

## APORTE DE UN SISTEMA PREDICTIVO DE CONTRALORÍA MÉDICA EN LA GESTIÓN DE LICENCIAS MÉDICAS ELECTRÓNICAS

CONTRIBUTIONS OF A PREDICTIVE MEDICAL AUDIT SYSTEM IN THE ELECTRONIC MANAGEMENT OF SICK LEAVES

### RESUMEN

**Introducción:** El retraso del procesamiento de las licencias médicas (LMs) representa un problema de salud pública en Chile, considerando que esto afecta el pago del subsidio a las personas destinado a realizar el reposo médico prescrito mientras no se pueda trabajar. El objetivo de este estudio fue explorar las diferencias en el tiempo de procesamiento de las licencias médicas electrónicas (LMEs) evaluadas por contraloría médica (CM) y las evaluadas por un sistema predictivo de contraloría médica (SPCM) basado en redes neuronales artificiales. **Materiales y métodos:** El tiempo de procesamiento de LMEs procesadas con SPCM fue comparado con el tiempo de procesamiento de LMEs examinadas solo con CM, usando curvas de Kaplan Meier, prueba de log-rank y modelos multivariados de Cox. **Resultados:** La tasa de procesamiento del SPCM fue entre 1,7 a 5,5 veces más rápida que la tasa de procesamiento de la CM, ajustando por potenciales confusores. **Discusión:** La implementación del SPCM permitió disminuir el tiempo de procesamiento de las LMEs, beneficiando a los trabajadores afiliados al seguro público.

**Palabras clave:** ausencia por enfermedad; inteligencia artificial; auditoría médica; financiamiento gubernamental; Chile

### ABSTRACT

**Introduction:** The delay in the processing of sick leaves (SLs) is a public health problem in Chile, considering that this affects the payment of the subsidy to the individuals destined to perform the prescribed medical rest while unable to work. The aim of this study was to explore the differences in the processing time of electronic SLs (ESLs) evaluated by medical audit (MA) and the SLs evaluated by a predictive medical audit system (PMAS) based on artificial neural networks. **Materials and methods:** The processing time of the ESLs that were processed by PMAS was compared with the processing time of those that were examined only by MA, using Kaplan Meier curves, log-rank test, and multivariate Cox models. **Results:** The processing rate for PMAS was 1.7-fold to 5.5-fold faster than MA, after adjusting for potential confounding variables. **Discussion:** The implementation of the PMAS reduced the processing time of ESLs, which benefits the workers affiliated to the public insurance system in Chile.

**Keywords:** sick leave; artificial intelligence; medical audit; government financing; Chile

**Bélgica Bernales**

División de Planificación  
Institucional, FONASA.  
Santiago, Chile

**Stéphanie Bravo**

COMPIN, SEREMI RM,  
Subsecretaría de Salud Pública.  
Santiago, Chile

**Leonardo Causa**

Proyectos de Ingeniería  
DataOn SpA.  
Santiago, Chile

**Najely Gómez**

Instituto de Salud Poblacional.  
Facultad de Medicina.  
Universidad de Chile.  
Santiago, Chile

**Macarena Valdés**

Departamento de Epidemiología.  
Instituto de Salud Poblacional.  
Facultad de Medicina. Universidad  
de Chile. Santiago, Chile.  
Centro de Ciencia del Clima y la  
Resiliencia, CR2. Santiago, Chile  
macavaldes@uchile.cl

## INTRODUCCIÓN

La Organización Internacional del Trabajo define la Seguridad Social como un Derecho Humano<sup>1</sup>, que implica entre otras cosas, que la sociedad debe procurar la protección y el acceso a la asistencia médica de los individuos, garantizando adicionalmente la seguridad de sus ingresos.

La licencia médica (LM) es el instrumento que permite a los trabajadores acceder al reposo y ausentarse del trabajo cuando están impedidos temporalmente de realizar sus actividades laborales a causa de una enfermedad o accidente; esta, además de cumplir un rol terapéutico les permite acceder a un pago por incapacidad laboral con cargo a las aseguradoras previsionales como las Instituciones de Salud Previsional (ISAPRES) y el Fondo Nacional de Salud (FONASA).

En Chile, el retraso en la resolución de las LMs de los cotizantes de FONASA y el pago asociado a estas es un reconocido problema de salud pública<sup>2,3</sup>. A comienzos del año 2018, desde el Departamento de Coordinación Nacional de las Comisiones de Medicina Preventiva e Invalidez (COMPIN) se reconoció un retraso de aproximadamente 10 mil licencias médicas solo en la Región Metropolitana, lo que afecta la periodicidad del soporte financiero de un número considerable de hogares. Considerando que un 77% de la población pertenece a este seguro público de salud y que un 70% de sus cotizantes lo hace con una renta mensual inferior a los 650.000 pesos (800 USD), el impacto del retraso del pago en esta población que tiene una mayor vulnerabilidad socioeconómica afecta diversos ámbitos de la vida personal, familiar y social<sup>4</sup>.

El aumento progresivo de las LMs —un 400% entre los años 2001 y 2016<sup>5</sup>— ha sobrepasado la capacidad de respuesta de la COMPIN, lo que explica significativamente el retraso en la resolución de las LMs<sup>6</sup>. Ello porque la COMPIN realiza, entre otras funciones, la contraloría médica (CM) de las LMs lo que involucra la evaluación de la emisión y la pertinencia; este proceso se basa en la revisión de decretos, guías referenciales y protocolos, lo que en muchas ocasiones conlleva un tiempo considerable para procesar completamente una LM<sup>7,8</sup>.

Para enfrentar esta problemática, desde el año 2018, la Subsecretaría de Salud Pública está desarrollando un “Plan de optimización del proceso de gestión de las LMs de trabajadores cotizantes FONASA”. Un componente central de este plan, desarro-

llado en conjunto con FONASA, es la implementación de un sistema predictivo de contraloría médica (SPCM) de LMs que utiliza algoritmos de aprendizaje de máquina (AM) o conocido como machine Learning en inglés, con el propósito de apoyar la CM y aumentar la tasa de procesamiento y por ende de resolución<sup>9</sup>. El SPCM se validó desde el punto de vista informático a través de la construcción, entrenamiento, validación y prueba del modelo de AM, explicado en detalle más adelante.

