



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



Escola Tècnica
Superior d'Enginyeria
Informàtica

Escola Tècnica Superior d'Enginyeria Informàtica
Universitat Politècnica de València

Análisis de la correlación entre la evolución cuantitativa del COVID-19 y el contenido publicado en Twitter en España

TRABAJO FIN DE GRADO

Grado en Ingeniería Informática

Autor: Víctor Dorado Javier

Tutor: Lenin Guillermo Lemus Zúñiga

Curso 2019-2020

Resum

L'objectiu principal d'aquest treball de final de grau és dissenyar i implementar un sistema que siga d'utilitat a la comunitat per a lluitar contra el COVID-19, tot això utilitzant dades obtingudes de *Twitter*. Per a això, s'utilitzaran tècniques del processament del llenguatge natural (PLN) i l'aprenentatge automàtic.

El sistema serà capaç de i) connectar-se a la API de *Twitter*, recopilar i emmagatzemar els tuits, ii) transformar els tuits en vectors numèrics que siguen d'utilitat i iii) utilitzar aquests vectors per a realitzar una estimació de l'evolució quantitativa del COVID-19 a Espanya. El que es busca és extraure informació sobre la simptomatologia de la societat espanyola a partir dels tuits publicats dins del territori espanyol, i a partir d'aquesta informació realitzar l'estimació de l'evolució quantitativa del COVID-19. S'avaluarà el sistema sobre la sèrie temporal oficial publicada pel Govern d'Espanya. També es proposa com a objectiu secundari, intentar estimar l'evolució quantitativa de la gravetat de la pandèmia, introduint una gradació en la gravetat dels casos estimats pel sistema.

Finalment, es proposa dividir el sistema en quatre fases (o mòduls). La *fase 0* seria la corresponent a la recopilació i emmagatzematge dels tuits. La *fase 1* seria la corresponent a la vectorització dels tuits. La *fase 2* seria la corresponent a l'estimació bàsica de l'evolució del COVID-19. I, finalment, la *fase 3* seria la que s'encarregaria d'estimar l'evolució de la gravetat de la pandèmia a Espanya, l'objectiu secundari que s'ha proposat.

Paraules clau: Processament del llenguatge natural, Twitter, Aprenentatge automàtic, Simptomatologia, Estimador, Python

Resumen

El objetivo principal de este trabajo de final de grado es diseñar e implementar un sistema que sea de utilidad a la comunidad para luchar contra el COVID-19, todo ello utilizando datos obtenidos de *Twitter*. Para ello, se utilizarán técnicas del procesamiento del lenguaje natural (PLN) y el aprendizaje automático.

El sistema será capaz de i) conectarse a la API de *Twitter*, recopilar y almacenar los tuits, ii) transformar los tuits en vectores numéricos que sean de utilidad y iii) utilizar estos vectores para realizar una estimación de la evolución cuantitativa del COVID-19 en España. Lo que se busca es extraer información acerca de la sintomatología de la sociedad española a partir de los tuits publicados dentro del territorio español, y a partir de esta información realizar la estimación de la evolución cuantitativa del COVID-19. Se va a evaluar el sistema sobre la serie temporal oficial publicada por el Gobierno de España. También se propone como objetivo secundario, intentar estimar la evolución cuantitativa de la gravedad de la pandemia, introduciendo una gradación en la gravedad de los casos estimados por el sistema.

Finalmente, se propone dividir el sistema en cuatro fases (o módulos). La *fase 0* sería la correspondiente a la recopilación y almacenamiento de los tuits. La *fase 1* sería la correspondiente a la vectorización de los tuits. La *fase 2* sería la correspondiente a la estimación básica de la evolución del COVID-19. Y, por último, la *fase 3* sería la que se encargaría de estimar la evolución de la gravedad de la pandemia en España, el objetivo secundario que se ha propuesto.

Palabras clave: Procesamiento del lenguaje natural, Twitter, Aprendizaje automático, Sintomatología, Estimador, Python

Abstract

The main objective of this end-of-degree work is to design and implement a system that will be useful to the community in the fight against COVID-19, all using data obtained from *Twitter*. To do so, natural language processing (NLP) and machine learning techniques will be used.

