

UNIVERSIDAD DE CHILE
FACULTAD DE MEDICINA
ESCUELA DE POSTGRADO



“Modelo Predictivo de la Demanda de Atención de Urgencia en Chile: una Aplicación de Google Trends”

SAMUEL OSVALDO CONTRERAS VALDÉS

**TESIS PARA OPTAR AL GRADO DE
MAGÍSTER EN INFORMÁTICA MÉDICA**

Director de Tesis: Prof. Dra. Paulina Pino

Co- Director de Tesis: Prof. Dr. Rodrigo Martínez

(2018)

UNIVERSIDAD DE CHILE
FACULTAD DE MEDICINA
ESCUELA DE POSTGRADO

INFORME DE APROBACION TESIS DE MAGISTER

Se informa a la Comisión de Grados Académicos de la Facultad de Medicina, que la Tesis de Magister presentada por el candidato

SAMUEL OSVALDO CONTRERAS VALDÉS

ha sido aprobada por la Comisión Informante de Tesis como requisito para optar al Grado de Magister en Informática Médica en el Examen de Defensa de Tesis rendido el día (día, mes, año)

.....
Prof. Dra. Paulina Pino
Director de Tesis

.....
Prof. Dr. Rodrigo Martínez
Co-Director de Tesis

COMISION INFORMANTE DE TESIS

.....
Prof. Dra. María
Soledad Martínez

.....
Prof. Dr. Ángel Jiménez

.....
Prof. Dr. Nelson Baloian

.....
Prof. Dr. Steffen Härtel
Presidente Comisión

Esta tesis está dedicada a mi madre, Margarita Valdés, que ha entregado su vida porque tenga la mejor educación y sea una gran persona, sin ella no habría logrado nada en mi vida. Ella siempre creyó en mí y me dio la confianza para lograr mis sueños.

Agradezco a mis amigos, especialmente a Pamela Arias y Marusella Lam, que fueron demasiado importantes en este proceso, siempre se preocuparon por mí y me aconsejaron y ayudaron de la mejor manera en los momentos en que necesité su apoyo.

Tabla de contenido

RESUMEN.....	1
ABSTRACT	3
1. Introducción	5
2. Marco Teórico	7
2.1. Proceso de atención de un Servicio de Urgencia (SU) en Chile.....	7
2.2. Enfermedades respiratorias en Chile	9
2.3. Problema de la sobredemanda en los SU.....	10
2.4. Modelos predictivos de atenciones en los SU	12
2.5. Uso de la Tecnología de Información (TI) en Salud en Chile.....	14
2.6. Google Trends	15
2.7. Origen de los Datos de Google Trends	17
2.8. Google Correlate.....	18
2.9. Google Flu Trends	19
2.10. Modelo SARIMA.....	20
2.11. Modelo ARIMA con una variable exógena (ARIMAX).....	22
2.12. Problema Metodológico de este Estudio	22
2.13. Test de causalidad de Granger	23
3. Hipótesis	24
4. Objetivo General	24
5. Objetivos específicos	24
6. Métodos.....	25
6.1. Diseño	25
6.2. Población.....	25
6.3. Variables	26
6.4. Análisis modelo SARIMA.....	27

6.5.	Búsqueda de los términos relacionados	28
6.6.	Análisis modelo ARIMAX.....	29
6.7.	Test de causalidad de Granger	29
7.	Resultados.....	31
7.1.	Modelo SARIMA	31
7.2.	Búsqueda de términos relacionados.....	37
7.3.	Modelo ARIMA con una variable exógena (ARIMAX)	39
7.4.	Test de causalidad de Granger	42
8.	Discusión.....	43
8.1.	Modelo SARIMA	43
8.2.	Búsqueda de términos relacionados.....	45
8.3.	Modelo ARIMA con una variable exógena (ARIMAX)	46
8.4.	Test de causalidad de Granger	48
8.5.	Discusión final	49
9.	Conclusión.....	51
10.	Bibliografía	52

TABLA DE FIGURAS

Figura 1: Modelo BPM del proceso general de atención en un Servicio de Urgencia	8
Figura 2: Porcentaje de atenciones por causas respiratorias respecto de atenciones totales por semana estadística en los SU de Chile, año 2016.	9
Figura 3: Predicción de Atenciones de Urgencia Totales por semana estadística, utilizando el modelo ARIMA (2, 0, 1)(2, 0, 0).	32
Figura 4: Predicción de Atenciones de Urgencia en UEH por semana estadística, utilizando el modelo ARIMA (3, 0, 2).	33
Figura 5: Predicción de Atenciones de Urgencia en SAPU por semana estadística, utilizando el modelo ARIMA (3, 0, 3).	34
Figura 6: Predicción de Atenciones de Urgencia en SAR por semana estadística, utilizando el modelo ARIMA (2, 1, 0).....	35
Figura 7: Series de tiempo “Atenciones por causas respiratorias” (en azul) y “bequium” (en rojo), durante los años 2014 a 2016.	38
Figura 8: Predicción de Atenciones de Urgencia por semana estadística utilizando el modelo ARIMAX (2, 1, 3), con el término de búsqueda “jarabe” como variable exógena.	40
Figura 9: Predicción de Atenciones de Urgencia por semana estadística utilizando el modelo ARIMA (1, 0, 4), con la suma de las 10 primeras búsquedas como variable exógena (ARIMAX).	41

ÍNDICE DE TABLAS

Tabla 1: Orden del modelo SARIMA probados para la serie de tiempo “Atenciones totales por causas respiratorias por semana estadística 2014-2016”	31
Tabla 2: Error de la predicción del modelo ARIMA por tipo de establecimiento	35
Tabla 3: Error de la predicción del modelo ARIMA por grupo etario.....	36
Tabla 4: 40 primeras de las 100 búsquedas obtenidas con Google Correlate y su correlación con la serie de tiempo “Atenciones por causas respiratorias” en todos los SU del país, durante los años 2014 a 2016.	37
Tabla 5: Tópicos de las 100 búsquedas mejor correlacionados con las Atenciones por causas respiratorias.....	38
Tabla 6: Errores de la predicción utilizando algunas de las búsquedas encontradas con Google Correlate.	39
Tabla 7: Error de la predicción del modelo ARIMAX para los 10 primeras búsquedas	41
Tabla 8: Test de causalidad de Granger entre la serie de tiempo "Atenciones por causas respiratorias" versus algunas de las búsquedas encontradas.....	42
Tabla 9: Resumen de artículos que evalúan la predicción de visitas a los SU.	44

RESUMEN

Antecedentes: Aglomeraciones y tiempos de espera prolongados de pacientes son problemas frecuentes en los Servicios de Urgencia (SU) de Chile y el mundo. Un modelo predictivo de la demanda permitiría una mejor planificación y distribución de los recursos humanos y físicos (camas, boxes de atención, sala de procedimientos, equipamiento general, etc.) y de esta manera mejoraría el flujo de pacientes y del servicio en general. El uso de internet, cada vez más masivo, podría ser utilizado como herramienta para predecir o anticipar la necesidad de los pacientes evitando aglomeraciones y sus problemas asociados, lo cual, permitiría sacar provecho de esta herramienta para anticiparse.

Objetivo: Estimar si en Chile, las consultas de usuarios de Google permiten predecir la demanda de atención de urgencia por enfermedades respiratorias en los UEH, SAPU y SAR del país.

Método: Estudio retrospectivo, relacionando el registro de búsquedas en Google consistentes con enfermedades respiratorias, con el registro de atenciones de urgencia de tales enfermedades. Se efectuó un análisis de series de tiempo mediante los modelos SARIMA y ARIMAX, para valorar el grado de correlación existente entre ambas series y la capacidad predictiva de la serie de tiempo "Atenciones". Adicionalmente se usó el modelo de causalidad de Granger, para evaluar la probabilidad de que la relación se de en el sentido de la hipótesis o se trate de causalidad reversa.

Relevancia: El uso de información espontánea de los usuarios podría llegar a configurar un instrumento útil para anticipar eventos tales como aglomeración de pacientes que consultan por causas respiratorias a los SU de Chile, permitiendo reorganizar los recursos materiales y humanos en los SU, mejorando la atención de pacientes.

Resultados: El modelo SARIMA (2, 0, 1)(2, 0, 0)[7], fue el que entregó la mejor predicción para la serie de tiempo “Atenciones” (Error Porcentual Absoluto Medio (MAPE) de 1,46% y 17,87%, para el grupo de validación y prueba, respectivamente). De las 100 búsquedas encontradas con Google Correlate, el 100% de ellas tenía relación directa o indirecta con las enfermedades respiratorias, en su mayoría fármacos usados para tratar este tipo de enfermedades. El modelo ARIMAX que arrojó la mejor predicción fue al usar la suma de las 10 primeras búsquedas como variable exógena, con un MAPE de 0,97% y 3,54% para el grupo de validación y prueba, respectivamente. El test de Granger mostró una causalidad bidireccional para las dos series de tiempo analizadas.

Conclusión: El uso de las búsquedas en Google permitió elaborar un modelo predictivo de la demanda por enfermedades respiratorias en los SU de Chile. Basado en el MAPE, la suma de las 10 primeras búsquedas fue elegida como la variable exógena del modelo ARIMAX. Sin embargo, aún es necesario evaluar el modelo bajo patrones de frecuencias inhabituales de enfermedades respiratorias. Además, no fue posible determinar si los pacientes realizan la búsqueda en Google antes o después de la atención en el SU, cuyo impacto debe ser aclarado previo a la implementación del modelo.

ABSTRACT

Background: Overcrowding and extended waiting times of patients are common problems in Emergency Department (ED) in Chile and in the world. A forecasting model of demand, would allow a better planning and distribution of both human and material resources (beds, examination and procedure rooms, general equipment), improving the patients flow and service. The use of internet, every time more massive, could be used as a tool to predict the patient's needs, limiting overcrowding and its problems, which would allow to take advantage of this tool to foresee the problems that generate overcrowding.

Objective: Estimate if in Chile, search in Google could predict the number of patient's visits for respiratory diseases in UEH or primary care (SAPU or SAR) ED.

Methods: Retrospective analysis, evaluating the search behavior in Google related to respiratory diseases, with the amount of ED visits for those diseases. A time series analysis was performed using SARIMA and ARIMAX models, assessing the correlation grade between the two series and forecasting performance of ED "Visits" time series. Additionally a Granger causality test was used to evaluate if the two time series were related in the direction of the hypothesis or if it was a reverse causality case.

Relevance: The use of spontaneous information of users could become a useful tool to anticipate overcrowding of patients with respiratory causes in ED in Chile, allowing the reorganization of human and material resources, improving the patient's care.

Results: The SARIMA (2, 0, 1)(2, 0, 0)[7] model, generated the best prediction (Mean Absolute Percentage Error (MAPE) 1,46% and 17,87% for the training and test groups, respectively) for time series “*Visits*”. Of a hundred searches found with google correlate, a 100% was directly or indirectly related to respiratory diseases, most of them regarding to treatment. The best fit of ARIMAX model was when the sum of the ten first searches was used as an exogenous variable, with a MAPE of 0,97% and 3,54% for the training and test groups, respectively. The Granger test showed bidirectional causality for the two time series analyzed.

Conclusion: The use of Google searches allowed the design of a forecasting model for respiratory related patient´s visits to the ED in Chile. Based on the MAPE, the sum of the 10 first searches was chosen as the exogenous variable of the ARIMAX model. However, it is still necessary to evaluate this model under unusual frequency patterns of respiratory diseases, in order to study whether other factors could influence the results. Furthermore, it was not possible to determine whether patients performed the Google searches before or after visiting the ED, the impact of which needs to be clarified before implementation.

1. Introducción

Las aglomeraciones en los Servicios de Urgencia (SU) son un problema de salud pública a nivel mundial, que afecta tanto a pacientes como al personal de salud(1,2). Estos problemas provocan retardos en el diagnóstico, aumento en la mortalidad(3,4), errores en la atención, retardos en el inicio del tratamiento de enfermedades críticas, disminución en la capacidad de camas y disminución de la seguridad del paciente, entre otros(5).