Según F. Tobar del Centro de Modelamiento Matemático de la Universidad de Chile<sup>10</sup>, el AM actualmente se desarrolla en base a algoritmos que permiten el aprendizaje continuo de las máquinas, combinando elementos de la estadística, las probabilidades y las ciencias cognitivas. En salud pública, la publicación de experiencias basadas en la aplicación de AM ha aumentado progresivamente mostrando beneficios para temáticas de variada índole, por ejemplo reducción de los tiempos y costos asociados a la codificación de cuentas de gastos sanitarios<sup>11</sup>, mejora de la predicción de eventos de revascularización posteriores a una perfusión miocárdica<sup>12</sup>, estimaciones de la expectativa de vida según comuna de nacimiento<sup>13</sup> o estimaciones de la mortalidad hospitalaria<sup>14,15</sup>.

En este estudio el objetivo fue explorar las diferencias en el tiempo de procesamiento de las LMs evaluadas por CM y las LMs evaluadas por CM con apoyo de AM mediante el SPCM. Esto servirá como evidencia sobre la utilidad del AM en la resolución de las LMs y concomitantemente, en la disminución del tiempo de procesamiento y tiempo de pago.

## MATERIALES Y MÉTODOS

### Licencias médicas electrónicas (LMEs)

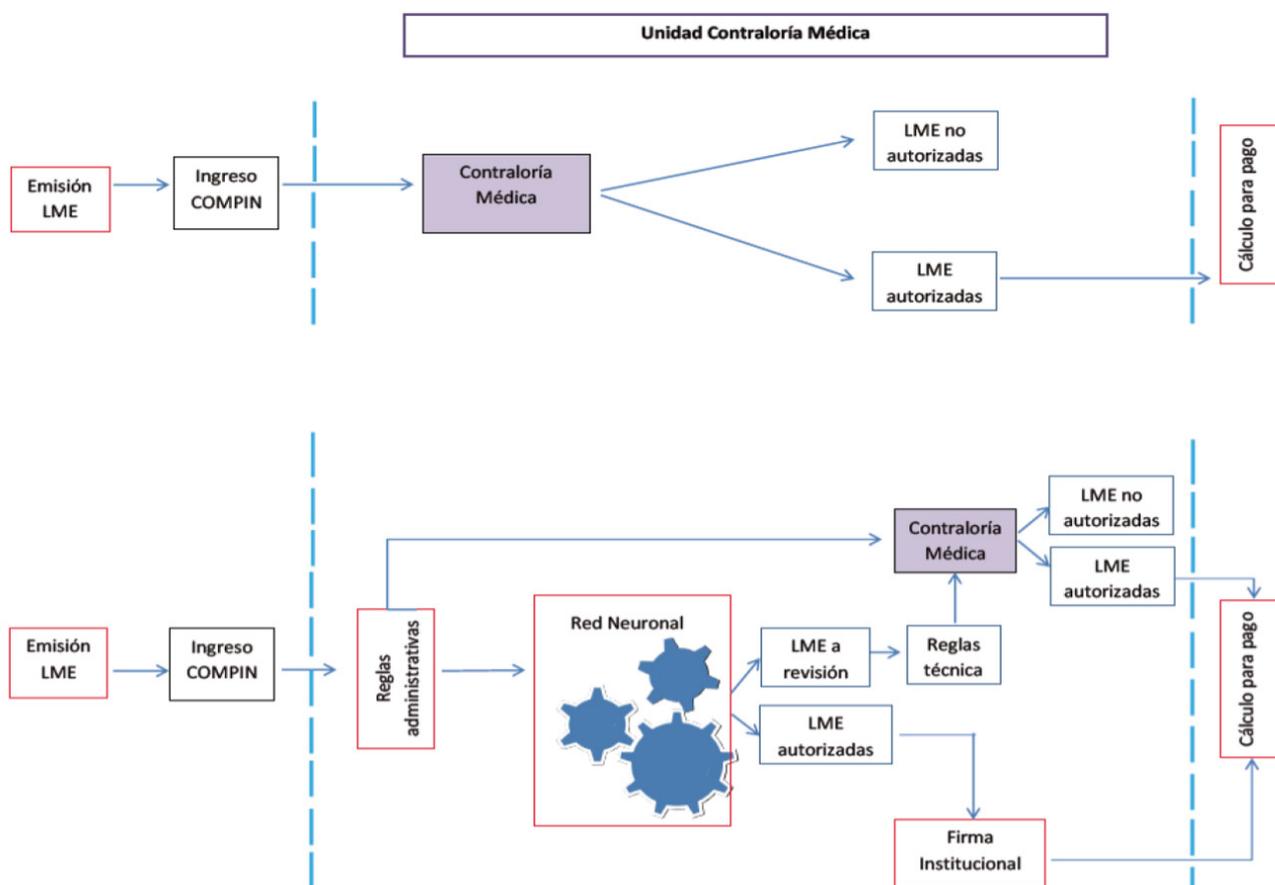
La LME se caracteriza por el uso de documentos y comunicaciones electrónicas en su otorgamiento y tramitación, permitiendo un resultado equivalente a la LM otorgada en formulario de papel. Su implementación fue orientada a facilitar el proceso de otorgamiento y tramitación mediante el uso de Tecnologías de la Información (TIC), proporcionando múltiples beneficios a los distintos actores vinculados al proceso, tales como mayor seguridad y resguardo de la información, comodidad para el paciente, y trazabilidad completa de los procesos tanto para el trabajador, empleador y organismos fiscalizadores<sup>16-18</sup>. Por lo tanto, su tiempo de recepción en

la COMPIN debería ser menor, no así su tiempo de procesamiento que debería ser equivalente.

Un aspecto relevante es que las LMEs incluyen el diagnóstico médico codificado mediante el sistema de clasificación internacional de enfermedades décima versión (CIE-10)<sup>19</sup>, lo que en las LM de formulario de papel no sucede. Esta característica es un requisito indispensable para que la LM pueda ser examinada por el SPCM. Por lo tanto, en este estudio se utilizaron LMEs para validar el SPCM, para luego comparar los tiempos de procesamiento entre un sistema basado solo en CM y un SPCM (Figura 1).

