especialidad	Conteo	Frecuencia Relativa en porcentaje
Oftalmología	3.352.203	17,91
Otorrinolaringología	1.270.563	6,79
Traumatología y Ortopedia	1.066.814	5,70
Ginecología	991.166	5,30
Cirugía General	982.500	5,25
Dermatología	762.758	4,08
Medicina Interna	703.844	3,76
Endodoncia	662.607	3,54
Rehabilitación Oral Removible	652.604	3,49
Urología	605.425	3,23
Neurología Adulto	598.409	3,20
Cardiología	513.402	2,74
Gastroenterología Adulto	379.281	2,03
Obstetricia	378.622	2,02
Cirugía y Traumatología Buco Maxilofacial	354.823	1,90
Ortodoncia y Ortopedia Dento Máxilo Facial	350.217	1,87
Cirugía Pediátrica	339.099	1,81
Pediatría	325.121	1,74
Neurología Pediátrica	290.388	1,55
Neurocirugía	251.433	1,34
Endocrinología Adulto	246.405	1,32
Periodoncia	246.055	1,31
Cirugía Vasculat Periférica	234.110	1,25
Traumatología y Ortopedia Pediátrica	229.829	1,23
Psiquiatría Adulto	225.309	1,20
Enfermedades Respiratorias del Adulto	186.206	0,99
Odontopediatría	176.000	0,94
Medicina Física y Rehabilitación	173.849	0,93
Reumatología	168.667	0,90
Cirugía Digestiva	152.999	0,82
Nefrología Adulto	143.823	0,77
Cirugía Bucal	125.947	0,67
Psiquiatría Pediátrica y de la Adolescencia	110.733	0,59
Coloproctología	109.964	0,59

Tabla .3: Distribución de la especialidad médica presente en lista de espera histórica - Parte 2.

Especialidad	Conteo	Frecuencia Relativa en porcentaje
Rehabilitación Oral Prótesis Fija	101.502	0,54
Hematología	91.691	0,49
Cardiología Pediátrica	89.726	0,48
Cirugía de Cabeza, Cuello y Maxilofacial	80.530	0,43
Endocrinología Pediátrica	72.549	0,39
Gastroenterología Pediátrica	71.375	0,38
Trastornos Temporomandibulares y Dolor Orofacial	70.067	0,37
Anestesiología	59.011	0,32
Enfermedades Respiratorias Pediátricas	57.755	0,31
Oncología Médica	53.274	0,28
Ginecología Pediátrica y de la Adolescencia	53.181	0,28
Nefrología Pediátrico	52.228	0,28
Urología Pediátrica	45.936	0,25
Radioterapia Oncológica	36.396	0,19
Geriatría	35.997	0,19
Endocrinología	33.197	0,18
Cirugía Plástica y Reparadora	31.597	0,17
Genética Clínica	31.481	0,17
Infectología	23.289	0,12
Medicina Física y Rehabilitación Pediátrica	22.075	0,12
Implantología Buco Maxilofacial	22.042	0,12
Nutriólogo	21.847	0,12
Cirugía de Tórax	19.013	0,10
Hemato-oncología Pediátrica	17.824	0,10
Inmunología	17.301	0,09
Operatoria	17.229	0,09
Nutriólogo Pediátrico	16.359	0,09
Enf, Transmisión Sexual	16.139	0,09
Patología Oral	16.029	0,09
Diabetología	15.903	0,08
Medicina Familiar	10.774	0,06
Reumatología Pediátrica	10.706	0,06
Infectología Pediátrica	9.223	0,05
Cirugía Plástica y Reparadora Pediátrica	8.471	0,05
Cirugía Cardiovascular	8.259	0,04
Salud Ocupacional	4.189	0,02
Odonto. Indiferenciada	3.957	0,02
Neonatología	3.496	0,02
Imagenología Oral y Maxilofacial	2.367	0,01
Medicina Familiar Del Niño	1.469	0,01

Tabla .4: Cantidad de palabras por oración a nivel de especialidad en interconsultas CNE en lista de espera histórica - Parte 1.