En Chile, de acuerdo al Departamento de Estadísticas e Información en Salud (DEIS) del Gobierno, las consultas a los SU en Unidades de Emergencia Hospitalaria (UEH), Servicios de Atención Primaria de Urgencia (SAPU) y Servicios de Atención Primaria de Urgencia de Alta Resolutividad (SAR) han aumentado significativamente en los últimos años, llegando a más de 17 millones de consultas el año 2016(6), con un aumento de alrededor de 5% anual(7). Además la tasa de utilización de las UEH al año 2015 era de 571/1000hab/año, la tercera más alta de los países de la OCDE(15).

La habilidad de predecir las visitas de pacientes a los SU, es crucial para diseñar estrategias para evitar las aglomeraciones.

Los modelos predictivos más reportados, se basan en modelos matemáticos como la regresión, que por lo general es lineal, entre el número de visitas y distintas variables independientes como el día de la semana, factores climáticos, redes sociales o búsquedas en internet entre otros, o como los análisis de series de tiempo,

donde se tratan el número de visitas como series de tiempo y se predicen valores futuros utilizando valores pasados(1).

Existe evidencia de que las redes sociales pueden ser empleadas para predecir el número de visitas a los SU; la herramienta Google Flu Trends ha sido usada para predecir el número de visitas a los SU de pacientes con Influenza(8,9) y la red social Twitter mediante la búsqueda de términos específicos escritos por los usuarios fue capaz de predecir las visitas de pacientes con asma a los SU de Estados Unidos(10).

Chile es el país líder en la región en el uso de tecnologías de la información(11) con más de 84% de la población con acceso a Internet fijo o móvil(12), por lo que un estudio que utilice las tecnologías existentes para predecir las visitas a los SU en el país, es posible.

Respecto al problema de la sobredemanda en los SU de Chile, no existen estadísticas específicas relacionadas a la saturación de estos, sin embargo, el aumento sostenido de pacientes en estos servicios, sumado a la escasez de camas en los hospitales, hace pensar que la situación es similar a la de otros países(13).

El presente trabajo utiliza la información de las visitas a los SU por causas respiratorias de los hospitales de Chile durante los años 2014 a 2016, y las relaciona con las búsquedas en internet de los usuarios en el motor de búsqueda Google mediante la herramienta Google Trends y Google Correlate para elaborar un modelo que permita predecir las aglomeraciones.

2. Marco Teórico

2.1. Proceso de atención de un Servicio de Urgencia (SU) en Chile

Los SU representan un elemento clave dentro de la gestión hospitalaria. Son unidades donde las prestaciones de salud se otorgan las 24 horas del día a pacientes de diferente complejidad y que representan una proporción significativa de las admisiones en las redes asistenciales(14).

El proceso general de atención en un servicio de urgencia se inicia con la admisión del paciente, familiar o equipo de salud que lo acompaña, siempre y cuando se trate de un paciente no grave, en cuyo caso el paciente será enviado directamente a evaluación médica en la sala de reanimación. Luego de la admisión, el paciente ingresa al selector de demanda, cuyo objetivo es categorizar el nivel de urgencia del paciente con la finalidad de determinar qué tan rápido debe ser atendido. Posterior a la categorización, continúa la evaluación médica, proceso en el cual el paciente recibe la atención directa de un profesional de salud. Finalmente se procede a dar el alta al paciente o su hospitalización según corresponda, la Figura 1 muestra el proceso general de atención en un servicio de urgencia.

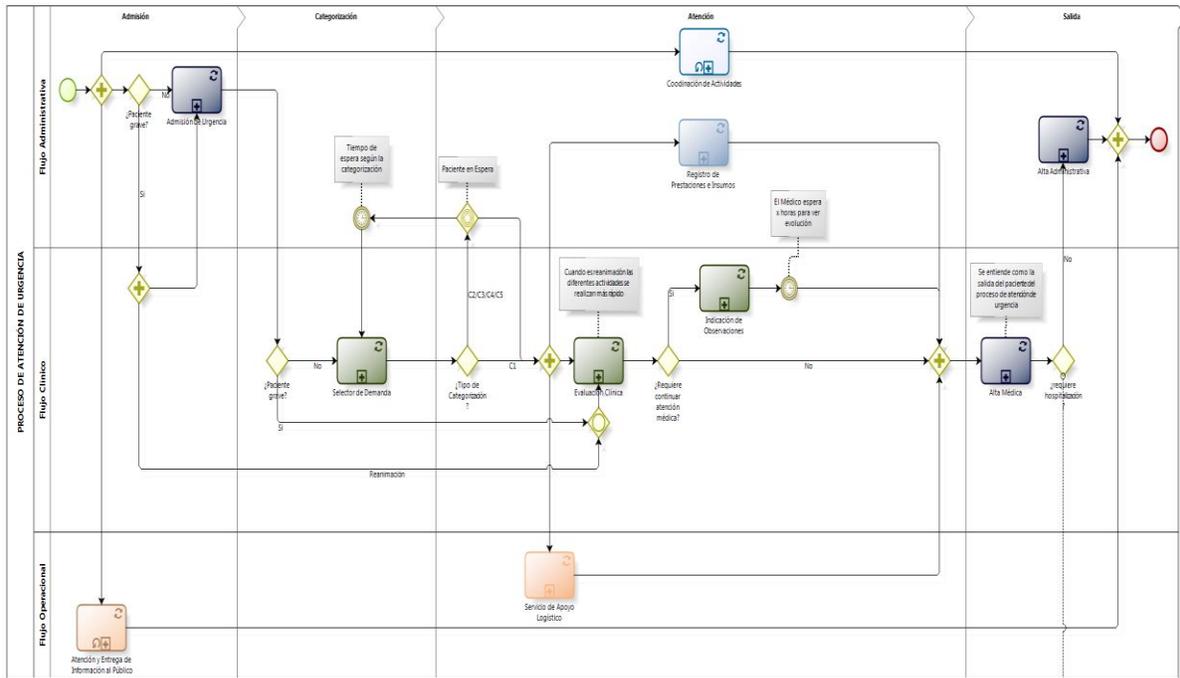


Figura 1: Modelo BPM del proceso general de atención en un Servicio de Urgencia

(Fuente: Consultoría para la Estandarización de Procesos de Redes Asistenciales Ministerio de Salud)

2.2. Enfermedades respiratorias en Chile

Las enfermedades respiratorias representan en promedio aproximadamente el 30% del total de atenciones en los SU de Chile(6), con un aumento en los meses de invierno llegando a alrededor del 44% de las atenciones totales (Figura 2), siendo el 60% de estas, las Infecciones Respiratorias Agudas (IRA) altas (CIE 10 J00 a J06).

En pacientes pediátricos han sido históricamente la principal causa de hospitalización y de consulta en atención primaria y SAPUs, constituyendo más del 60% de las atenciones de urgencia en niños menores de 14 años en período de invierno en los SU(6).

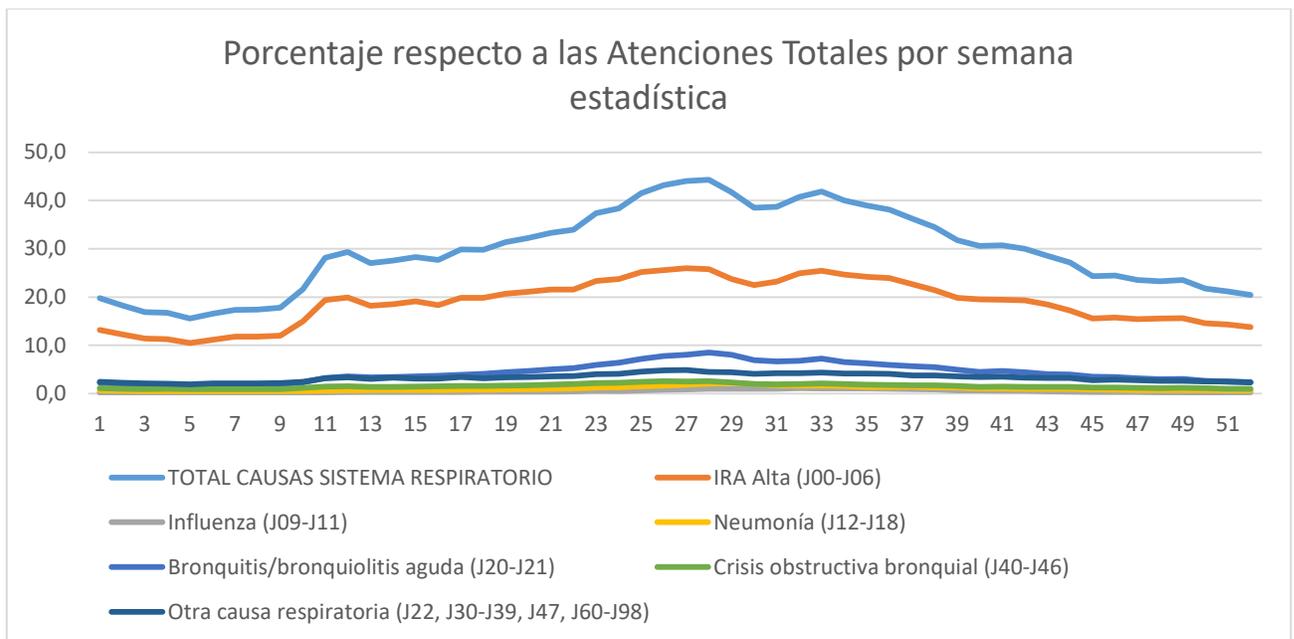


Figura 2: Porcentaje de atenciones por causas respiratorias respecto de atenciones totales por semana estadística en los SU de Chile, año 2016.

Fuente: Elaboración propia en base a datos de Atenciones de Urgencia DEIS MINSAL año 2016

2.3. Problema de la sobredemanda en los SU

La saturación o sobredemanda de los SU se define como un excesivo número de consultas respecto a la capacidad que tiene el SU para atenderlas de manera apropiada y oportuna(13).

El problema de la sobredemanda de los SU es un denominador común en la mayoría de los países y es reconocido como un problema de salud pública global. La sobredemanda afecta tanto a pacientes como al equipo de salud y está asociado a un aumento en la mortalidad(3,4), errores en la atención, retardos en el inicio del tratamiento de enfermedades críticas, disminución en la capacidad de camas y disminución de la seguridad del paciente, entre otros(5).

En Chile el 46% de las atenciones médicas son otorgadas en alguno de los establecimientos de la red de urgencia y la tasa de utilización al año 2015 era de 1100 atenciones/1000habitantes/año de las cuales 571/1000habitantes/año fueron en UEH, siendo la tercera más alta entre los países de la OCDE, muy por sobre países como Canadá (476/1000hab/año), Estados Unidos (437/1000hab/año) o Inglaterra (332/1000hab/año)(15).

Un informe de la Dirección de Presupuestos (DIPRES) del año 2016, señala que el número de pacientes que debe esperar más de 12 horas en los SU para hospitalizarse aumentó de 22,5 en el año 2009 a 34,2% en el año 2013(16). Además, de acuerdo al Departamento de Estadísticas e Información en Salud (DEIS) del Gobierno de Chile, las consultas a los SU en UEH, SAPU y SAR han aumentado

significativamente los últimos años, llegando a más de 17 millones de consultas el año 2016(6), con un aumento de alrededor de 5% anual(7).

Se considera que la sobredemanda se debe, además del aumento del número de atenciones, a que alrededor de 30-50% de las atenciones podrían haberse manejado en niveles de menor complejidad(17).

Otro factor importante para la saturación es muchas veces la carencia de camas disponibles en los hospitales, lo que provoca que los pacientes sean hospitalizados en los SU a la espera de una cama (13).

2.4. Modelos predictivos de atenciones en los SU

Dada la gran relevancia que tiene para un servicio de salud el poder predecir los problemas de sobredemanda de los SU, y de esta manera poder reorganizar los recursos materiales y humanos de mejor manera, existen varios trabajos publicados que abordan este tema(1,10,18).

Las técnicas que se han desarrollado para la predicción de visitas a los SU se pueden dividir principalmente en dos tipos: métodos cualitativos y métodos cuantitativos. Los métodos cualitativos predicen el futuro utilizando usualmente la opinión y el juicio de expertos en campos especializados(19).