En el primer caso, las LMEs fueron recibidas en la COMPIN de la Región Metropolitana (RM) y fueron examinadas por los contralores según fecha (principalmente orden de llegada). En el segundo caso, las LMEs no tan solo fueron ordenadas por fecha, sino que pasaron por reglas administrativas que permitieron clasificarlas en dos grupos: uno que fue revisado por CM y otro grupo de licencias que se consideró como aprobadas por las reglas administrativas y que fue revisado por una red neuronal artificial (RNA). Cabe destacar que las reglas administrativas corresponden a un árbol de decisión que clasifica

Figura 1. Procesamiento de LME en CM y SPCM.



A) Modelo de CM: las LMEs que ingresan en COMPIN pasan directamente a la unidad de CM donde se revisan individualmente según orden de llegada. Las LMEs que son autorizadas pasan a la unidad de subsidio para calcular el pago. B) Modelo de SPCM: se aplican reglas administrativas a las LMEs que ingresan a COMPIN para clasificarlas en 2 grupos: revisión por CM o por RNA. En la RNA, las LMEs son nuevamente clasificadas en 2 grupos: LMEs autorizadas, que son resueltas masivamente y validadas en cada COMPIN con firma Institucional, y LMEs a revisión, que son dirigidas a revisión por CM. Tanto las LMEs autorizadas por CM como las autorizadas por firma institucional pasan a la unidad de subsidio para calcular su pago.

las LMEs según complejidad para su revisión por los contralores; dentro de las reglas más relevantes podemos considerar: licencias fuera de plazo, licencias sin recuperabilidad laboral, duplicidad de licencias durante el mismo periodo, licencias con exceso de días de reposo según diagnóstico, licencias con sospecha de patología de origen laboral, entre otras.

Las LMEs que pasaron por la RNA pueden ser autorizadas institucionalmente sin ningún proceso adicional. Lo anterior ocurre porque la RNA fue diseñada solo para resolver LMEs de baja complejidad, complementando el trabajo de la CM con una reducción del volumen de LMEs que deben ser examinadas diariamente por los contralores. Por lo tanto, para el examen de las LMEs en el SPCM fue necesario validar el sistema desde el punto de vista informático. Lo anterior conllevó un trabajo de implementación de una RNA que sirvió como soporte a la CM tradicional. La etapa de implementación consistió en: 1. definición de la metodología de construcción, entrenamiento, validación y prueba del modelo de AM, y 2. la construcción y prueba del modelo de RNA.

### **Metodología de construcción, entrenamiento, validación y prueba del modelo de AM**

El primer paso correspondió la comprensión y levantamiento de requerimientos del problema. Esto implicó analizar las fuentes de información disponibles y los datos existentes sobre CM tradicional para construir una primera base de datos. En esta fase fue importante realizar una limpieza y pre-procesamiento que permitió eliminar casos atípicos e imputar datos faltantes. Posterior a este pre-procesamiento, se dividieron los datos en conjuntos para el entrenamiento, validación y prueba del modelo predictivo.

La derivación o extracción de características fue considerada como una fase crítica en el desarrollo del modelo de AM, básicamente porque la elección de estas características permitió convertir datos sin procesar en información para la generación del vector de características para la RNA. Esta selección de características permitió mejorar la precisión y rendimiento del algoritmo, mejorar la interpretabilidad del modelo, y prevenir el sobre-ajuste durante el entrenamiento.

La siguiente fue la construcción del modelo de RNA. Una RNA es un tipo de AM que está inspirada en el funcionamiento del cerebro. Su propiedad más importante es la capacidad de aprender a partir

de un conjunto de patrones de entrenamiento, es decir, ser capaz de encontrar un modelo que ajuste los datos<sup>10</sup>. Se caracterizan por: 1. utilizar algoritmos de aprendizaje adaptativo y auto-organizativos; 2. permitir el procesado no lineal, lo que aumenta la capacidad de la red para aproximar funciones, clasificar patrones y aumentar su inmunidad frente al ruido; y, 3. realizar el procesamiento en paralelo utilizando un gran número de nodos de procesado, con alto nivel de interconectividad.

En esta etapa se probaron distintas configuraciones de la red para generar distintos modelos, los que fueron evaluados construyendo matrices de confusión que permitieron comparar indicadores de rendimiento para los conjuntos de entrenamiento y validación. Mediante este proceso iterativo se determinó cuál era el mejor modelo, siendo el criterio usado la maximización del poder predictivo. Una vez ajustada la RNA, se evaluó su desempeño sobre el conjunto de prueba.

### **Construcción y prueba de la RNA de CM**

El objetivo de la implementación de la RNA fue permitir realizar predicciones sobre la resolución de una LM. Para ello se utilizaron las resoluciones históricas realizadas por CM en cuanto a la aprobación y/o paso a revisión de las LMs presentes en la base de datos.

Para el SPCM se usó una RNA con aprendizaje supervisado. Se implementó una estructura multicapa, con una capa de entrada —vector de características— de 84 variables, 3 capas ocultas cada una con 200 neuronas, y una capa de salida con 2 neuronas para las categorías aprueba o a revisión.

Se evaluó el desempeño de la RNA sobre un conjunto de prueba con 76728 LMEs que habían sido procesadas por CM tradicional entre el 01 y 16 de junio de 2018. Se evidenció una concordancia de clasificación comparada con lo resuelto por los médicos contralores del 97,6%, con una sensibilidad de 97,7% y especificidad de 97,2%. Dado el éxito de la simulación se llevó a cabo un piloto en ambiente de producción en el mes de noviembre 2018, y luego se implementó el SPCM en la COMPIN de la RM en Santiago de Chile a partir diciembre de 2018.

### **Análisis estadístico del tiempo de procesamiento de LMEs en CM y SPCM**

Se definió como tiempo de procesamiento, al tiempo que transcurre desde que una LME se recibe hasta que se pronuncia (Figura 1). Fueron comparados los tiempos de procesamiento de las LMEs recibidas

durante los meses de diciembre de los años 2015, 2016 y 2017 con los tiempos de procesamiento de las LMEs recibidas en el mes de diciembre del año 2018; las primeras (2015-2017) fueron examinadas solo por CM y las segundas (2018) fueron examinadas por el SPCM (es decir, CM y AM).