Especialidad	Cantidad de tokens (std)	Cantidad de oraciones (std)	Cantidad de tokens por oraciones
Infectología	28,60 (48,05)	1,51 (1,61)	18,95
Oncología Médica	20,10 (42,13)	1,16 (0,67)	17,40
Diabetología	19,03 (33,07)	1,34 (1,32)	14,22
Reumatología Pediátrica	15,06 (30,96)	1,19 (0,75)	12,61
Patología Oral	14,55 (24,52)	1,18 (0,69)	12,34
Neonatología	12,93 (31,31)	1,11 (0,56)	11,65
Hemato-oncología Pediátrica	12,71 (26,75)	1,16 (0,75)	10,94
Cirugía Plástica y Reparadora Pediátrica	12,15 (16,34)	1,12 (0,51)	10,89
Ginecología Pediátrica y de la Adolescencia	13,01 (22,61)	1,23 (0,83)	10,61
Traumatología y Ortopedia Pediátrica	12,27 (18,40)	1,16 (0,74)	10,55
Enfermedades Respiratorias del Adulto	13,14 (27,73)	1,27 (0,95)	10,34
Medicina y Física y Rehabilitación	12,55 (21,42)	1,24 (0,86)	10,15
Inmunología	11,95 (24,11)	1,18 (0,97)	10,11
Cirugía Cardiovascular	11,97 (28,14)	1,21 (0,80)	9,91
Neurocirugía	11,94 (23,39)	1,22 (0,82)	9,81
Traumatología y Ortopedia	11,95 (20,72)	1,22 (0,86)	9,79
Neurología Pediátrica	12,15 (26,60)	1,24 (1,00)	9,77
Hematología	11,40 (26,28)	1,17 (0,73)	9,76
Gastroenterología Pediátrica	11,55 (24,19)	1,19 (0,79)	9,74
Psiquiatría Adulto	13,17 (27,68)	1,38 (1,08)	9,57
Enfermedades Respiratorias Pediátricas	10,69 (20,05)	1,12 (0,64)	9,52
Obstetricia	11,79 (11,62)	1,24 (0,78)	9,51
Cirugía de Tórax	11,19 (22,11)	1,18 (0,71)	9,46
Genética Clínica	11,22 (17,11)	1,19 (0,65)	9,46
Urología Pediátrica	10,94 (18,21)	1,16 (0,68)	9,43
Cardiología Pediátrica	11,00 (19,81)	1,17 (0,79)	9,42
Nefrología Pediátrico	11,16 (19,63)	1,19 (0,70)	9,41
Cardiología	11,68 (25,36)	1,24 (0,94)	9,40
Medicina Interna	11,41 (25,35)	1,21 (0,94)	9,39
Coloproctología	10,81 (23,39)	1,15 (0,78)	9,37
Nefrología Adulto	11,98 (22,85)	1,28 (0,93)	9,32
Cirugía Vascul ar Periférica	10,99 (18,22)	1,19 (0,71)	9,25
Cirugía General	10,75 (19,78)	1,17 (0,76)	9,22
Gastroenterología Adulto	11,58 (23,91)	1,26 (0,95)	9,20

Tabla .5: Cantidad de palabras por oración a nivel de especialidad en interconsultas CNE en lista de espera histórica - Parte 2.