Los métodos cuantitativos, por otro lado, se basan en modelos matemáticos los cuales se fundamentan en análisis de datos históricos y asumen que valores del pasado pueden ser usados para predecir datos del futuro. Estos modelos matemáticos son principalmente de dos tipos: análisis de regresión y de series de tiempo(1).

Los análisis de regresión consisten en la búsqueda de una correlación, que por lo general es lineal, entre el número de visitas a los SU, y una o varias variables independientes como el día de la semana, factores climáticos o incluso el uso de redes sociales, búsquedas en internet e ingresos a una determinada página Web(1,10,18).

Los análisis de series de tiempo por otro lado consisten en ver el número de visitas como una serie de tiempo y de esta manera predecir número de atenciones futuras utilizando las del pasado(1).

Las series de tiempo son el tipo de modelo matemático más usado, debido a que tienen la ventaja de ser técnicas confiables y efectivas. Estas pueden ser clasificadas en dos tipos: univariantes y multivariantes, dependiendo si se trabaja con una o más de una variable simultáneamente.

Muchos trabajos han utilizados las series de tiempo para predecir las visitas de pacientes, Tandberg y Qualls, 1994(20), utilizaron métodos estadísticos (medias móviles y descomposición estacional), para predecir el número de pacientes en los SU en cualquier hora de la semana en un hospital universitario de Nuevo México en Estados Unidos. Rotstein y col., 1997(21), desarrollaron un modelo estadístico para un SU de un hospital en Israel basado en series de tiempo de 3 años de datos diarios. Utilizaron un modelo de regresión lineal y 3 tipos de factores estacionales, representando los efectos del día de la semana, el mes del año, y el tipo de día (festivo, medio hábil, o día hábil completo).

Tanto para los análisis de regresión como para las series de tiempo, la metodología de análisis consiste en dividir los datos en dos grupos, utilizando el primero como grupo de entrenamiento y el segundo como grupo de validación. De esta forma se estiman los parámetros del modelo en el grupo de entrenamiento para luego evaluar el desempeño de este en el grupo de validación(1).

Para calcular el desempeño del modelo, se utilizan tres criterios principalmente: el porcentaje de variabilidad (R^2) en análisis de regresión, el error porcentual absoluto medio (MAPE) y el error cuadrático medio (RMSE)(1).

2.5. Uso de la Tecnología de Información (TI) en Salud en Chile

Chile es el país líder en la región en el uso de TI según el Foro Económico Mundial, que en su reporte tecnológico de año 2016 ubica al país en el puesto 38 a nivel mundial y 1ro a nivel Latinoamericano en el uso de las Tecnologías de Innovación en Salud (TI)(11).

La penetración de internet fijo o móvil en Chile llega al 84,1% de la población, siendo la navegación por teléfonos inteligentes la más común (74,9% del total de accesos)(12).

Por otro lado, el uso de las redes sociales también es de gran importancia en el país, con aplicaciones como WhatsApp o Facebook con un 86 y 81% de uso respectivamente, en forma frecuente u ocasional, por parte de la gente que declara conocer esta red social, según la encuesta UC-Adimark 2016. Más atrás aparecen otras aplicaciones como Instagram, Twitter y LinkedIn con un 48, 37 y 32% de uso, respectivamente(22).

2.6. Google Trends

Google Trends es una herramienta de Google Inc. que permite a los usuarios interactuar con las búsquedas realizadas en internet, específicamente en la página Web del buscador Google, es gratuito y accesible públicamente en línea(23). Google Trends analiza una porción de los aproximadamente tres billones de búsquedas diarias en el buscador de Google, y entrega datos en patrones geospaciales y temporales en volúmenes de búsquedas para los términos especificados por el usuario(24). El portal determina la proporción de búsquedas para un término especificado por el usuario, entre todo el volumen de búsquedas en el buscador Google. Cada punto de datos se divide por el total de búsquedas de la región geográfica y el intervalo de tiempo que representa para comparar su popularidad relativa. Luego, los números resultantes se escalan a un intervalo del 0 al 100 en función de la proporción de un tema con respecto a todas las búsquedas sobre todos los temas(23).

El usuario puede especificar el área geográfica de estudio, si es una ciudad un país o el mundo entero (los datos están disponibles para todo el mundo). Además, el usuario puede elegir un período de tiempo de estudio, desde enero del 2004 hasta el presente, dividido por meses o días. El programa permite además que el usuario descargue el resultado de las búsquedas para realizar análisis posteriores.

Otro punto importante es que el usuario puede comparar los resultados de hasta 5 diferentes términos de búsquedas, o un término particular de búsqueda entre áreas geográficas y entre periodos de tiempo determinados. Es posible la búsqueda

de múltiples términos combinados usando el signo “+” y también de términos excluidos usando el signo “-“. Las comillas pueden ser usadas para especificar una búsqueda de una frase exacta. Adicionalmente el usuario puede elegir entre 25 categorías de tópicos específicos para restringir la búsqueda, cada uno con múltiples sub-categorías lo que da un total de más de 300 opciones, Ej. Salud-> Estado de Salud -> Alergia.

Google Trends ha sido usado en muchas publicaciones de investigación relacionados con diversos temas, entre ellos, la Salud(24). En una publicación de Shan Yin y Mona Ho, 2012(25) encontraron una correlación de 0,84 entre las búsquedas en internet de drogas conocidas como “sales de baño” en Estados Unidos al compararlos con los datos del National Poison Database System.

Otro trabajo de Gunn JF y Lester D., 2013(26), pudo relacionar positivamente el volumen de búsquedas en Google de tres términos relacionados al suicidio, con la tasa de suicidios en Estados Unidos en el año 2009.

2.7. Origen de los Datos de Google Trends

Los datos que existen en Google Trends son una muestra imparcial de las búsquedas totales realizadas en Google(23). Existen dos tipos de datos:

- Datos en tiempo real: Es una muestra aleatoria de los datos de los últimos siete días.
- Datos atemporales: Es una muestra aleatoria de los datos desde el año 2004 hasta 36 horas antes de la búsqueda.

Cada vez que un dato ingresa a Google Trends este es categorizado, conectado con un tema en particular y toda la información personal que viene asociada a él se elimina, de acuerdo a lo declarado por Google.

Existen algunos datos que no son incluidos en Google Trends, como los realizados por muy pocos usuarios, búsquedas duplicadas, es decir, las realizadas por la misma persona durante un breve periodo de tiempo, y las búsquedas que tienen caracteres especiales.

2.8. Google Correlate

Google Correlate es otra herramienta de Google Inc., la cual permite ingresar una serie de tiempo de datos y obtener las búsquedas cuya frecuencia de uso tiene un patrón similar al de los datos ingresados(27).

Luego de ingresar una serie de datos, Google Correlate calculará el Coeficiente de Correlación de Pearson entre la serie de datos ingresada y la frecuencia de serie de tiempo de todas las búsquedas en su base de datos y entregará como resultado una lista con las búsquedas con el más alto coeficiente(27).

Google Correlate contiene información de búsquedas desde Enero del 2003 hasta el presente.

Todos los resultados que entrega Google Correlate se encuentran como desviaciones estándar sobre la media, la cual se calcula de la siguiente manera:

$$z = \frac{x - \mu}{\sigma}$$

donde μ y σ son la media y la desviación estándar de la población respectivamente.

2.9. Google Flu Trends

Google Flu Trends (GFT) es una herramienta de vigilancia epidemiológica propuesta en el año 2008 por Ginsberg y colaboradores(28).

El objetivo de GFT es realizar una temprana detección y precisa estimación de la intensidad de una epidemia de influenza.

El modelo original de GFT utiliza las búsquedas de internet de 45 términos de búsqueda asociados a enfermedades tipo influenza (ILI por sus siglas en inglés), para estimar las visitas al médico por este tipo de enfermedades en una ciudad, estado o región en particular(8).

En el año 2009 debido a que la pandemia de influenza A/H1N1 fue completamente inadvertida por el sistema de GFT, se realizó una revisión y actualización del modelo en la cual se añadieron términos de búsqueda y se usaron búsquedas relacionadas con la infección por influenza y no con las complicaciones de la influenza como ocurría con el modelo original(29).

Una segunda re-calibración de GFT se realizó en el año 2013, debido a que el sistema sobreestimó en aproximadamente tres veces la magnitud de la “moderadamente severa” temporada de influenza del año 2012-2013(30), además de que la detección fue tres semanas tarde(31).

Estas imprecisiones han sido atribuidas al cambio en el comportamiento de búsqueda que experimentan las personas cuando se comienza a hablar de influenza en los medios de comunicación.

Debido a que luego de la última actualización no han existido periodos en que la influenza tenga un comportamiento inhabitual, hasta el día de hoy no existe consenso en cuanto a la utilidad de GFT.

Por el momento, la página Web de GFT ha dejado de mostrar las predicciones actuales, y solo muestra datos históricos(32).

2.10. Modelo SARIMA

El modelo Modelo Autorregresivo Integrado de Media Móvil Estacional (SARIMA) es una variante del Modelo Autorregresivo Integrado de Media Móvil (ARIMA) que fue presentado por primera vez por Box y Jenkins en 1976. Es uno de los métodos de series de tiempo más utilizado. Este modelo se caracteriza por 3 procesos, con 3 parámetros correspondientes p, d y q(1).

El proceso autorregresivo (AR), considera cada valor de la serie de tiempo como función lineal de p valores pasados(33). Un modelo autorregresivo de orden p, puede ser escrito como:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

donde ε_t corresponde a ruido blanco Gaussiano de media cero $\varepsilon_t \sim N(0; \sigma^2)$.

El proceso integrado (I), está relacionado con la tendencia a largo plazo de la serie de tiempo y asume que la diferencia entre 2 valores consecutivos es invariable: el método usual consiste en calcular una nueva serie restando el valor pasado al

valor dado, y en ese caso el parámetro d del proceso es igual a 1 (si se repite este cálculo en la nueva serie, $d= 2$)(1).

El proceso de media móvil (MA), se refiere a que un valor depende tanto del error actual como de uno o más errores previos(33).

$$y_t = c + \varepsilon_t + \theta_1\varepsilon_{t-1} + \theta_2\varepsilon_{t-2} + \dots + \theta_q\varepsilon_{t-q}$$

donde ε_t es el ruido blanco.

El modelo ARIMA clásico es muy útil para analizar series de tiempo, sin embargo, muchos fenómenos tienden a variar de una estación a otra, y estas fluctuaciones estacionales pueden causar problemas cuando se ajusta el modelo(1). La característica principal de los datos estacionales es que las observaciones están altamente correlacionadas en ciertos periodos de tiempo (día, semana, mes).

Cuando una serie de tiempo muestra estacionalidad, existen variantes como el modelo SARIMA, el cual se forma al incluir términos adicionales estacionarios al modelo ARIMA clásico, que se denotan como (P, D, Q), y de esta forma se puede medir el efecto estacional o eliminar la estacionalidad.

2.11. Modelo ARIMA con una variable exógena (ARIMAX)

El modelo ARIMAX es una extensión del modelo ARIMA de Box y Jenkins, más una variable exógena (X) explicativa (34).

Si pensamos en una serie de tiempo y_1, \dots, y_n . Un modelo ARIMA sin variable exógena o covariable sería de la forma:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} - \theta_1 z_{t-1} - \dots - \theta_q z_{t-q} + z_t$$

donde z_t es el ruido blanco.

El modelo ARIMAX simplemente agrega una covariable a la derecha de la ecuación:

$$y_t = \beta x_t + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} - \theta_1 z_{t-1} - \dots - \theta_q z_{t-q} + z_t$$

donde x_t es la covariable a tiempo t y β es el coeficiente.

2.12. Problema Metodológico de este Estudio

Una pregunta interesante es saber que ocurre primero: ¿el paciente (o una persona cercana a él) consulta en Google al momento de tener los síntomas, previo a la atención de urgencia, o esta consulta se realiza luego de ser atendido (o al mismo tiempo) ?

Esto último es muy importante para poder desarrollar un buen modelo predictivo de las atenciones de urgencia, debido a que si la búsqueda en Google se realiza en forma posterior a la atención, el modelo tendría muy poco valor ya que no podría anticiparse a hecho.

Para intentar responder a esta pregunta, se utilizó el test de causalidad de Granger, el cual permite estimar si una serie es causa o efecto de la otra.