Se describieron los tiempos de procesamiento usando medianas y rangos intercuartílicos (RIC) e histogramas. Para comparar los tiempos de procesamiento de las LMEs examinadas por CM con aquellas examinadas por el SPCM, se utilizaron curvas de Kaplan Meier y la prueba de log-rank; las curvas de Kaplan Meier permitieron realizar una descripción gráfica de la ocurrencia del evento de pronunciamiento de la LME y el tiempo que demoró este evento en suceder, y la prueba de log-rank complementó la apreciación gráfica con una prueba de hipótesis que permitió estimar diferencias significativas entre la CM y el SPCM<sup>20</sup>.

Para evaluar las diferencias en el tiempo de procesamiento de las LMEs realizadas por CM versus SPCM se estimaron modelos de regresión de Cox multivariados<sup>20</sup>. Se consideró en el ajuste un indicador denominado razón de LMEs recibidas versus procesadas, que tomó en consideración la cantidad de LMEs que son recibidas diariamente y la cantidad de contralores que están disponibles para el procesamiento diario. También se consideraron características de las LMEs, tales como edad y sexo del trabajador, diagnóstico y días de reposo. Adicionalmente, fue necesario tener en cuenta la estructura de datos multinivel ya que las LMEs procesadas en un mismo día comparten variabilidad y no son independientes.

Para la realización de este estudio se contó con la autorización del jefe de la División de Planificación Institucional de FONASA. Los datos fueron anonimizados previo al manejo estadístico.

## RESULTADOS

El total de LMEs analizadas en el período 2015-2018 fue 311826, la mayoría (30,9%) correspondiente al mes de diciembre de 2018. Tanto el número de LMEs recibidas como procesadas diariamente tuvieron una distribución asimétrica; la mediana de LMEs recibidas diariamente fue 4521 [RIC: 3235; 5344] y la mediana de LMEs procesadas diariamente fue 3009 [RIC: 2040; 4782]; la mediana de la razón entre LMEs recibidas y procesadas fue 1,37 [RIC: 0,85; 2,13] para los 4 años. La mediana del número de

contralores disponibles diariamente para procesar las LMEs fue 10 [RIC: 8; 11] y la mediana de tiempo de procesamiento en días fue 18 [RIC: 11; 23]. Con respecto a las características del trabajador, la mediana de edad era 38 [RIC: 29; 50] y la mayoría de las LMEs eran presentadas por mujeres (65,5%). La mediana de días de reposo fue 10 [RIC: 4; 15] y los diagnósticos principales fueron osteomusculares (23,8%) seguidos de mentales (23,2%) y respiratorios (8,5%).

Los resultados según año de procesamiento muestran diferencias modestas en la distribución de las variables analizadas (Tabla 1) pero estadísticamente significativas (valor-p <0,05). Se observó un aumento de la razón diaria de LMEs recibidas y procesadas, aumento de los días de LM prescritos a los trabajadores, aumento de la proporción de LMEs con diagnóstico por trastornos mentales, y aumento de la proporción de LMEs presentadas por mujeres; adicionalmente, se observó una disminución de la proporción de LMEs autorizadas y disminución de los días de procesamiento.

Los tiempos de procesamiento para cada año distribuyeron asimétricamente, concentrando el procesamiento de la mayoría de las LMEs antes de los 60 días para los años 2015 a 2017 —antes de los 60 días para diciembre 2015 y antes de los 40 días para diciembre 2016 y 2017—. Para diciembre 2018, utilizando el SPCM, las LMEs fueron procesadas antes del mes (Figura 2).

Las curvas de Kaplan Meier (Figura 3) mostraron un tiempo de procesamiento menor —es decir una tasa de procesamiento más rápida— para el año 2018, en comparación con los años anteriores; las diferencias son significativas (prueba de log-rank, valor p <0,001).

Tanto en el modelo de regresión de Cox crudo, como en el modelo de regresión de Cox ajustado —relación ajustada por potenciales confusores— se observó una tasa de procesamiento de LMEs significativamente más rápida bajo el SPCM (LMEs procesada en diciembre de 2018) (Tabla 2). La tasa de procesamiento del año 2018 fue 5,5 veces más rápida que la del año 2015, 1,8 veces más rápida que la del año 2016 y 1,7 veces más rápida que la del año 2017, ajustando por el efecto de la razón diaria de LMEs recibidas y procesadas, el sexo y edad del trabajador, y el diagnóstico y duración de la LME.