The system will be able to i) connect to the API of *Twitter*, collect and store the tweets, ii) transform the tweets into useful numerical vectors and iii) use these vectors to estimate the quantitative evolution of COVID-19 in Spain. The aim is to extract information about the symptoms of Spanish society from the tweets published in Spain, and from this information to estimate the quantitative evolution of COVID-19. The system will be evaluated on the official time series published by the Spanish Government. A secondary objective is to try to estimate the quantitative evolution of the severity of the pandemic, introducing a gradation in the severity of the cases estimated by the system.

Finally, it is proposed to divide the system into four phases (or modules). *Phase 0* would be the one corresponding to the collection and storage of the tweets. *Phase 1* would correspond to the vectorization of the tweets. *Phase 2* would correspond to the basic estimation of the evolution of COVID-19. And finally, *phase 3* would be responsible for estimating the evolution of the severity of the pandemic in Spain, the secondary objective that has been proposed.

Key words: Natural language processing, Twitter, Machine learning, Symptomatology, Estimator, Python

Índice general

Índice general	V
Índice de figuras	VII
Índice de tablas	VII
<hr/>	
1 Introducción	3
1.1 Motivación	3
1.2 Objetivos	4
1.3 Impacto Esperado	4
1.4 Metodología	5
1.5 Estructura	5
2 Estado de la cuestión	7
2.1 Propuesta	8
3 Análisis del problema	9
3.1 Análisis de seguridad	9
3.2 Análisis del marco legal y ético	9
3.2.1 Análisis de la protección de datos	9
3.2.2 Propiedad intelectual	10
3.2.3 Otros aspectos legales	10
3.2.4 Ética	10
3.3 Identificación y análisis de soluciones posibles	10
3.4 Solución propuesta	11
3.5 Plan de trabajo	12
3.6 Presupuesto	21
4 Diseño de la solución	25
4.1 Arquitectura del sistema	25
4.2 Diseño detallado	26
4.2.1 Módulo 0	26
4.2.2 Módulo 1	26
4.2.3 Módulo 2	27
4.2.4 Módulo 3	27
4.2.5 Casos de uso del sistema	28
4.3 Tecnología utilizada	30
4.3.1 Python 3	30
4.3.2 MongoDB	34
5 Desarrollo de la solución propuesta	37
5.1 Fase 0: recopilación, adecuación y almacenamiento de los datos	37
5.1.1 Recopilación de los datos	37
5.1.2 Truncamiento de los datos	38
5.1.3 Anonimización de los datos	38
5.1.4 Almacenamiento de los datos	38
5.1.5 Entrenamiento de modelos de clasificación de localización	39
5.1.6 Clasificación de localización de los datos	40

5.2	Fase 1: vectorización de los datos	41
5.2.1	Lectura de los datos	41
5.2.2	Vectorización de los datos	41
5.2.3	Almacenamiento de la vectorización	42
5.3	Fase 2: estimación básica de la evolución cuantitativa del COVID-19	42
5.3.1	Lectura de la vectorización	42
5.3.2	Transformaciones previas a la estimación	42
5.3.3	Estimación de la evolución cuantitativa	43
6	Implantación	45
7	Pruebas y evaluaciones	47
7.1	Análisis de la correlación entre las series temporales	47
7.2	Evaluación de los clasificadores de localización	51
7.2.1	Métricas para los experimentos de clasificación	51
7.2.2	Experimentos con los clasificadores	52
7.3	Evaluación de los estimadores de la evolución	55
7.3.1	Métricas para los experimentos de estimación	56
7.3.2	Experimentos con los estimadores	57
8	Conclusiones	63
8.1	Relación del trabajo desarrollado con los estudios cursados	64
9	Trabajos futuros	67
	Glosario	69
	Bibliografía	71

Apéndices		
A	Tabla comparativa de configuraciones de localización: red neuronal artificial	75
B	Tabla comparativa de configuraciones de localización: máquina de vectores soporte	95
C	Tabla comparativa de configuraciones de estimador: regresión lineal	105
D	Tabla comparativa de configuraciones de estimador: red neuronal artificial	109
E	Tabla comparativa de configuraciones de estimador: red neuronal recurrente	131
F	Licencia	153
G	License	155