2.13. Test de causalidad de Granger

El test de causalidad de Granger fue desarrollado en el año 1969 por Clive Granger (35), bajo el criterio de que si una serie de tiempo retardada está correlacionada con valores futuros de otra variable, se dice que la primera es la “causa” de la segunda(36). Dicho de otro modo, dadas dos series de tiempo x e y , el test de causalidad de Granger es un método que intenta determinar si una serie es probable de influenciar cambios en la otra. Esto se logra tomando diferentes retardos de una de las series y utilizando eso para modelar los cambios en la segunda serie.

Si creamos dos modelos para predecir “ y ”, uno sólo con valores pasados de y (I), y otro con valores pasados de x e y (II). Los modelos serían de la forma:

$$I. \quad y_t = \beta_0 + \beta_1 y_{t-1} + \dots + \beta_k y_{t-k} + e$$

$$II. \quad y_t = \beta_0 + \beta_1 y_{t-1} + \dots + \beta_k y_{t-k} + \alpha_1 x_{t-1} + \dots + \alpha_k x_{t-k} + e$$

donde k es el número de retardos en la serie de tiempo.

La suma residual de los errores cuadrados son comparados para determinar si el modelo (I) es adecuado para explicar los futuros valores de “ y ”, o si el modelo (II) es mejor.

3. Hipótesis

Las búsquedas específicas realizadas en internet permiten predecir el comportamiento de las visitas por causas respiratorias a los SU de Chile.

4. Objetivo General

Desarrollar un modelo predictivo de sobredemanda por causas respiratorias en los SU de Chile.

5. Objetivos específicos

1. Describir los registros de visitas a los SU por causas respiratorias de Chile, entre los años 2014 y 2016.
2. Identificar las búsquedas relacionadas.
3. Relacionar las series de tiempo "*Atenciones por causas respiratorias*" y las "*Búsquedas en Google*".
4. Evaluar la causalidad entre ambas series de tiempo.
5. Evaluar el error de la predicción de las atenciones a partir de las búsquedas.

6. Métodos

6.1. Diseño

El diseño de este trabajo corresponde a un estudio ecológico de tipo serie de tiempo. Es un estudio ecológico debido a que no se estudiaron los pacientes en forma individual, sino que en este caso, se trata de conglomerados de atenciones de pacientes por causas respiratorias por semanas estadísticas entre los años 2014 a 2016.

Es importante tener en cuenta que los estudios ecológicos están sujetos a la “falacia ecológica”, que corresponde al error que se comete cuando se aceptan asociaciones entre eventos que en realidad no existen, debido a que se supone que los resultados obtenidos serían los mismos que se obtendrían si se estudiara a las personas en forma individual (37). Por este motivo se debe tener precaución al momento de analizar los resultados.

6.2. Población

Este estudio se aplica a la población que consulta en los SU de las UEH, SAPU y SAR de Chile por causas respiratorias, durante los años 2014 a 2016. Se utilizará este periodo de tiempo debido a que de acuerdo a la revisión sistemática realizada por Wargon y colaboradores el año 2009, la mayoría de los trabajos reportados que intentan predecir el número de atenciones en los SU utilizan alrededor de 150 datos en la serie de tiempo, lo cual sería aproximadamente lo que se usó en este trabajo. Además, hasta la fecha en la que se realizó este estudio, la base de datos del DEIS cuenta con información desde los años 2008 hasta 2016,

con datos 2017 y 2018 solo preliminares, por lo tanto al utilizar las semanas estadísticas del 2014 a 2016, corresponde a 157 datos del período más actual.

6.3. Variables

Variable	Tipo de Variable	Descripción de la Variable
Búsquedas en Google	Índice de búsquedas/día o semana estadística	Discreta El índice de búsquedas es calculado de acuerdo a lo especificado en el punto 2.6 de esta Tesis. El rango va de 0 a 100.
	Numero de búsquedas	Discreta Una o la suma de varias búsquedas para confeccionar el modelo predictivo.
	Zona geográfica	Categórica Chile
Atenciones de Urgencia	Nº de consultas/ semana estadística	Discreta Reporte por semana estadística (2014-2016)
	Servicio de Salud	Categórica 29 servicios de salud del país
	Zona geográfica	Categórica Región de Chile (I a XV)
	Tipo de establecimiento	Categórica 1. UEH 2. SAPU 3. SAR
	Grupo de edad	Categórica 1. < 1 año 2. 1 a 4 años 3. 5 a 14 años 4. 15 a 64 años 5. >65 años

6.4. Análisis modelo SARIMA

Se realizó un análisis con el modelo SARIMA (Seasonal Autoregressive Integrated Moving Average) de la serie de tiempo “*Atenciones por causas respiratorias por semana estadística*” de acuerdo a las recomendaciones de(33), usando el protocolo Box-Jenkins.

En primer lugar se analizaron las funciones de Autocorrelación Simple y Autocorrelación Parcial, para identificar la estructura de los probables modelos que definan el proceso que mejor se ajusta a los datos.

Para evaluar qué valores de los parámetros no estacionales del modelo (p , d , q) y los parámetros estacionales del modelo (P , D , Q) eran los más apropiados, se utilizó el Criterio de información de Akaike corregido (AICc) usando el software R con los paquetes “tseries” y “forecast”. A menor AICc, mejor es el ajuste.

Luego de elegido el modelo, se realizó el análisis de predicción, para lo cual se usaron las 157 semanas estadísticas de los años 2014 a 2016, las cuales se dividieron de la siguiente forma: de las 151 semanas que quedaron luego de la remoción de outliers y el suavizado de la serie, se utilizó como grupo de entrenamiento del modelo, desde la primera semana del año 2014, hasta la segunda semana de abril 2016, es decir 121 semanas (80% de los datos), y como grupo de validación las 30 últimas semanas del año 2016 (20% de los datos).

Este análisis se efectuó para las atenciones de urgencia totales por causas respiratorias, y también se compararon las atenciones por causas respiratorias de UEH, SAPU, SAR y para los grupos etarios <1, 1-4, 5-14, 15-65 y >65 años.

Con el objetivo de medir el rendimiento predictivo del modelo, se utilizó el estadístico Error Porcentual Absoluto Medio (Mean Absolute Percentage Error; MAPE) tanto para el grupo de prueba como para el grupo de validación, el cual se calcula de la siguiente manera:

$$MAPE = \frac{\sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t}}{n}$$

Y_t = valor observado

\hat{Y}_t = valor estimado por el modelo

n = numero de retardos

6.5. Búsqueda de los términos relacionados

Se extrajeron desde la base de datos del DEIS las atenciones de urgencias por semana estadística de todos los establecimientos, de todas las regiones del país, de todos los grupos de edad, para cada uno de los años (2014 – 2016) en formato Excel (3 archivos en total), y luego se tomaron las atenciones por causas respiratorias (Cód. CIE 10 J00 a J98) en un archivo CSV para su análisis posterior.

Posteriormente, se cargó este archivo CSV en la página Web de Google Correlate, utilizando como filtro país “Chile” y shift series “0” semanas, el cual entrega otro archivo CSV con las 100 primeras búsquedas encontradas. Con esto se pudo obtener las búsquedas que tienen un comportamiento en el tiempo similar a la serie cargada.

Finalmente, se extrajeron las bases de datos de cada una de las búsquedas obtenidas en la etapa previa, desde la página Web de Google Trends. Para esto, se

utilizó como filtro país “Chile”, periodo “29-12-2013 al 31-12-2106”, “Todas las categorías” y “Búsqueda Web”. Este filtro entrega un archivo CSV con los índices de búsqueda en escala 0 al 100 (ver punto 2.6 de esta tesis), ordenados por semana estadística.

6.6. Análisis modelo ARIMAX

Para conocer si las búsquedas en internet permitían mejorar el rendimiento del modelo predictivo, se usó una variante del modelo ARIMA, a la cual se le agrega la serie de tiempo “*Búsquedas*” como variable exógena.

Esto se logra agregando en los comandos de R, la variable “xreg” dentro de la función “Arima”.

Se realizó el análisis en cada una de las búsquedas encontradas en forma individual, y luego se analizó la suma de búsquedas encontradas con Google Correlate, comenzando por la suma de las 5 primeras, hasta la suma de las 100 primeras búsquedas.

Al igual que en el modelo SARIMA, para medir el rendimiento del modelo, se usó el estadístico MAPE.

6.7. Test de causalidad de Granger

Para el test de causalidad de Granger se utilizaron los paquetes de R “lmtest”, “vars” y “forecast”. Al igual que en ARIMA es necesario trabajar con series estacionarias, para esto se calcula la primera diferencia de los datos y luego se

aplica la función “grangertest” para cada serie, usando como hipótesis nula la causalidad.

7. Resultados

7.1. Modelo SARIMA

Usando las funciones de Autocorrelación Simple y Parcial, se evaluó que valores de p , d y q y P , D , Q , eran los más apropiados para el modelo.

La Tabla 1 muestra algunos de los parámetros probados y el valor del AICc.

Tabla 1: Orden del modelo SARIMA probados para la serie de tiempo "Atenciones totales por causas respiratorias por semana estadística 2014-2016".

Modelo SARIMA (p , d , q) (P , D , Q)[S]	AICc
(2, 0, 7) (1, 0, 0) [7]	588,91
(2, 0, 7) (1, 0, 1) [7]	587,70
(2, 0, 7) (1, 0, 2) [7]	590,29
(2, 0, 1) (2, 0, 0) [7]^a	553,37
(2, 0, 0) (1, 0, 1) [7]	597,80
(2, 0, 0) (1, 0, 0) [7]	606,75
(2, 0, 7) (5, 0, 1) [7]	593,74
(2, 0, 0) (5, 0, 1) [7]	610,34
(2, 0, 1) (5, 0, 1) [7]	612,38
(2, 0, 2) (5, 0, 1) [7]	606,08
(2, 0, 5) (5, 0, 1) [7]	589,41

p , d , q = parámetros no estacionales del modelo.

P , D , Q = parámetros estacionales del modelo.

AICc = Criterio de información de Akaike corregido

a: función auto.arima de R

Se observa que el menor valor para AICc se obtiene con un SARIMA (2, 0, 1)(2, 0, 0)[7], el cuál es la recomendación de la función auto.arima de R, utilizando los parámetros "stepwise" y "approximation" en False, lo cual le toma un poco más de tiempo de cálculo, pero se obtienen los mejores resultados.

La Figura 3 muestra la predicción utilizando SARIMA (2, 0, 1)(2, 0, 0) para las atenciones totales.

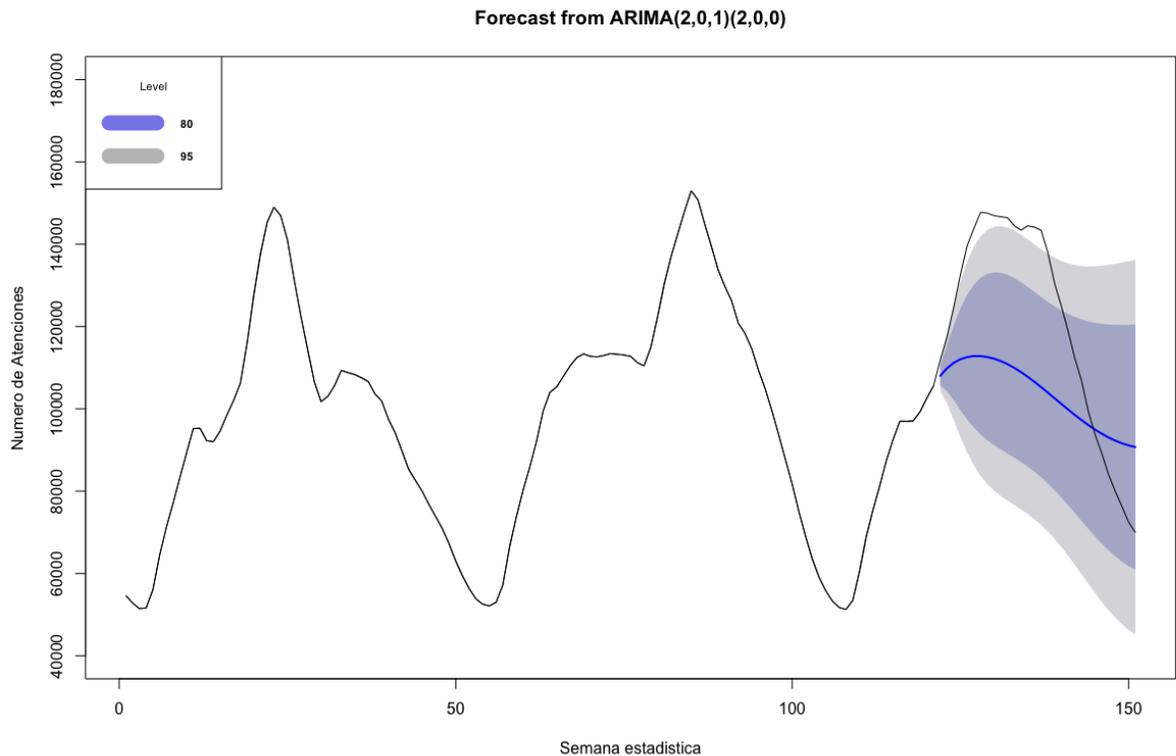


Figura 3: Predicción de Atenciones de Urgencia Totales por semana estadística, utilizando el modelo ARIMA (2, 0, 1)(2, 0, 0). La línea negra corresponde a las atenciones reales. La línea azul corresponde a la predicción hecha por el modelo, los colores azul y gris corresponden a los intervalos de confianza 80 y 95% respectivamente.