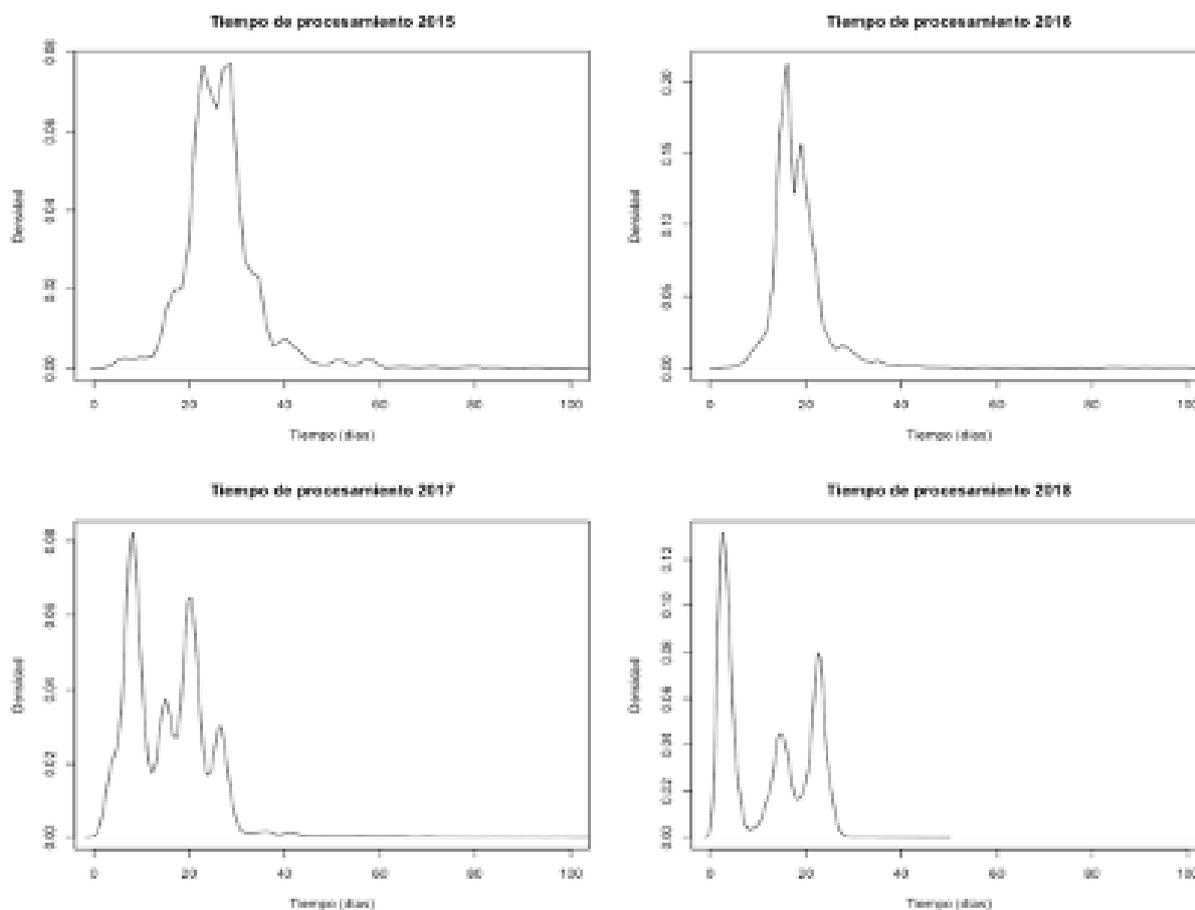
En el modelo ajustado, también se observó el efecto de otras variables en el tiempo de procesamiento de las LMEs, tales como el ratio diario de recibidas

Tabla 1. Características de las LMEs según año en COMPIN RM

		2015	2016	2017	2018
N		64569	72824	78160	96273
Licencias recibidas diariamente (mediana [RIC])*		3265 [2702; 5142]	3882 [2751; 4547]	4766 [3124; 6322]	4920 [4489; 5841]
Licencias procesadas diariamente (mediana [RIC])*		2558 [1928; 3945]	3095 [2178; 4216]	2704 [1759; 6133]	3181 [2104; 5097]
Razón diaria recibidas/procesadas (mediana [RIC])*		1,37 [0,83; 2,05]	1,12 [0,65; 1,73]	1,46 [0,87; 3,12]	1,68 [0,95; 1,99]
Nro. de contralores diarios (mediana [RIC])*		9 [6; 10]	9 [8; 11]	9 [7; 10]	12 [11; 13]
Edad (mediana [RIC])*		38 [29; 50]	38 [29; 50]	38 [29; 51]	38 [29; 50]
Sexo (%)*	femenino	41746 (64,7)	47310 (65,0)	50991 (65,2)	64265 (66,8)
	masculino	22823 (35,3)	25514 (35,0)	27169 (34,8)	32008 (33,2)
Días de licencia (mediana [RIC])*		7 [3; 15]	8 [4; 15]	9 [4; 15]	11 [4; 15]
Diagnóstico CIE-10 (%)*	osteomuscular	15417 (23,9)	17858 (24,5)	18978 (24,3)	21883 (22,7)
	mental	12035 (18,6)	15586 (21,4)	17396 (22,3)	27253 (28,3)
	respiratoria	6744 (10,4)	6209 (8,5)	6336 (8,1)	7072 (7,3)
	otras	30373 (47,0)	33171 (45,5)	35450 (45,4)	40065 (41,6)
Tipo de pronunciamiento de la licencia (%)*	autorizada	62143 (96,2)	69598 (95,6)	74677 (95,5)	87493 (90,9)
	rechazada	1811 (2,8)	2268 (3,1)	2346 (3,0)	4477 (4,7)
	ampliada	191 (0,3)	187 (0,3)	272 (0,3)	148 (0,2)
	reducida	354 (0,5)	502 (0,7)	582 (0,7)	456 (0,5)
	Pendiente	70 (0,1)	269 (0,4)	283 (0,4)	3699 (3,8)
Tiempo de procesamiento en días (mediana [RIC])*		26 [22; 30]	17 [15; 20]	15 [8; 21]	13 [3; 22]

\*valor p&lt; 0,05

Figura 2. Cien primeros días de procesamiento de LMEs para el periodo 2015-2018.



Los histogramas muestran la distribución del tiempo de procesamiento de las LMEs con menos de 100 días. Si se consideran los primeros 100 días como valor umbral de procesamiento, en el año 2015 un 0,5% de las LMEs se estaban procesando luego de este umbral, en el año 2016 este indicador fue 0,2% y en el año 2017 fue 0,1%. En el año 2018, un 0% de las LMEs estaba pendiente después de los 100 días; de hecho, un 99,8% de las LMEs fueron procesadas antes del primer mes.

y procesadas, el sexo del trabajador, el diagnóstico de la LME y los días de duración. Por cada aumento en el ratio diario de recibidas y procesadas, por cada día más de LME y por cada año más de edad, el procesamiento era más lento. Las LMEs de trabajadores de sexo masculino eran procesadas con un 2% más de rapidez. Las LMEs por causas mentales eran procesadas más lentamente que las osteomusculares y las LMEs por causas respiratorias eran procesadas más rápidamente que las osteomusculares.

Si solo se consideraran las LMEs que tuvieron tipo de pronunciamiento autorizado —aquellas que

luego de ser evaluadas por la RNA pasaron a firma institucional para aprobar el pago del subsidio— la velocidad de procesamiento de las LMEs del SPCM es más rápida que la CM realizada en los años 2015 al 2017 (5,9; 1,9; y 1,8 veces respectivamente). Similarmente, si solo se consideran las LMEs que no tuvieron tipo de pronunciamiento autorizado en el análisis, la velocidad de procesamiento media del año 2018 mostró ser mayor que el resto de los años 2015 al 2017 (2,5; 2,1; y 1,2 veces respectivamente) (Tabla 2).