Especialidad	Cantidad de tokens (std)	Cantidad de oraciones (std)	Cantidad de tokens por oraciones
Infectología Pediátrica	10,50 (17,90)	1,15 (0,64)	9,16
Ortodoncia y Ortopedia Dento Máxilo Facial	10,52 (11,37)	1,16 (0,64)	9,04
Urología	10,75 (19,65)	1,19 (0,81)	9,03
Cirugía Plástica y Reparadora	10,03 (17,11)	1,11 (0,50)	9,02
Cirugía y Traumatología Buco Maxilofacial	10,88 (17,17)	1,21 (0,78)	9,01
Endocrinología Adulto	10,56 (20,45)	1,17 (0,76)	8,99
Endocrinología Pediátrica	10,42 (23,24)	1,17 (0,70)	8,90
Psiquiatría Pediátrica y de la Adolescencia	11,95 (24,64)	1,35 (1,07)	8,82
Ginecología	10,38 (16,55)	1,18 (0,72)	8,82
Odonto. Indiferenciada	10,64 (8,85)	1,21 (0,59)	8,76
Rehabilitación Oral Prótesis Fija	11,11 (10,69)	1,28 (0,65)	8,70
Implantología Buco Maxilofacial	11,55 (10,96)	1,33 (0,72)	8,68
Medicina Física y Rehabilitación Pediátrica	10,16 (12,64)	1,19 (0,72)	8,56
Rehabilitación Oral Removible	10,65 (10,12)	1,26 (0,63)	8,44
Neurología Adulto	10,39 (23,06)	1,24 (0,94)	8,41
Dermatología	9,69 (17,43)	1,16 (0,68)	8,34
Reumatología	9,29 (20,10)	1,15 (0,72)	8,06
Cirugía de Cabeza, Cuello y Maxilofacial	9,00 (8,86)	1,12 (0,48)	8,02
Odontopediatría	9,39 (12,35)	1,17 (0,68)	8,00
Cirugía Pediátrica	9,02 (14,17)	1,13 (0,60)	7,99
Otorrinolaringología	9,10 (18,03)	1,14 (0,69)	7,95
Nutriólogo	8,92 (17,66)	1,13 (0,52)	7,91
Radioterapia Oncológica	8,67 (11,25)	1,10 (0,45)	7,88
Pediatría	9,32 (18,79)	1,19 (0,89)	7,81
Geriatría	10,10 (12,52)	1,30 (0,82)	7,75
Endocrinología	9,29 (6,94)	1,20 (0,54)	7,75
Trastornos Temporomandibulares y Dolor Orofacial	10,84 (13,94)	1,43 (0,84)	7,60
Medicina Familiar Del Niño	9,20 (18,56)	1,25 (0,83)	7,37
Anestesiología	7,65 (7,90)	1,07 (0,40)	7,12
Enf, Transmisión Sexual	8,11 (9,73)	1,15 (0,52)	7,05
Operatoria	7,59 (7,42)	1,09 (0,38)	6,99
Oftalmología	7,97 (9,61)	1,16 (0,51)	6,88
Endodoncia	8,15 (8,93)	1,19 (0,57)	6,87
Cirugía Digestiva	7,40 (13,56)	1,09 (0,45)	6,81
Nutriólogo Pediátrico	7,63 (9,54)	1,12 (0,56)	6,80
Periodoncia	8,41 (11,62)	1,24 (0,68)	6,78
Medicina Familiar	7,82 (14,70)	1,16 (0,51)	6,76
Cirugía Bucal	7,66 (6,45)	1,14 (0,47)	6,72
Imagenología Oral y Maxilofacial	5,21 (2,55)	1,02 (0,21)	5,11
Salud Ocupacional	4,16 (1,41)	1,01 (0,11)	4,12

Tabla .6: Rendimiento de las especialidades médicas - Parte 1.

ESPECIALIDAD	IoU Nivel Categoría	MAP Nivel Categoría	Frecuencia Relativa en porcentaje
Operatoria	1.00	1.0	0.58
Otorrinolaringología	1.00	1.0	1.45
Endodoncia	1.00	1.0	1.45
Imagenología Oral y Maxilofacial	1.00	1.0	0.58
Nutriólogo Pediátrico	0.95	1.0	1.45
Psiquiatría Adulto	0.90	1.0	1.45
Rehabilitación Oral Prótesis Fija	0.90	1.0	1.45
Nefrología Adulto	0.90	1.0	1.45
Urología Pediátrica	0.90	1.0	1.45
Medicina Física y Rehabilitación Pediátrica	0.90	1.0	1.45
Ortodoncia y Ortopedia Dento Máxilo Facial	0.80	1.0	1.45
Odontopediatría	0.80	1.0	1.45
Periodoncia	0.80	1.0	1.45
Cirugía y Traumatología Buco Maxilofacial	0.70	1.0	1.45
Rehabilitación Oral Removible	0.60	1.0	1.45
Cirugía Plástica y Reparadora	0.50	1.0	1.45
Obstetricia	0.40	1.0	1.45
Neurología Pediátrica	0.97	0.96	1.45
Neurocirugía	0.77	0.96	1.45
Medicina Interna	0.80	0.94	1.45
Infectología	0.93	0.93	1.45
Hemato-Oncología Pediátrica	0.85	0.93	1.45
Endocrinología Pediátrica	0.75	0.93	1.45
Cirugía Vasculat Periférica	0.65	0.91	1.45
Nutriólogo	0.90	0.9	1.45
Cirugía de Cabeza, Cuello y Maxilofacial	0.82	0.9	1.45
Cardiología Pediátrica	0.80	0.89	1.45
Dermatología	0.80	0.89	1.45
Psiquiatría Pediátrica y de la Adolescencia	0.80	0.89	1.45
Cirugía Pediátrica	0.70	0.88	1.45
Oftalmología	0.70	0.88	1.45
Ginecología Pediátrica y de la Adolescencia	0.70	0.88	1.45
Genética Clínica	0.65	0.88	1.45
Implantología Buco Maxilofacial	0.55	0.88	1.45
Ginecología	0.35	0.88	1.45

Tabla .7: Rendimiento de las especialidades médicas - Parte 2.