Índice de figuras

3.1	Esquema de desglose del trabajo	12
3.2	Rama de la <i>fase 0</i> del esquema de desglose del trabajo	13
3.3	Rama de la <i>fase 1</i> del esquema de desglose del trabajo	15
3.4	Rama de la <i>fase 2</i> del esquema de desglose del trabajo	16
3.5	Rama de la <i>fase 3</i> del esquema de desglose del trabajo	19
4.1	Diagrama de la arquitectura del sistema	25
4.2	Diagrama de casos de uso del sistema	28
4.3	Logotipo de <i>Python</i>	30
4.4	Logotipo de <i>Jupyter Project</i>	31
4.5	Logotipo de <i>Visual Studio Code</i>	31
4.6	Logotipo de <i>Spacy</i>	32
4.7	Logotipo de <i>Pandas</i>	32
4.8	Logotipo de <i>Numpy</i>	33
4.9	Logotipo de <i>Scikit-Learn</i>	33
4.10	Logotipo de <i>Keras</i>	34
4.11	Logotipo de <i>Matplotlib</i>	34
4.12	Logotipo de <i>MongoDB</i>	34
7.1	Gráfica de la auto-correlación	48
7.2	Gráfica de la correlación entre las series temporales	49
7.3	Gráfica del test de Granger entre las series temporales	50
7.4	Gráfico representativo de las métricas <i>Precision</i> y <i>Recall</i>	52
7.5	Funciones generadoras de la configuración de las capas ocultas para el clasificador ANN	54
7.6	Funciones generadoras de la configuración de las capas ocultas para el estimador ANN	59
7.7	Funciones generadoras de la configuración de las capas de memoria LSTM para el estimador RNN	60
7.8	Funciones generadoras de la configuración de las capas ocultas para el estimador RNN	60

Índice de tablas

3.1	Tabla resumen del presupuesto	23
7.1	Tabla de los mejores resultados para clasificación con SVM	54
7.2	Tabla de los mejores resultados para clasificación con ANN	55

7.3	Tabla de los mejores resultados para estimación con regresión lineal	58
7.4	Tabla de los mejores resultados para estimación con ANN	59
7.5	Tabla de los mejores resultados para estimación con RNN	61

“El doblepiensa se refiere a la capacidad de sostener dos creencias contradictorias de manera simultánea y aceptar ambas a la vez.”

- George Orwell, 1984

CAPÍTULO 1

Introducción

En la actualidad vivimos en un mundo digital, un mundo en el que cada vez más las interacciones interpersonales se desarrollan en entornos digitales. Al mismo tiempo, es un mundo en el que el desarrollo de las tecnologías tiene un ritmo frenético, y esto también ha culminado en una evolución de los comportamientos de la sociedad.

Uno de los muchos resultados de esta evolución es que la sociedad ha normalizado el hecho de tener una vida privada pública: gran parte de la sociedad publica en redes sociales multitud de aspectos sobre su vida privada, ya sea en forma de imágenes, vídeos o texto.

Todos esos datos, a pesar de no estar estructurados, contienen cantidades masivas de información que se encuentra abierta al público, utilizando las herramientas apropiadas. En teoría, el propietario de esta información conoce este hecho.

Este trabajo, se va a centrar la extracción y tratamiento de información en lenguaje natural, concretamente en castellano, a partir de tuits presentes en la red social *Twitter*.

1.1 Motivación

La cantidad de información que se puede extraer de las redes sociales es abrumadora y va más allá de las simples cifras en el papel. Por eso, este trabajo se va a centrar en darle valor a información que a primera vista parece no tenerlo. Ya que los textos incluidos en los tuits están escritos con la finalidad de intercambiar información entre los seres humanos, y los códigos con los que se escriben estos textos son los que se conocen como lenguaje natural.

Todo esto será llevado a cabo utilizando técnicas y herramientas del campo del procesamiento del lenguaje natural (PLN de ahora en adelante). El PLN es un campo extremadamente extenso y que encuentra usos en infinidad de situaciones. Con técnicas de PLN puede dar valor a casi cualquier dato que se encuentre expresado en lenguaje natural. Todos estos puntos fuertes vienen acompañados de su respectivo nivel de dificultad.

Personalmente, el PLN es un campo que me sorprende y me abruma a partes iguales, pero pienso que en el futuro será un punto clave para todo el desarrollo de soluciones para el análisis de datos. Pienso que todavía hay infinidad de cosas por descubrir y avances por hacer, y que sin duda el desarrollo de estas competencias puede ser positivo para toda la sociedad.