Tabla 2. Modelos de regresión de Cox para evaluar las tasas de procesamiento de todas las LMEs

			RTPc	IC 95%		RTPa	IC 95%	
Todas la LMEs	Año	2018	Ref.	-		Ref.	-	
		2015	0,230	0,188	0,282	0,182	0,147	0,226
		2016	0,568	0,479	0,673	0,542	0,456	0,643
		2017	0,623	0,454	0,856	0,577	0,416	0,799
		Razón diaria recibidas/procesadas		0,995	0,994	0,996		
	Edad en años				0,999	0,998	0,999	
	Sexo	femenino				Ref.	-	
		masculino				1,023	1,009	1,038
	Diagnóstico CIE-10	osteomuscular				Ref.	-	
		mental				0,864	0,828	0,901
		respiratoria				1,060	1,028	1,093
		otra				1,125	1,097	1,153
Nro. de días de licencia				0,987	0,980	0,993		
LMEs con pronuncia- miento autorizado	Año	2018	Ref.	-	Ref.	-		
		2015	0,209	0,170	0,258	0,170	0,137	0,212
		2016	0,551	0,463	0,655	0,533	0,448	0,635
		2017	0,589	0,424	0,819	0,555	0,396	0,776
		Razón diaria recibidas/procesadas		0,995	0,994	0,996		
	Edad en años				0,999	0,998	0,999	
	Sexo	femenino				Ref.	-	
		masculino				1,014	1,000	1,029
	Diagnóstico CIE-10	osteomuscular				Ref.	-	
		mental				0,883	0,844	0,925
		respiratoria				1,042	1,013	1,073
		otra				1,112	1,086	1,140
Nro. de días de licencia				0,987	0,981	0,993		
LMEs con pronun- ciamiento distinto de autorizado	Año	2018	Ref.	-	Ref.	-		
		2015	0,381	0,312	0,466	0,398	0,321	0,494
		2016	0,421	0,352	0,503	0,468	0,385	0,568
		2017	0,638	0,537	0,758	0,805	0,665	0,973
		Razón diaria recibidas/procesadas		0,996	0,995	0,997		
	Edad en años				1,001	0,999	1,002	
	Sexo	femenino				Ref.	-	
		masculino				1,013	0,977	1,052
	Diagnóstico CIE-10	osteomuscular				Ref.	-	
		mental				0,964	0,921	1,008
		respiratoria				1,138	0,982	1,318
		otra				1,021	0,978	1,065
Nro. de días de licencia				1,011	1,006	1,016		

## DISCUSIÓN

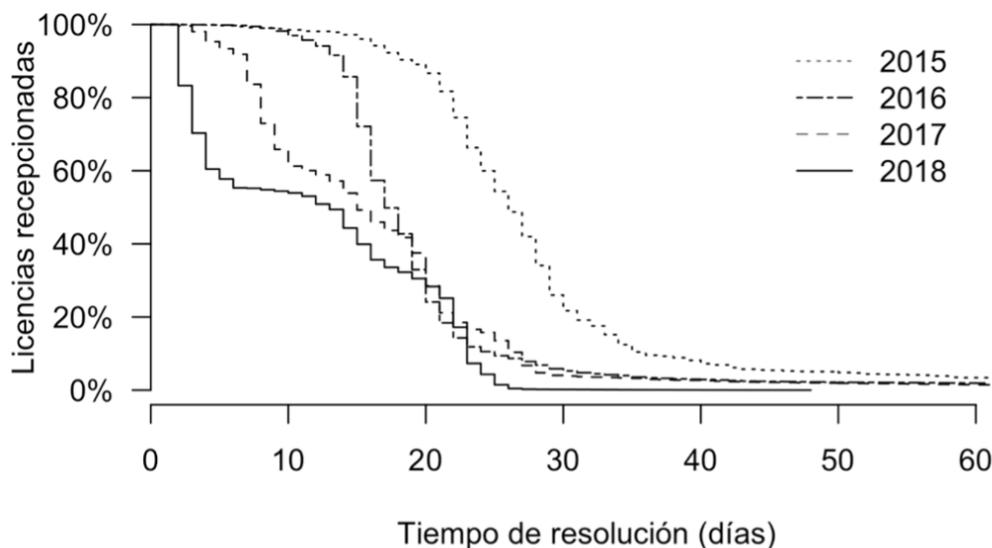
La implementación de la RNA en la contraloría de las LMEs redujo significativamente los tiempos de resolución (Figura 3) lo que supone un acceso oportuno al pago asociado. El SPCM permitió aumentar la velocidad global de procesamiento de las LMEs, mejorando tanto los tiempos de las LMEs que fueron examinadas por la RNA así como también las que sólo fueron examinadas por CM. Esto puede observarse en los resultados que comparan las LMEs con tipo de pronunciamiento autorizado —LMEs que en el mes de diciembre 2018 fueron mayormente procesadas por el SPCM— con los resultados obtenidos con LMEs con otro tipo de procesamiento.

La mayor eficiencia en el procesamiento de LMEs del SPCM permitió disminuir el tiempo de procesamiento; no obstante, dado que los contralores contaban con mayor tiempo para revisar las LMEs de mayor complejidad sumado a la cantidad de LMEs que fueron derivadas desde la RNA a una re-revisión por CM tradicional, el porcentaje de LMEs pendientes aumentó en diciembre de 2018 (Tabla 1). Las LMEs pendientes requieren de documentos adicionales

para su resolución tales como informes del médico tratante, resultados de exámenes, peritajes clínicos, visitas domiciliarias, entre otras acciones. Considerando que un porcentaje de LMEs no lograba ser vista oportunamente antes de la implementación del SPCM, algunas LMEs no lograban ser clasificadas como pendientes a pesar de serlo, lo que subestimaba el porcentaje de LMEs pendientes. En ese sentido, la implementación del SPCM debería mejorar la calidad de la CM y la focalización de esfuerzos para detectar oportunamente las emisiones de LMEs potencialmente abusivas.

Los resultados no solo evidenciaron una mejoría en los tiempos de procesamiento de las LMEs bajo el SPCM (450% más rápido que el 2015, 80% más rápido que el 2016 y 70% más rápido que el 2017), sino que también mostraron que la edad y el sexo del trabajador, el diagnóstico y tiempo de duración de la LME y la razón diaria de LMEs recibidas y procesadas tuvieron efecto sobre la velocidad de procesamiento. Lo anterior podría explicarse por diversas razones; en el caso de la edad, la LMEs de gente más joven son mayoritariamente de resolución rápida, puesto que generalmente se trata de patologías

Figura 3. Curvas de Kaplan Meier comparando el tiempo de procesamiento hasta los 60 días.