ESPECIALIDAD	IoU Nivel Categoría	MAP Nivel Categoría	Frecuencia Relativa en porcentaje
Cirugía Plástica y Reparadora Pediátrica	0.70	0.86	1.45
Nefrología Pediátrico	0.55	0.86	1.45
Coloproctología	0.85	0.85	1.45
Gastroenterología Adulto	0.68	0.85	1.45
Cirugía Bucal	0.53	0.85	1.45
Pediatría	0.85	0.83	1.45
Urología	0.83	0.83	1.45
Medicina Familiar	0.74	0.83	1.45
Cirugía General	0.60	0.83	1.45
Patología Oral	0.50	0.83	1.45
Anestesiología	0.80	0.8	1.45
Cirugía Digestiva	0.72	0.8	1.45
Enfermedades Respiratorias Del Adulto	0.73	0.79	1.45
Reumatología Pediátrica	0.62	0.79	1.45
Oncología Médica	0.52	0.79	1.45
Enfermedades Respiratorias Pediátricas	0.72	0.78	1.45
Cirugía Cardiovascular	0.70	0.78	1.45
Medicina Física y Rehabilitación	0.70	0.78	1.45
Neonatología	0.70	0.75	1.45
Reumatología	0.65	0.73	1.45
Cardiología	0.72	0.72	1.45
Endocrinología Adulto	0.72	0.72	1.45
Trastornos Temporomandibulares y Dolor Orofacial	0.60	0.71	1.45
Traumatología y Ortopedia	0.50	0.71	1.45
Infectología Pediátrica	0.60	0.69	1.45
Inmunología	0.50	0.67	1.45
Neurología Adulto	0.70	0.64	1.45
Geriatría	0.50	0.6	1.45
Gastroenterología Pediátrica	0.41	0.58	1.45
Cirugía de Tórax	0.53	0.53	1.45
Radioterapia Oncológica	0.30	0.5	1.45
Diabetología	0.38	0.47	1.45
Medicina Familiar del Niño	0.33	0.45	1.45
Hematología	0.38	0.38	1.45
Traumatología y Ortopedia Pediátrica	0.40	0.33	1.45

Tabla .8: Codificación automática en lista de espera histórica.

Servicios de Salud	Cantidad de CNE	Diagnósticos codificados	Diagnósticos no codificados	Porcentaje de codificación
Servicio de Salud Arica	370.270	291.842	78.428	78,81 %
Servicio de Salud Iquique	205.664	69.253	136.411	33,67 %
Servicio de Salud Antofagasta	420.902	201.056	219.846	47,76 %
Servicio de Salud Atacama	324.231	267.275	56.956	82,43 %
Servicio de Salud Coquimbo	910.423	897.677	12.746	98,59 %
Servicio de Salud Valparaíso San Antonio	531.846	512.185	19.661	96,3 %
Servicio de Salud Viña del Mar Quillota	915.537	811.616	103.921	88,64 %
Servicio de Salud Aconcagua	393.534	315.249	78.285	80,1 %
Servicio de Salud Metropolitano Norte	869.472	493.744	375.728	56,78 %
Servicio de Salud Metropolitano Occidente	1.106.700	877.318	229.382	79,27 %
Servicio de Salud Metropolitano Central	776.739	557.991	218.748	71,83 %
Servicio de Salud Metropolitano Oriente	846.481	826.899	19.582	97,68 %
Servicio de Salud Metropolitano Sur	1.046.528	933.021	113.507	89,15 %
Servicio de Salud Metropolitano Sur Oriente	1.410.769	1.054.696	356.073	74,76 %
Servicio de Salud Del Libertador B.O'Higgins	936.831	682.790	254.041	72,88 %
Servicio de Salud Del Maule	1.131.353	576.542	554.811	50,96 %
Servicio de Salud Ñuble	741.755	658.544	83.211	88,78 %
Servicio de Salud Concepción	1.064.778	694.967	369.811	65,26 %
Servicio de Salud Talcahuano	548.052	514.044	34.008	93,79 %
Servicio de Salud Biobío	478.538	441.001	37.537	92,15 %
Servicio de Salud Araucanía Sur	977.828	718.843	258.985	73,51 %
Servicio de Salud Valdivia	451.626	292.974	158.652	64,87 %
Servicio de Salud Osorno	418.179	385.367	32.812	92,15 %
Servicio de Salud Del Reloncaví	478.690	375.712	102.978	78,48 %
Servicio de Salud Aisén	184.335	130.371	53.964	70,72 %
Servicio de Salud Magallanes	312.159	97.447	214.712	31,21 %
Servicio de Salud Arauco	271.663	210.941	60.722	77,64 %
Servicio de Salud Araucanía Norte	357.977	194.227	163.750	54,25 %
Servicio de Salud Chiloé	233.769	164.190	69.579	70,23 %