Posteriormente se analizaron por separado las atenciones de urgencia por causas respiratorias para UEH, SAPU y SAR (Figura 4, Figura 5 y Figura 6). Para obtener los parámetros del modelo sólo se usó la función `auto.arima` de R. La Tabla 2 muestra la comparación de los errores obtenidos con cada uno de los modelos.

Forecasts from ARIMA(3,0,2) with non-zero mean

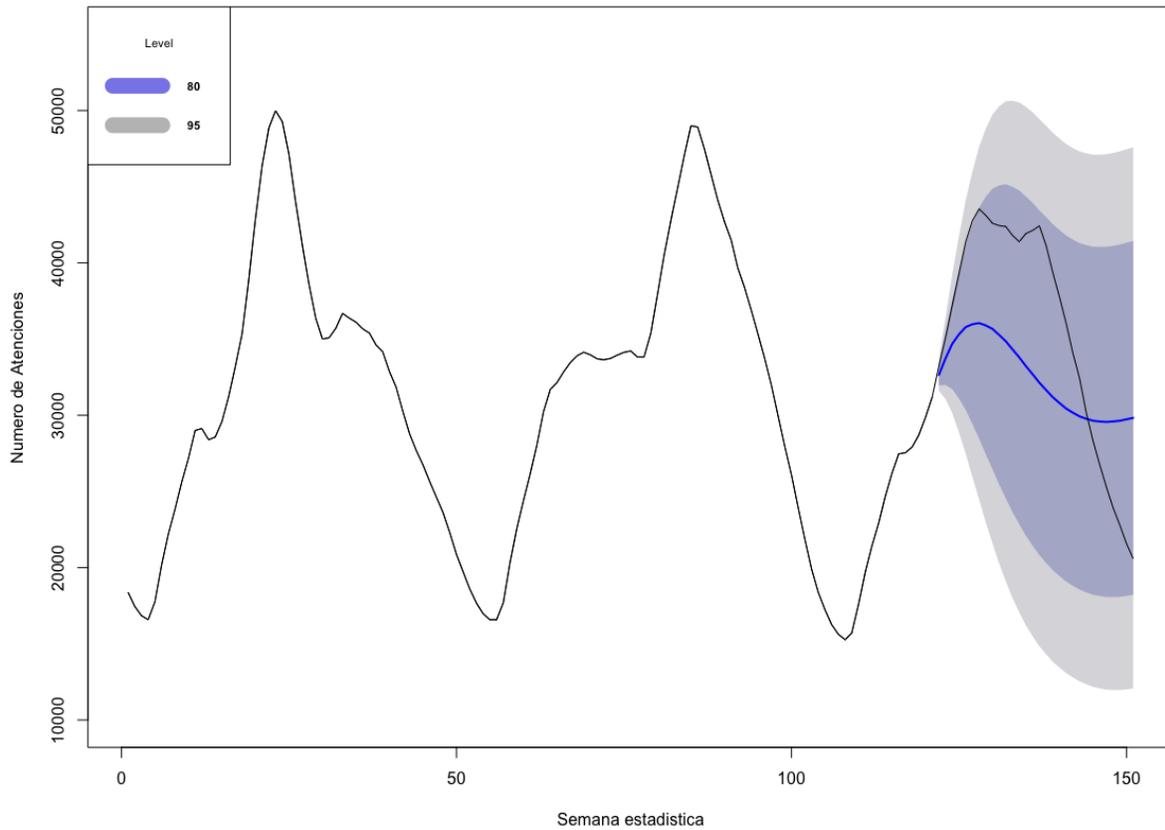


Figura 4: Predicción de Atenciones de Urgencia en UEH por semana estadística, utilizando el modelo ARIMA (3, 0, 2).

La línea negra corresponde a las atenciones reales. La línea azul corresponde a la predicción hecha por el modelo, los colores azul y gris corresponden a los intervalos de confianza 80 y 95% respectivamente

Forecasts from ARIMA(3,0,3) with non-zero mean

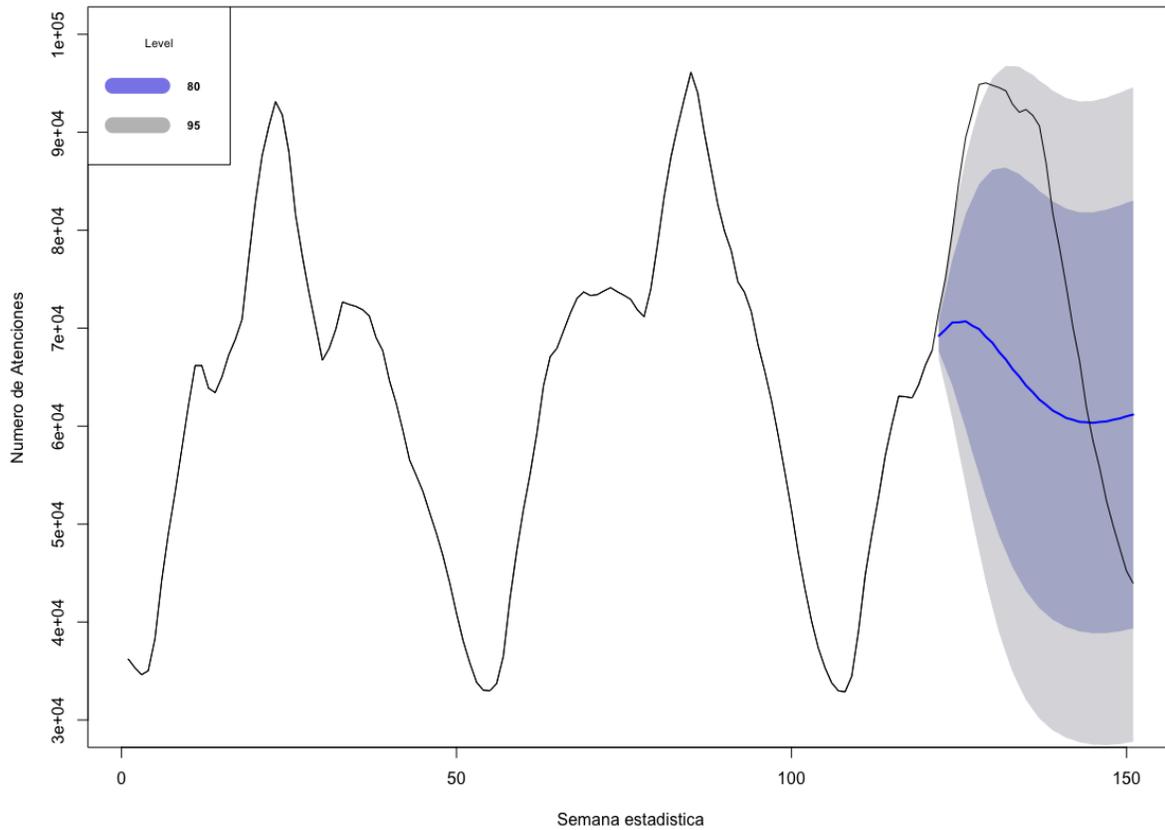


Figura 5: Predicción de Atenciones de Urgencia en SAPU por semana estadística, utilizando el modelo ARIMA (3, 0, 3).

La línea negra corresponde a las atenciones reales. La línea azul corresponde a la predicción hecha por el modelo, los colores azul y gris corresponden a los intervalos de confianza 80 y 95% respectivamente

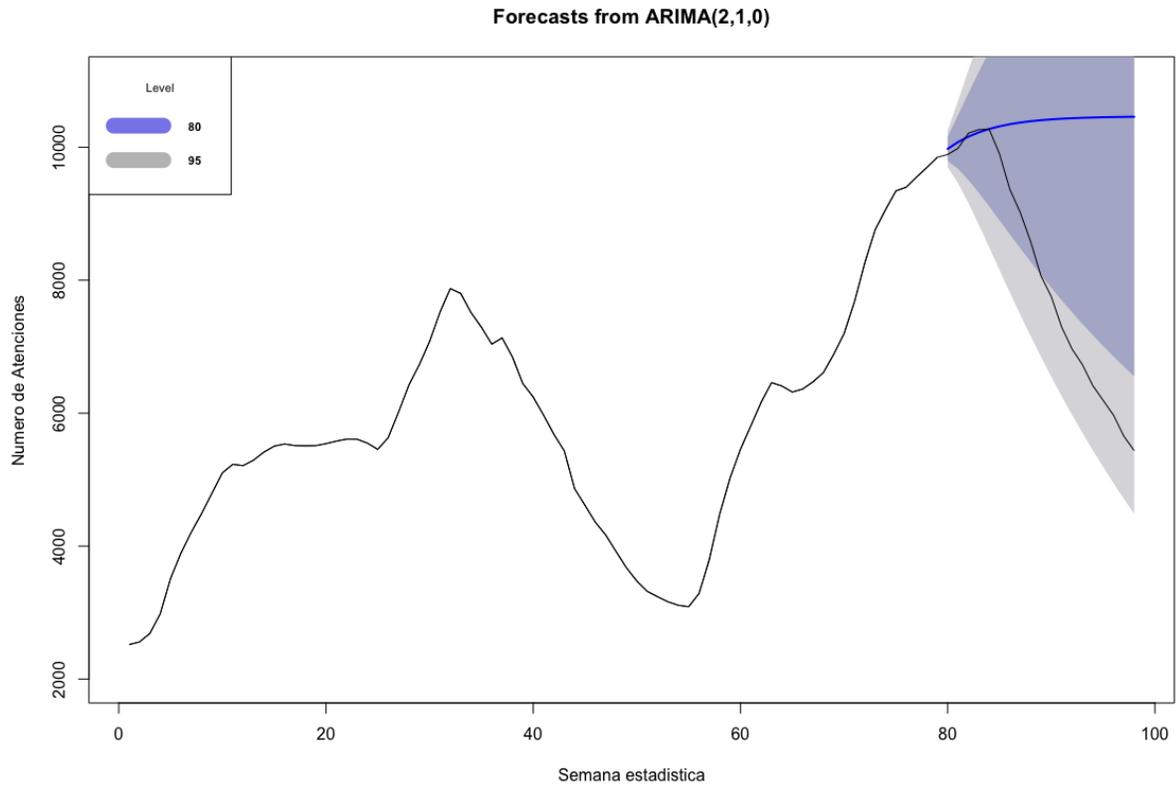


Figura 6: Predicción de Atenciones de Urgencia en SAR por semana estadística, utilizando el modelo ARIMA (2, 1, 0).

La línea negra corresponde a las atenciones reales. La línea azul corresponde a la predicción hecha por el modelo, los colores azul y gris corresponden a los intervalos de confianza 80 y 95% respectivamente. Nota: Para SAR solo existe información para los años 2015 y 2016.