Y es por esto que nos hemos armado de valor y se ha decidido proponer un trabajo que aporte soluciones modernas a un problema que siempre ha existido, pero que en la situación que se está viviendo por el COVID-19 se ha agravado hasta unos límites sorprendentes.

1.2 Objetivos

El objetivo principal de este trabajo es diseñar e implementar un sistema basado en técnicas de procesamiento del lenguaje natural y **aprendizaje automático**, que sea capaz de estimar la evolución cuantitativa del COVID-19 en España, a partir de la información que se publica en *Twitter*. Concretamente, se va a tratar de estimar la serie temporal oficial publicada por el Gobierno de España, sobre la cual también se va a realizar un estudio de la correlación con los datos adquiridos de *Twitter*.

Un sistema como el que se propone habría sido de gran ayuda en el inicio de la pandemia en España, donde muchas (sino todas) las comunidades autónomas se han visto obligadas a desplegar hospitales de campaña urgentemente a causa de la falta de camas en las Unidades de Cuidados Intensivos (**UCI**) de los hospitales.

Tomando en cuenta esto, se propone como objetivo secundario, intentar estimar la evolución cuantitativa de la gravedad de la pandemia, introduciendo una gradación en la gravedad de los casos estimados por el sistema.

1.3 Impacto Esperado

El resultado final de este proyecto podría mejorar la capacidad de los órganos sanitarios a la hora de gestionar la pandemia del COVID-19, apoyando la toma de decisiones en ámbitos de gestión, tales como:

- La gestión de los recursos sanitarios críticos, como pueden ser el número de camas en las Unidades de Cuidados Intensivos (**UCI**) de los hospitales, ya que las camas **UCI** no son solo camas con un respirador: necesitan aparatos especializados, un espacio determinado y profesionales intensivistas.
- A la hora de gestionar las existencias de productos de primera necesidad, como mascarillas o geles hidro-alcohólicos.
- Para dar apoyo a modelos de estimación ya existentes y de uso extendido.

Cabe destacar que los objetivos de este proyecto están fuertemente entrelazados con uno de los 17 *Objetivos de Desarrollo Sostenible* de las Naciones Unidas (ONU).

Concretamente, es el objetivo número tres: salud y bienestar. Ya que el objetivo global de este proyecto se ve englobado dentro de la meta 3.d del objetivo tres. Esta meta dice: «Reforzar la capacidad de todos los países, en particular los países en desarrollo, en materia de alerta temprana, reducción de riesgos y gestión de los riesgos para la salud nacional y mundial» [31].

1.4 Metodología

La siguiente lista muestra los pasos que se van a seguir para alcanzar los objetivos de este trabajo:

1. Recopilar datos de *Twitter*, anonimizándolos y almacenándolos en una base de datos previamente.
2. Evaluar diferentes modelos y configuraciones adecuados para la clasificación de los datos en dos clases: datos surgidos de territorio español y datos surgidos de fuera del territorio español.
3. Implementar el modelo seleccionado en el paso anterior.
4. Realizar una búsqueda bibliográfica de posibles soluciones para transformar esos datos no estructurados en vectores numéricos.
5. Implementar el mecanismo de **vectorización** seleccionado en el paso anterior.
6. Evaluar diferentes modelos y configuraciones adecuados para la estimación de la serie temporal objetivo: la evolución cuantitativa del COVID-19 en España, en este caso.
7. De los modelos y configuraciones evaluadas en el paso anterior, seleccionar e implementar el modelo y configuración que mejores resultados haya dado.
8. Evaluar diferentes modelos y configuraciones adecuados para la estimación de la serie temporal, pero en este caso tomando también como objetivo el número de hospitalizados graves.
9. De los modelos y configuraciones evaluadas en el paso anterior, seleccionar e implementar el modelo y configuración que mejores resultados haya dado.
10. Evaluar el sistema al completo y transformarlo a una librería de *Python 3*.

1.5 Estructura

A continuación se enumeran y comentan cada uno de los capítulos que componen la memoria. También se explica de forma sucinta el contenido que se trata en cada capítulo.