La curva continua representa la velocidad de procesamiento de las LMEs examinadas por el SPCM; esta cayó rápidamente durante los primeros 5 días y luego disminuyó paulatinamente hasta llegar a casi 0% de LMEs sin procesar a los 25 días. Las curvas discontinuas representan la velocidad de procesamiento de las LMEs recibidas en los meses de diciembre de los años 2015 al 2017 que fueron examinadas por CM tradicional.

agudas autolimitadas, además de tratarse de pacientes con menos comorbilidades lo que disminuye la complejidad del cuadro. El aumento del tiempo de procesamiento de algunas licencias, en particular en el caso de LM de mayor duración en días y de las LM con diagnósticos de la esfera de salud mental, se explica principalmente porque se trata de licencias de mayor complejidad, que requieren de mayor análisis y en muchas ocasiones de acciones adicionales como la solicitud de informes médicos o peritajes. Esto explica además los mayores tiempos de pronunciamiento de las LM emitidas para mujeres, puesto que el 68% de las licencias médicas de patología de origen mental corresponden a mujeres<sup>5</sup>.

Cabe destacar que la emisión de LMEs ha presentado un aumento sostenido durante los años evaluados, excediendo la capacidad de procesamiento de la COMPIN. Dado lo anterior, en los últimos años se han implementado diversas medidas que han permitido optimizar el trabajo de la contraloría médica (aumento de la dotación de médicos, optimización de los recursos administrativos, etc.), mitigando parcialmente la carga de procesamiento de LMEs. Sin embargo, la implementación de la RNA en los procesos de CM, ha mostrado ser una medida costo-efectiva para catalizar significativamente los tiempos de procesamiento.

Por otro lado, la mejora en el tiempo de procesamiento de las LMEs podría disminuir el número de reclamos contra la COMPIN<sup>22</sup>, contribuyendo con el aumento de la satisfacción usuaria; aunque esto no fue medido, se especula que esto podría revertir la opinión negativa de los usuarios respecto de esta institución. Lo anterior es consistente con la Ley de derechos y deberes de los pacientes<sup>23</sup> y con la gestión en salud centrada en las personas. Existen otras experiencias publicadas que muestran mejoras en la satisfacción usuaria<sup>24,25</sup> al aplicar tecnologías de AM, sin embargo se requiere más investigación para profundizar este aspecto.

En relación a la implementación de la RNA, esta tuvo como objetivo clasificar LMEs como aprobadas o a revisión, buscando minimizar los errores de clasificación para las LMEs aprobadas y maximizando la detección correcta de las LMEs enviadas a revisión para ser analizadas por los contralores. Los procesos de entrenamiento, explotación y validación de la RNA permitieron: 1. estandarizar criterios de clasificación entre los contralores, y 2. encontrar patrones de datos consistentes con posibles abusos, los cuales no estaban siendo considerados durante la CM.

La utilización de AM para resolver problemas sanitario ha mostrado beneficios, como la detección de fraude en el uso del sistema de salud<sup>26</sup> o la predicción de bancarrota de empresas privadas del sector sanitario<sup>22</sup>. Aun cuando este estudio tiene limitaciones, como el uso de datos secundarios o el uso arbitrario del mes de diciembre como periodo de comparación, los resultados obtenidos son consistentes con la experiencia de AM en salud y respaldan la utilidad de este tipo de tecnologías para complementar los procesos que involucran un gran volumen de datos.

Es importante señalar que en Chile no existe evidencia publicada sobre modelos de CM apoyada por RNA y su efectividad en condiciones pragmáticas. Existen algunos estudios previos sobre LMs —principalmente con un enfoque predictivo<sup>25,26</sup>—, sin embargo esta es la primera investigación que busca mostrar los beneficios de tecnologías como las RNAs en el procesamiento de LMs, con un enfoque pragmático, es decir, en condiciones reales.

En cuanto al trabajo futuro, se considera el re-entrenamiento periódico de la RNA, con el objetivo de incorporar al SPCM nuevos patrones de clasificación —nuevo conocimiento experto y/o patrones detectados por la RNA—, así como la incorporación de criterios socio-demográficos, laborales, entre otras variables. El desarrollo de RNA que soporta el SPCM ha sido limitado a un tipo específico de LMEs, por lo que ampliar el espectro de evaluación podría acelerar aún más los tiempos de procesamiento.

## REFERENCIAS BIBLIOGRÁFICAS

1. Organización Internacional del Trabajo. Hechos concretos sobre la seguridad social [Internet]. Ginebra: OIT; 2001 [consultado en enero 2019]. p. 1–2. Disponible en: [https://www.ilo.org/wcmsp5/groups/public/---dgreports/---dcomm/documents/publication/wcms\\_067592.pdf](https://www.ilo.org/wcmsp5/groups/public/---dgreports/---dcomm/documents/publication/wcms_067592.pdf)
2. Benavides P, Leonardo S, Roa G, Jones I, Daniela J, Herrera S. Subsidios por incapacidad laboral por enfermedad y medicina curativa: estado actual y desafíos Estudios de Finanzas Públicas [Internet]. Santiago; 2011 [consultado el 13 feb 2019]. Disponible en: [www.dipres.cl](http://www.dipres.cl)
3. Chávez M. Economía y Negocios: Fonasa pidió \$57 mil millones a Hacienda para pagar 415 mil licencias médicas retrasadas [Internet]. El Mercurio. 2018 [consultado el 13 feb 2019]. Disponible en: <http://>