Tabla 2: Error de la predicción del modelo ARIMA por tipo de establecimiento

	MAPE			
	Total	UEH	SAPU	SAR*
Urgencias				
Grupo de entrenamiento	1,46	1,37	1,56	1,79
Grupo de validación	17,87	16,91	21,41	34,14

MAPE: Error Porcentual Absoluto Medio, UEH: Unidad de Emergencia Hospitalaria, SAPU: Servicio de Atención Primaria de Urgencia,

SAR: Servicio de Atención Primaria de Urgencia de Alta Resolutividad

*Para SAR solo existe información para los años 2015 y 2016

El mismo análisis se realizó para comparar las atenciones por causas respiratorias totales de los distintos grupos etarios que clasifica DEIS (Tabla 3).

Tabla 3: Error de la predicción del modelo ARIMA por grupo etario

	MAPE				
	<1año	1-4 años	5-14 años	15-64 años	>65 años
Grupo de entrenamiento	1,96	1,94	2,20	1,39	1,14
Grupo de validación	20,56	15,75	22,58	23,91	25,22

MAPE: Error Porcentual Absoluto Medio

7.2. Búsqueda de términos relacionados

En la Tabla 4 se muestran algunos de las búsquedas mejor correlacionados con la serie de tiempo “Atenciones por causas respiratorias”, cargada en la página Web de Google Correlate.

Tabla 4: 40 primeras de las 100 búsquedas obtenidas con Google Correlate y su correlación con la serie de tiempo “Atenciones por causas respiratorias” en todos los SU del país, durante los años 2014 a 2016.

Búsqueda	Coefficiente de correlación de Pearson (R)	Búsqueda	Coefficiente de correlación de Pearson(R)
1 bequium	0,9466	21 abrilar	0,9169
2 niofen	0,9434	22 nontox	0,9142
3 flemex	0,9391	23 la bronquitis	0,9136
4 salbutamol	0,9323	24 ipson	0,9136
5 pironal flu	0,9312	25 obstructiva	0,9131
6 gripe	0,9303	26 la gripe	0,9115
7 bronquitis	0,9286	27 congestex	0,9105
8 cloval	0,9276	28 broncatox	0,9105
9 perebron	0,9265	29 bronconeumonía	0,9099
10 flu	0,9259	30 tusigen	0,9069
11 bronquitis aguda	0,9244	31 neumonitis	0,9069
12 flu forte	0,9237	32 pironal flu forte	0,9069
13 oxolamina	0,9231	33 jarabe	0,9064
14 rinofaringitis	0,9225	34 brontal	0,9061
15 pseudoefedrina	0,9212	35 bronquitis obstructiva	0,9056
16 broncard	0,9210	36 claritromicina	0,9034
17 pironal	0,9203	37 berodual	0,9025
18 codetol	0,9180	38 los bronquios	0,9010
19 muxol	0,9175	39 sinusitis	0,9006
20 ambroxol	0,9173	40 hedera helix	0,9004

La Tabla 5 muestra la clasificación de las 100 búsquedas con Google Correlate de acuerdo a su tópico.

Tabla 5: Tópicos de las 100 búsquedas mejor correlacionados con las Atenciones por causas respiratorias.

Tópicos	%
Medicamentos para enfermedades respiratorias	59
Enfermedades respiratorias	24
Síntomas respiratorios	15
Partes anatómicas del Sistema respiratorio	2
Total	100

La Figura 7 muestra un ejemplo del gráfico obtenido usando Google Correlate de la serie de tiempo “Atenciones por causas respiratorias” junto al término de búsqueda mejor correlacionado con esta (bequium $r=0,9466$).

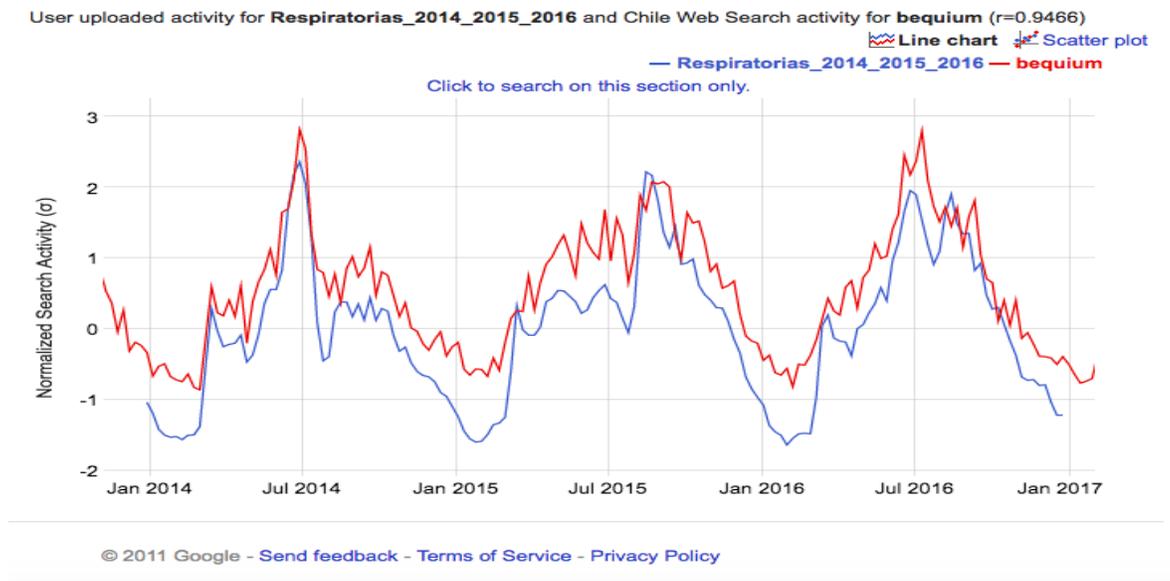


Figura 7: Series de tiempo “Atenciones por causas respiratorias” (en azul) y “bequium” (en rojo), durante los años 2014 a 2016.

(Los valores corresponde a desviaciones estándar por sobre la media de acuerdo a lo expresado en el punto 2.7 de esta tesis).

Fuente: Google Correlate

7.3. Modelo ARIMA con una variable exógena (ARIMAX)

La Tabla 6 muestra los errores de la predicción utilizando algunos de las búsquedas encontradas con Google Correlate como variable exógena.

Tabla 6: Errores de la predicción utilizando algunas de las búsquedas encontradas con Google Correlate.

Búsqueda	MAPE	
	Grupo de entrenamiento	Grupo de validación
jarabe	1,10	3,82
oxolamina	1,22	3,55
rinofaringitis	1,21	3,75
tos seca	1,45	4,01
flemex	1,30	4,28
resfriado	1,01	4,60
ambroxol	1,24	4,82
broncard	1,33	4,98
nastizol	1,19	5,42
trioval	1,21	5,64
kaloba	1,19	5,83
abrilar	1,36	5,99
la bronquitis	1,46	6,40
codetol	1,36	6,57

MAPE: Error Porcentual Absoluto Medio

En la Figura 8 se observa la predicción de modelo ARIMAX con las búsquedas del término “*Jarabe*” como variable exógena, el cual produjo el menor error en la predicción del grupo de prueba.

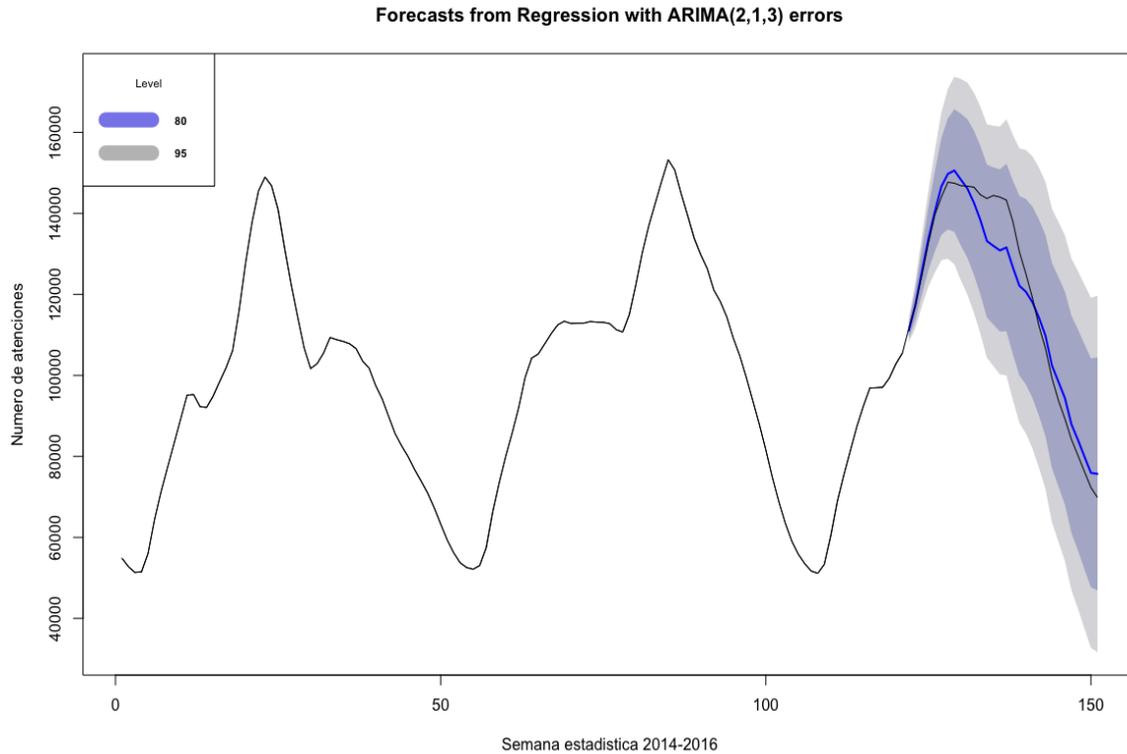


Figura 8: Predicción de Atenciones de Urgencia por semana estadística utilizando el modelo ARIMAX (2, 1, 3), con el término de búsqueda “jarabe” como variable exógena. La línea negra corresponde a las atenciones reales. La línea azul corresponde a la predicción hecha por el modelo, los colores azul y gris corresponden a los intervalos de confianza 80 y 95% respectivamente.

Luego de analizar usando ARIMAX con cada uno de las 100 búsquedas como variable exógena, se realizó el mismo método, pero usando la suma las búsquedas como variable exógena.

La Figura 9 y la Tabla 7 muestran la predicción hecha usando la suma de las 10 primeras búsquedas de Google Correlate como variable exógena, la cual produjo el menor MAPE.

Forecasts from Regression with ARIMA(1,0,4) errors

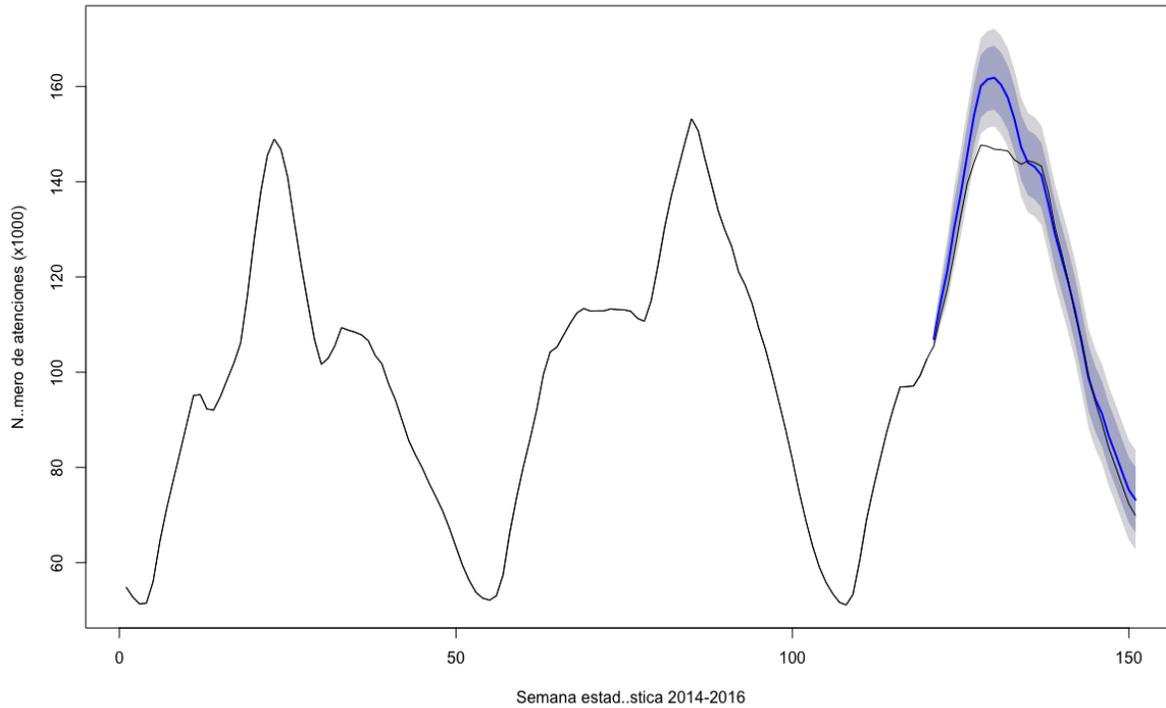


Figura 9: Predicción de Atenciones de Urgencia por semana estadística utilizando el modelo ARIMA (1, 0, 4), con la suma de las 10 primeras búsquedas como variable exógena (ARIMAX).