- **Capítulo 1: Introducción:** En este capítulo se realizó una introducción al trabajo y se habló de la motivación, de los objetivos, del impacto esperado y de la metodología a seguir.
- **Capítulo 2: Estado de la cuestión:** Se continuará en el segundo capítulo con el estado de la cuestión y la presentación de nuestra propuesta al problema que se pretende proporcionar una solución.
- **Capítulo 3: Análisis del problema:** A continuación, se dedicará el tercer capítulo a analizar de forma detallada el problema, donde se comentará y se analizará todo lo referente a la seguridad, la eficiencia, el marco legal y ético, y también se identificarán varias soluciones al problema, se propondrá una a desarrollar, se establecerá un plan de trabajo y finalmente se propondrá un presupuesto estimado.

- **Capítulo 4: Diseño de la solución:** En el cuarto capítulo se expondrá el diseño de la solución propuesta en el capítulo anterior, hablando también acerca de la arquitectura y las tecnologías que serán utilizadas.
- **Capítulo 5: Desarrollo de la solución propuesta:** A caballo con el capítulo anterior, se continuará en el quinto capítulo con la descripción detallada del desarrollo de la solución propuesta.
- **Capítulo 6: Implantación:** En el sexto capítulo se hablará acerca de la hipotética implantación del sistema, comentando todo lo que esta conllevaría.
- **Capítulo 7: Pruebas y evaluaciones:** Para finalizar el ciclo de vida del proyecto, se describirán las pruebas y evaluaciones llevadas a cabo y se hablará de los resultados obtenidos en el séptimo capítulo.
- **Capítulo 8: Conclusiones:** En el octavo capítulo se comentarán las conclusiones que se pueden extraer de todo el proceso.
- **Capítulo 9: Trabajos futuros:** Y por último, en el noveno capítulo se hablará de todas las posibles vertientes que abre este trabajo y mejoras que se podrían aplicar en trabajos futuros.

CAPÍTULO 2

Estado de la cuestión

Hoy en día, la necesidad de mejorar las tecnologías preventivas y de reacción ante enfermedades contagiosas se ha visto incrementada. Existen multitud de estudios, artículos y proyectos que se centran en apoyar la batalla contra el COVID-19.

Algunos proyectos se basan en utilizar tecnologías como el **wifi** o **Bluetooth** para poder trazar los brotes de contagio. Algunos de estos proyectos son *OpenCovidTrace*¹, *safepaths*², *CovidWatch*³ o *Radar COVID* [25], siendo esta última el proyecto piloto puesto en marcha por el Gobierno de España.

También existen proyectos que brindan sistemas de diagnóstico, los cuales mediante algunas preguntas clave hacia el usuario son capaces de darle asistencia y pautas en función de las respuestas que da. Un par de ejemplos de sistemas de este tipo pueden ser, por ejemplo, la «Herramienta de evaluación de la COVID-19» de Apple⁴ o *CovApp*⁵, una alternativa apoyada por instituciones alemanas.

Existen proyectos que van tan lejos que llegan a medir diferentes estadísticas e indicadores acerca de la movilidad de la población utilizando los datos obtenidos de diferentes compañías telefónicas. Estas son hoy en día poseedoras de información de gran valor, ya que poseen la información de los movimientos de la población en forma de números de teléfono y torres celulares. A pesar de que esta tecnología no es nueva, ya que se utiliza comúnmente en investigaciones policiales e iniciativas privadas con carácter de mercadotecnia (*marketing*), resulta interesante observar como la comunidad científica está haciendo uso de todo tipo de fuentes de datos con tal de ganarle terreno a la pandemia.

En cuanto al ámbito de la estimación de la evolución cuantitativa, en la web *kaggle*⁶ (que es una web de referencia en cuanto al análisis de datos y **aprendizaje automático**) se están llevando a cabo multitud de competiciones semanales en las que se compite por conseguir el modelo que estime la evolución de los casos confirmados y de los fallecidos con mejor exactitud. En estas competiciones también se valora el hecho de encontrar factores que impacten en la velocidad de transmisión del COVID-19.

¹<https://opencovidtrace.org/>

²<https://safepaths.mit.edu/>

³<https://www.covid-watch.org/>

⁴<https://www.apple.com/covid19>

⁵<https://covapp.charite.de/>

⁶<https://www.kaggle.com/>

Finalmente, en cuanto a **PLN**, en el *National Institute of Standards and Technology* (NIST), la *Text REtrieval Conference* (TREC) también ha lanzado desafíos acerca del almacenamiento y la recuperación de la información, en este caso relacionada con el COVID-19, y que se llama *TREC-COVID*⁷. Y también sigue publicando desafíos en la web *kaggle*. En este campo, también existen proyectos que tienen como objetivo la detección de *fake news* (noticias falsas), ya que en momentos de gran alboroto social y preocupación generalizada, este tipo de noticias son una gran amenaza que puede afectar gravemente a la salud de las personas.