- www.economiaynegocios.cl/noticias/noticias.asp?id=476287
4. Fondo Nacional de Salud(Chile). Cuenta Pública Participativa Fonasa Gestión 2017 [Internet]. Santiago, Chile; 2017 [consultado en enero 2019]. Disponible en: <https://www.fonasa.cl/sites/fonasa/institucional/archivos>
  5. Fondo Nacional de Salud (Chile). Estadísticas 2016 Fonasa - Superintendencia de Salud [Internet]. Santiago, Chile; 2016 [consultado en enero 2019]. Disponible en: <https://www.fonasa.cl/sites/fonasa/institucional/archivos>
  6. Chile. Congreso Nacional. Cámara de Diputados. Modifica diversos textos legales en lo que respecta a las facultades de las Isapres para modificar o rechazar las licencias médicas y al pago del subsidio por incapacidad laboral. Santiago, Chile; 2018.
  7. Chile. Ministerio de Salud. Aprueba reglamento de autorización de licencias médicas por las COMPIN e Instituciones de salud previsional [Internet]. Chile: Biblioteca del Congreso Nacional de Chile; 1984 [consultado en enero 2019] p. 1–16. Disponible en: <https://www.leychile.cl/Navegar?idNorma=7281&idVersion=2013-04-27>
  8. Chile. Ministerio de Salud. COMPIN. Comisión de Medicina Preventiva e Invalidez [Internet]. 2019 [consultado el 13 feb 2019]. Disponible en: <http://compin.redsalud.gob.cl/>
  9. 9. Chávez M. Economía y Negocios: En cuatro meses, Salud pondrá en marcha plan que acelera el pago de licencias médicas [Internet]. El Mercurio. 2018 [consultado el 13 de feb 2019]. Disponible en: <http://www.economiaynegocios.cl/noticias/noticias.asp?id=465158>
  10. Tobar F. Maquinas que aprenden. Rev BITS Ciencias. 2017;15:36–43.
  11. Brady ES, Leider JP, Resnick BA, Natalia Alfonso Y, Bishai D. Machine-learning algorithms to code public health spending accounts. Public Health Rep. 2017;132(3):350–6.
  12. Arsanjani R, Dey D, Shalev a, Khachatryan T, Hayes S, Fish M, et al. Improved accuracy of myocardial perfusion spect for prediction of revascularization by machine learning in a large population. J Am Coll Cardiol. 2014;63(12):A1229.
  13. Chiavegatto Filho ADP, dos Santos HG, do Nascimento CF, Massa K, Kawachi I. Overachieving Municipalities in Public Health. Epidemiology [Internet]. 2018 [consultado el 13 de feb 2019];29(6):836–40. Disponible en: <http://insights.ovid.com/crossref?an=00001648-201811000-00012>
  14. Trujillano J. b f, Sarria-Santamera A. d, Esquerda A., Badia M., Palma M., March J. Approach to the methodology of classification and regression trees. Gac Sanit [Internet]. 2008 [consultado el 15 de feb 2019];22(1):65–72. Disponible en: <http://www.scopus.com/inward/record.url?eid=2-s2.0-39349118240&partnerID=40&md5=eae38e7e72b7a66b59500840a8b53990>
  15. Sorribas A, Rodríguez A, March J, Badia M, Trujillano J. Aplicación de las redes neuronales artificiales para la estratificación de riesgo de mortalidad hospitalaria. Gac Sanit. 2003;17(6):504–11.
  16. Chile. Ministerio de Salud. Establece normas para el otorgamiento y tramitación de la licencia médica electrónica [Internet]. Chile: Biblioteca del Congreso Nacional de Chile; 2006 [consultado el 15 de feb 2019] p. 1–4. Disponible en: <https://www.leychile.cl/Navegar?idNorma=253860&idVersion=2006-10-06>
  17. Chile. Superintendencia de Seguridad Social. Circular 2773. Imparte instrucciones sobre la tramitación de la licencia médica electrónica por parte de las cajas de compensación de asignación familiar [Internet]. Santiago, Chile; 2011 [consultado el 15 de feb 2019]. Disponible en: <https://www.suseso.cl/612/w3-article-3062.html>
  18. Chile. Superintendencia de Seguridad Social; Chile. Superintendencia de Salud. Intendencia de Fondos y Seguros Previsionales de Salud. Circular 2338. Circular IF 32. Imparte instrucciones sobre otorgamiento y tramitación de la licencia médica electrónica [Internet]. Santiago, Chile; 2006 [consultado el 15 de feb 2019]. Disponible en: [http://www.observatoriodigital.gob.cl/sites/default/files/circular\\_ndeg\\_2338.pdf](http://www.observatoriodigital.gob.cl/sites/default/files/circular_ndeg_2338.pdf)
  19. World Health Organization. List of Official ICD-10 Updates [Internet]. World Health Organization; 2017 [consultado el 13 feb 2019]. Disponible en: <https://www.who.int/classifications/icd/icd10updates/en/>
  20. Carrillo L, Jadue J. Bioestadística. Taucher E, editor. Santiago, Chile: OchoLibros; 2014. 332 p.
  21. Chile. Ministerio de Salud. Estudio de Opinión de Usuarios.Sistema de Salud Año 2016 [Internet]. Santiago, Chile; 2016 [consultado el 13 de feb 2019]. Disponible en: <http://www.supersalud.gob.cl/docu>

- mentacion/666/w3-article-14189.html
22. Chile. Ministerio de Salud. Ley Nro. 20584. Regula los derechos y deberes que tienen las personas en relación con acciones vinculadas a su atención en salud [Internet]. Chile: Biblioteca del Congreso Nacional de Chile; 2015 [consultado el 13 de feb 2019] p. 1–16. Disponible en: <https://www.leychile.cl/N?i=1039348&f=2015-12-04&p=>
  23. Priyanga P, Naveen NC. Analysis of Machine Learning Algorithms in Health Care to Predict Heart Disease. *Int J Heal Inf Syst Inform* [Internet]. 2018 [consultado el 13 de feb 2019];13(4):82–97. Disponible en: <https://doi.org/10.4018/IJHISI.2018100106>
  24. Chiu MC, Ko LW. Develop a personalized intelligent music selection system based on heart rate variability and machine learning. *Multimed Tools Appl*. 2017;76(14):15607–39.
  25. Navarro A, Casanovas G, Alvarado S, Moriña D. Analyzing recurrent events when the history of previous episodes is unknown or not taken into account: proceed with caution. *Gac Sanit*. 2016;31(3):227–34.
  26. Gutiérrez J, Jiménez M, Escalera L. Intervenciones eficaces para reducir el absentismo del personal de enfermería hospitalario. *Gac Sanit*. 2013;27(6):545–51.