La línea negra corresponde a las atenciones reales. La línea azul corresponde a la predicción hecha por el modelo, los colores azul y gris corresponden a los intervalos de confianza 80 y 95% respectivamente.

Tabla 7: Error de la predicción del modelo ARIMAX para los 10 primeras búsquedas

	MAPE
Grupo de entrenamiento	0,97
Grupo de validación	3,54

MAPE: Error Porcentual Absoluto Medio

7.4. Test de causalidad de Granger

La Tabla 8 muestra los resultados del test de causalidad de Granger entre la serie de tiempo "Atenciones por causas respiratorias" versus algunas de las búsquedas encontradas. "Atenciones por causas respiratorias" y algunas de las búsquedas por separado y sumados encontrados usando Google Correlate.

Tabla 8: Test de causalidad de Granger entre la serie de tiempo "Atenciones por causas respiratorias" versus algunas de las búsquedas encontradas.

Búsqueda	Valor p	
	Búsqueda	Atenciones
bequium	0,0902	1,806e-09
niofen	0,0162	1,333e-09
salbutamol	0,2097	1,612e-07
bronquitis	0,4636	1,989e-05
bronquitis aguda	0,2183	2,925e-10
tos con flemas	0,2403	3,082e-07
tos	0,0147	0,0009648
resfriado	0,0012	3,446e-05
jarabe	0,0096	2,559e-06
nastizol	0,0003	0,0001069
sinusitis	0,0012	1,696e-09
gripe	0,7613	0,0005355
jarabe para la tos	0,8198	2,518e-06
claritromicina	0,1972	2,902e-12
Suma 10 primeras	1,127e-05	2,353e-05

Se considera significativo un valor $p \leq 0,05$

8. Discusión

Esta tesis describe el desarrollo de un modelo de predicción para las atenciones de urgencia por causas respiratorias en Chile usando las búsquedas en Google.

8.1. Modelo SARIMA

La serie de tiempo en semanas estadísticas de las consultas de urgencia por enfermedades respiratorias en Chile fueron consistentes con un modelo SARIMA $(p, 0, q)$ $(p, 0, 0)$. El mejor ajuste fue el SARIMA $(2, 0, 1)(2, 0, 0)[7]$ con un AICc de 553,37, que se obtuvo con la función “auto.arima” del paquete “forecast” de R. El MAPE de este modelo fue de 1,46% y 17,87% para los grupo de validación y prueba respectivamente.

Este rendimiento del modelo es similar a otros, como los trabajos de Milner P., 1997(38), Reis B., y Mandl K., 2003(39) y Marcilio I, *et al*, 2003(40) con un MAPE en el grupo de validación de 14,4%, 9,37% y 12,8% respectivamente, y peor rendimiento comparado con el trabajo de Abdel-Aal R. y Mangoud A., 1998(41), en el cuál se obtuvo un MAPE del grupo de validación de 4,23%, y también con un trabajo previo realizado en Chile de Cárdenas C. *et al*, 2014(42), en el cual el MAPE del grupo de validación del modelo SARIMA para la serie de tiempo de atenciones de urgencia por enfermedades respiratorias de 4,27% (Tabla 9).

Una explicación de estas diferencias es que en el primer trabajo se usaron las atenciones de urgencia totales y no las atenciones por enfermedades respiratorias como en este trabajo, y el segundo resultado puede ser explicado también debido a

que las poblaciones analizadas fueron diferentes, 5 hospitales de la red del servicio de salud de Chiloé en el trabajo señalado, mientras que en esta Tesis se utilizó todo el país. Además el porcentaje de los datos utilizados como grupo de validación en el trabajo de Cárdenas C. fue de 8% (12 de 135 semanas) y en este trabajo de 20% (30 de 151 semanas).

Tabla 9: Resumen de artículos que evalúan la predicción de visitas a los SU.

Referencia	Año	Población	MAPE (%)	
			Grupo entrenamiento	Grupo validación
Abdel-Aal R. y Mangoud A.(41)	1998	Total Atenciones Urgencia	1,86	4,23
Milner P.(38)	1997	Total Atenciones de Urgencia	-	14,4
Reis B., y Mandl K.(39)	2003	Total Atenciones Pediátricas	9,56	9,37
Reis B., y Mandl K.(39)	2003	Atenciones pediátricas por enfermedades respiratorias	-	27,54
Marcilio I., <i>et al</i> (40)	2013	Total Atenciones de Urgencia	-	12,8
Cárdenas C. <i>et al</i> (42)	2014	Atenciones por enfermedades respiratorias	-	4,27
Esta tesis	2018	Atenciones por enfermedades respiratorias	1,46	17,87

MAPE: Error Porcentual Absoluto Medio

Cuando se hizo la comparación por tipo de establecimiento, no se observó una mejora sustantiva en el rendimiento del modelo. Solamente en la UEH se apreció una leve mejora (MAPE 1,37% y 16,91% para grupos de entrenamiento y validación respectivamente), con respecto a las atenciones totales en todos los establecimientos del país.

Un resultado similar se obtuvo con la comparación por grupo etario, donde 2 resultados fueron levemente mejores que las atenciones totales por causar respiratorias, en el grupo de 1 a 4 años el MAPE para el grupo validación fue de 15,75% y en el grupo >65 años el MAPE del grupo de entrenamiento fue de 1,14%.

8.2. Búsqueda de términos relacionados

Luego de analizar la serie de tiempo "*Atenciones por causas respiratorias 2014-2016*" en Google Correlate, se encontraron 100 búsquedas con un comportamiento en el tiempo similar a la serie analizada, de los cuales el 100% de ellas tenía relación directa o indirecta con las enfermedades respiratorias. La gran mayoría de ellas (59%), correspondían a fármacos relacionados con el tratamiento de enfermedades respiratorias, principalmente nombres comerciales como "bequium", "niofen", "flemex", etc., pero también a nombres de medicamentos genéricos como salbutamol o "pseudoefedrina" y otros que no correspondían a un nombre de un medicamento en sí, pero que mostraban el interés de búsqueda por estos, como "jarabe", "remedio para la tos" o "antitusivo". En segundo lugar aparecen nombres comunes para algunas enfermedades del sistema respiratorio como "gripe", "bronquitis", "rinofaringitis" etc. (24%), y luego los síntomas de enfermedades respiratorias como "tos", "tos seca", "tos con flemas", etc. (15%), finalmente están las partes anatómicas del sistema respiratorio como "bronquios" o "los bronquios" (2%).

Estos resultados induce a pensar de que la mayoría de los pacientes que asisten a los SU realizan la búsqueda en Google después de la atención,

principalmente para buscar información acerca del medicamento que se le prescribió, o sobre el diagnóstico hecho por el profesional.

Las búsquedas estaban compuestas por entre 1 y 5 palabras, de las cuales la gran mayoría de ellas (63%) correspondía a una única palabra de búsqueda, a 2 palabras (24%) como por ejemplo “los bronquios”, a 3 palabras (7%) como “para la gripe”, a 4 palabras (5%) como “jarabe para la tos”, y a 5 palabras (1%) que era “jarabe para la tos seca” (resultados no mostrados).

Cuando se estudió si existía una relación entre la necesidad de tener una receta médica para adquirir los 50 nombres de medicamentos que aparecen en los resultados de Google Correlate usando el Registro Sanitario de medicamentos del ISP, se encontró que 41(82%) de ellos requieren receta (39 con receta médica y 2 con receta médica retenida) y sólo 9(18%) que no la necesitan. Lo que podría indicar una vez más, que los pacientes buscan información sobre lo que se les prescribió, tal como se mencionó anteriormente.

8.3. Modelo ARIMA con una variable exógena (ARIMAX)

El análisis ARIMAX de la suma de búsquedas, mostró que el sumar las primeras 10 búsquedas de la lista entregada por Google Correlate, se producía el mejor resultado en el grupo de validación con un MAPE de 3,54%, lo cual mejora considerablemente el resultado conseguido con el modelo SARIMA. La suma de las 10 primeras búsquedas produjo un resultado incluso mejor que al analizar cada una de las 100 búsquedas en forma individual.

Este último resultado es muy importante debido a que para la elaboración de un modelo predictivo es recomendable usar más de un término de búsqueda como variable predictora(29), ya que el modelo, al depender sólo de una variable no sería capaz de detectar una frecuencia inhabitual en el número de atenciones, por lo tanto carecería de sensibilidad.

Por este motivo según lo indicado por los creadores de Google Flu Trends(28,29), es recomendable utilizar el mayor número de búsquedas posible que entreguen un relativamente bajo error. En el caso de esta Tesis, el menor error se consiguió al utilizar la suma de las 10 primeras búsquedas, sin embargo, según las recomendaciones de aquellos autores, tal vez sería conveniente agregar más búsquedas sin que aumente significativamente el error, por ejemplo al sumar las 80 primeras búsquedas el MAPE del grupo de validación aumenta hasta solamente un 5,11%(resultados no mostrados), lo cual sigue siendo bajo de acuerdo a lo revisado en la literatura, y le entregaría una mayor sensibilidad al modelo.

Asimismo, es necesario analizar cómo se comporta el modelo en un brote o aumento inhabitual de alguna enfermedad respiratoria, para saber si es capaz de no verse influenciado por el aumento en las búsquedas en internet secundarias a la difusión de estos temas por la prensa o las redes sociales, como lo ocurrido con Google Flu Trends durante los años 2012-2013.

Usando el modelo ARIMAX con la suma de las 10 primeras búsquedas fue posible además hacer un análisis retrospectivo de las atenciones de urgencia desde

los años 2010 a 2013 (resultados no mostrados), obteniendo un MAPE en promedio de 10,3%, lo cual es un indicativo adicional del buen rendimiento del modelo.

8.4. Test de causalidad de Granger

En el test de causalidad de Granger, muchas de las búsquedas obtuvieron un valor p menor al de las atenciones Ej.: “bequium”, “niofen”, “tos”, etc. o un valor p no significativo Ej.: “salbutamol”, “bronquitis”, “bronquitis aguda” etc. En otras búsquedas, y también en la suma de ellas, se observa causalidad bidireccional, es decir, que las dos series obtuvieron un valor p significativo. En el primer caso, esto indicaría que la serie de tiempo “*Atenciones*” sería la causa, es decir, los pacientes realizarían la búsqueda en Google en forma posterior a la atención en el SU. Esto último sería concordante con lo señalado anteriormente, respecto a que la gran mayoría de las búsquedas correspondían a medicamentos usados para tratar enfermedades respiratorias, que podría significar que los pacientes usan Google para buscar información acerca de lo que se les recetó después de la atención. Sin embargo, ningún test estadístico existente es capaz de confirmar “causalidad” y solo se debe usar esta información como referencia. Además, es necesario recordar que 9 de las búsquedas correspondían a búsquedas de medicamentos para tratar enfermedades respiratorias Ej. “remedio para la tos”, por lo cual en definitiva no es posible establecer si la causalidad es en sentido de la hipótesis o de causalidad inversa.

Es posible que la poca información que entrega en este caso el test de Granger, sería debido al hecho de que la búsqueda de términos se hizo utilizando las atenciones por semana estadística, y no las atenciones diarias en los SU (la herramienta Google Correlate no permite trabajar con series de tiempo diarias, sólo permite el uso de series de semanales o mensuales), lo cual podría haber arrojado otros términos que correspondieran tal vez a lo que los pacientes buscan en internet antes de ir al SU.

8.5. Discusión final

El modelo predictivo elaborado en esta Tesis, podría ser usado para mejorar el funcionamiento general de los SU del país, ya que permite que estos puedan prepararse tanto en recursos humanos (médicos, enfermeras, técnicos) y físicos (consultas, salas de espera, materiales o camas), para las semanas en que exista una sobredemanda en la atención. Además, también es posible utilizar la información que entrega este modelo, para mejoramiento de herramientas y páginas Web como “Salud Responde” del Ministerio de Salud, donde el conocer de antemano las dudas que tienen los pacientes y que normalmente intentan resolver usando internet, sería de gran ayuda para poder orientarlos correctamente y con información con base científica.

Sin embargo, es importante aclarar que podría existir un sesgo en este trabajo, ya que Google Correlate no analiza términos de búsqueda que utilicen caracteres especiales, como el caso de la letra “ñ” o el tilde del idioma castellano.

Esto es relevante debido a que pueden existir términos de búsqueda con estos caracteres que no fueron considerados en el análisis de esta tesis.

Finalmente, la posibilidad real de poder implementar este sistema en un SU, se ve bastante posible, debido a que según lo consultado a médicos especialistas en medicina de urgencia y a jefes de SU tanto del sector privado como el público, para ellos sería de muchísima ayuda, sobretodo ya que los sistemas que se utilizan normalmente para el fin de predecir las atenciones en Chile están basados en los datos de años anteriores y por lo general no cuentan con ningún sistema predictivo basado en modelos matemáticos o similares..

Asimismo, el hecho de que en este estudio se trabajó por semanas estadísticas y no por día, no parece una debilidad, ya que, una predicción con una anticipación de 1 o 2 días frente a un aumento en el número de pacientes, no daría tiempo de reorganizar el servicio, como por ejemplo, habilitando camas o modificando los turnos de trabajo. Por lo tanto, una predicción con un plazo mayor, como por ejemplo un 1 mes, parece ser un tiempo bastante más adecuado, principalmente debido a que los turnos se programan mensualmente.

9. Conclusión

Usando las búsquedas en Google, fue posible elaborar un modelo predictivo de las atenciones de urgencia por enfermedades respiratorias en Chile, esto se logró utilizando un modelo ARIMAX con la suma de las 10 primeras búsquedas en Google como variable exógena.

Sin embargo, aún queda por estudiar si las búsquedas en Google son anteriores o posteriores a la atención, debido a que esto es crucial para el desempeño del modelo. Como también es necesario realizar este mismo estudio con atenciones de urgencia del sector privado, ya que esta tesis sólo utilizaron datos del sector público.

Asimismo, es importante evaluar el modelo en condiciones de un aumento inhabitual de enfermedades respiratorias, para establecer si puede ser influenciado por las búsquedas en internet secundarias a una masificación del tema por medio de la prensa o las redes sociales.

10. Bibliografía

1. Wargon M, Guidet B, Hoang TD, Hejblum G. A systematic review of models for forecasting the number of emergency department visits. *Emerg Med J.* 1 de junio de 2009;26(6):395-9.
2. Boyle A, Abel G, Raut P, Austin R, Dhakshinamoorthy V, Ayyamuthu R, et al. Comparison of the International Crowding Measure in Emergency Departments (ICMED) and the National Emergency Department Overcrowding Score (NEDOCS) to measure emergency department crowding: pilot study. *Emerg Med J.* mayo de 2016;33(5):307-12.
3. Sprivulis PC, Silva J-AD, Jacobs IG, Frazer ARL, Jelinek GA. The association between hospital overcrowding and mortality among patients admitted via Western Australian emergency departments. 2006;184(5):5.
4. Hoot NR, Aronsky D. Systematic Review of Emergency Department Crowding: Causes, Effects, and Solutions. *Ann Emerg Med.* agosto de 2008;52(2):126-136.e1.
5. Yarmohammadian M, Rezaei F, Haghshenas A, Tavakoli N. Overcrowding in emergency departments: A review of strategies to decrease future challenges. *J Res Med Sci.* 2017;22(1):23.
6. DEIS [Internet]. 2016 [citado 24 de mayo de 2018]. Disponible en: <http://www.deis.cl/estadisticas-atencionesurgencia/>
7. Instituto Nacional de Estadísticas. Compendio Estadístico 2016. Santiago, Chile; 2016.
8. Dugas AF, Hsieh Y-H, Levin SR, Pines JM, Mareiniss DP, Mohareb A, et al. Google Flu Trends: Correlation With Emergency Department Influenza Rates and Crowding Metrics.

Clin Infect Dis. 15 de febrero de 2012;54(4):463-9.

9. Araz OM, Bentley D, Muelleman RL. Using Google Flu Trends data in forecasting influenza-like-illness related ED visits in Omaha, Nebraska. *Am J Emerg Med.* septiembre de 2014;32(9):1016-23.
10. Ram S, Zhang W, Williams M, Pengetnze Y. Predicting Asthma-Related Emergency Department Visits Using Big Data. *IEEE J Biomed Health Inform.* julio de 2015;19(4):1216-23.
11. Baller S, Dutta S, Lanvin B. The Global Information Technology Report 2016: Innovating in the Digital Economy [Internet]. 2016 [citado 25 de mayo de 2018]. Disponible en: <http://www.deslibris.ca/ID/10090686>
12. SUBTEL. Reporte Telecomunicaciones Tercer Trimestre 2016. [Internet]. 2016. Disponible en: http://www.subtel.gob.cl/wp-content/uploads/2015/04/PPT_Series_SEPTIEMBRE_2016_V1.pdf
13. Lara BA, Cataldo A, Castro R, Aguilera PR, Ruiz C, Adresen M. Medicina de urgencia y unidades de cuidados intensivos: Una alianza necesaria en busca de la mejoría de la atención de pacientes críticos. *Rev Médica Chile.* julio de 2016;144(7):911-7.
14. Tobar E, Retamal A, Garrido N. Elementos de Gestión para un Servicio de Urgencia de un hospital universitario. *Rev Hosp Clin Univ Chile.* 2014;25(1):189-200.
15. Berchet C. Emergency Care Services: Trends, Drivers and Interventions to Manage the Demand [Internet]. 2015 ago [citado 4 de diciembre de 2018]. Report No.: 83. Disponible en: https://www.oecd-ilibrary.org/social-issues-migration-health/emergency-care-services_5jrts344crns-en

16. Instituto de Administracion de Salud U de Chile. Informe Final Evaluación del Gasto Institucional de la Red de Urgencia del Ministerio de Salud [Internet]. DIPRES; 2016 p. 583. Disponible en: http://www.dipres.gob.cl/597/articles-160332_informe_final.pdf
17. Durand A-C, Gentile S, Devictor B, Palazzolo S, Vignally P, Gerbeaux P, et al. ED patients: how nonurgent are they? Systematic review of the emergency medicine literature. *Am J Emerg Med.* marzo de 2011;29(3):333-45.
18. Ekström A, Kurland L, Farrokhnia N, Castrén M, Nordberg M. Forecasting Emergency Department Visits Using Internet Data. *Ann Emerg Med.* abril de 2015;65(4):436-442.e1.
19. Pope C. Qualitative methods in research on healthcare quality. *Qual Saf Health Care.* 1 de junio de 2002;11(2):148-52.
20. Tandberg D, Qualls C. Time Series Forecasts of Emergency Department Patient Volume, Length of Stay, and Acuity. *Ann Emerg Med.* febrero de 1994;23(2):299-306.
21. Rotstein Z, Wilf-Miron R, Lavi B, Shahar A, Gabbay U, Noy S. The dynamics of patient visits to a public hospital ED: A statistical model. *Am J Emerg Med.* octubre de 1997;15(6):596-9.
22. Católica U, GfK Adimark. Encuesta Nacional Bicentenario Uso de Redes Sociales 2016. 2016.
23. Trends Help [Internet]. [citado 26 de mayo de 2018]. Disponible en: <https://support.google.com/trends/?hl=en#topic=6248052>
24. Nuti SV, Wayda B, Ranasinghe I, Wang S, Dreyer RP, Chen SI, et al. The Use of Google Trends in Health Care Research: A Systematic Review. Voracek M, editor. *PLoS*

ONE. 22 de octubre de 2014;9(10):e109583.

25. Yin S, Ho M. Monitoring a toxicological outbreak using Internet search query data. *Clin Toxicol.* noviembre de 2012;50(9):818-22.

26. Gunn III JF, Lester D. Using google searches on the internet to monitor suicidal behavior. *J Affect Disord.* junio de 2013;148(2-3):411-2.

27. Google Correlate [Internet]. [citado 26 de mayo de 2018]. Disponible en: <https://www.google.com/trends/correlate>

28. Ginsberg J, Mohebbi MH, Patel RS, Brammer L, Smolinski MS, Brilliant L. Detecting influenza epidemics using search engine query data. *Nature.* febrero de 2009;457(7232):1012-4.

29. Cook S, Conrad C, Fowlkes AL, Mohebbi MH. Assessing Google Flu Trends Performance in the United States during the 2009 Influenza Virus A (H1N1) Pandemic. Cowling BJ, editor. *PLoS ONE.* 19 de agosto de 2011;6(8):e23610.

30. Olson DR, Konty KJ, Paladini M, Viboud C, Simonsen L. Reassessing Google Flu Trends Data for Detection of Seasonal and Pandemic Influenza: A Comparative Epidemiological Study at Three Geographic Scales. Ferguson N, editor. *PLoS Comput Biol.* 17 de octubre de 2013;9(10):e1003256.

31. Flu Trends updates model to help estimate flu levels in the US [Internet]. [citado 26 de mayo de 2018]. Disponible en: <http://blog.google.org/2013/10/flu-trends-updates-model-to-help.html>

32. Google Flu Trends [Internet]. [citado 26 de mayo de 2018]. Disponible en:

<https://www.google.org/flutrends/about/>

33. Hyndman RJ, Athanasopoulos G. Forecasting: principles and practice. Print edition. S.l.: OTexts; 2014. 291 p.
34. Lim C, McAleer M, Min JCH. ARMAX modelling of international tourism demand. *Math Comput Simul.* mayo de 2009;79(9):2879-88.
35. Granger CWJ. Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica.* agosto de 1969;37(3):424.
36. Montero R. Test de Causalidad. Documentos de Trabajo en Economía Aplicada. Universidad de Granada España. 2013;
37. Borja-Aburto VH. Estudios Ecologicos. *Salud Pública de México.* 2000;42(6).
38. Milner PC. Ten-year follow-up of ARIMA forecasts of attendances at accident and emergency departments in the Trent region. *Stat Med.* 30 de septiembre de 1997;16(18):2117-25.
39. Reis BY, Mandl KD. Time series modeling for syndromic surveillance. *BMC Med Inform Decis Mak [Internet].* diciembre de 2003 [citado 8 de agosto de 2018];3(1). Disponible en: <http://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/1472-6947-3-2>
40. Marcilio I, Hajat S, Gouveia N. Forecasting Daily Emergency Department Visits Using Calendar Variables and Ambient Temperature Readings. Merchant RC, editor. *Acad Emerg Med.* agosto de 2013;20(8):769-77.
41. Abdel-Aal R., Mangoud A. Modeling and forecasting monthly patient volume at a primary health care clinic using univariate time-series analysis. *Comput Methods Programs*

Biomed. junio de 1998;56(3):235-47.

42. CáRdenas M C, Sovier V C, Pérez R U, González A CAS. Consultas de urgencia general y por causa respiratoria en la Red de establecimientos del Sistema Nacional de Servicios de Salud (SNSS): un modelo predictivo en el Servicio de Salud de Chiloé. Rev Chil Enfermedades Respir. septiembre de 2014;30(3):133-41.