2.1 Propuesta

Como se puede observar, no se ha podido encontrar ningún proyecto que combine una fuente de datos no estructurada, como es el lenguaje natural, con el objetivo de estimar la evolución del COVID-19.

Al observar este «vacío» en la literatura, se decidió combinar estos dos grandes campos, buscando así poder aportar algo de provecho, o al menos avivar la discusión sobre un tema que, personalmente, creemos que va a ser clave en el futuro.

De este modo, se ha elegido *Twitter* como la fuente de datos. Se ha elegido *Twitter* por su ya adquirida fama de ser una fuente de datos variados y abierta, y porque también existen multitud de trabajos anteriores que utilizan *Twitter*.

⁷<https://ir.nist.gov/covidSubmit/data.html>

CAPÍTULO 3

Análisis del problema

En este capítulo se van a analizar algunos de los aspectos más importantes del sistema, como son la seguridad o el marco legal y ético, también se va a proponer un plan de trabajo y se va a explicar y proponer una estimación del coste de la aplicación en desarrollo.

3.1 Análisis de seguridad

En el caso de este sistema, se trata con información que se puede encontrar de forma pública en la red social *Twitter*. Y dado a que no se almacena ningún tipo de información de carácter crítico o sensible, la única capa de seguridad que existe en el sistema es la propia capa de autenticación de *MongoDB*.

Esta capa de seguridad es fácilmente configurable y no depende del propio sistema, sino que depende de la previa instalación y configuración de la base de datos por parte del usuario final.

3.2 Análisis del marco legal y ético

En este apartado se van a analizar todas las implicaciones legales y éticas que afecten a este proyecto. Así como también la postura de propiedad intelectual tomada.

3.2.1. Análisis de la protección de datos

Los datos que se utilizan en este proyecto han sido obtenidos acorde con lo que los términos de uso de la interfaz de programación de aplicaciones (API) de *Twitter* establecen [30]. Y estos datos no se utilizan para ninguna finalidad que pueda vulnerar la privacidad de ningún individuo.

Además, en el momento de recepción de cada unidad de datos (en este caso, el tuit), los datos se anonimizan por completo en un modo de sentido único, eliminando cualquier posible inferencia o relación que lleve al usuario que lo publicó.

Y en cuanto a los datos de la evolución cuantitativa del COVID-19, estos han sido adquiridos de una fuente pública y, de nuevo, no vulneran en ningún sentido la privacidad de ningún individuo al tratarse de datos acumulados a nivel nacional.

3.2.2. Propiedad intelectual

En cuanto a la propiedad intelectual del proyecto, se ha elegido seguir la ideología del código abierto. A estos efectos, la licencia elegida se trata de la licencia MIT ¹. A esta licencia también se le conoce como la licencia *X11*, ya que fue la licencia que portaba el software *X Window System* original del MIT del año 1980.

Esta licencia, a grandes rasgos, permite «usar, copiar, modificar, fusionar, publicar, distribuir, sublicenciar, y/o vender copias del Software». La única condición consiste en que una parte de la licencia ha de aparecer siempre que se copie completamente o un fragmento sustancial del código.

También es importante destacar que la licencia indica expresamente que el software se proporciona «como está» (*as is*) y sin garantía de ningún tipo.

En los apéndices **F** y **G** se puede encontrar la licencia tanto en castellano como en inglés.

3.2.3. Otros aspectos legales

Otro aspecto legal a destacar es que todas las librerías y fuentes de código que se han utilizado en este proyecto son de código libre, no se ha utilizado ningún programa ni librería de licencia propietaria.

3.2.4. Ética

En cuanto a la ética de este proyecto, cabe mencionar que no se ha realizado ninguna actividad ilícita para favorecer la resolución de ningún evento o acontecimiento, ni directa ni indirectamente.

Todos los experimentos aquí enunciados han sido llevados a cabo con información de dominio público. Y en ningún momento se pretende ni condicionar las decisiones de nadie, ni condicionar las conductas, ni alterar el orden público.

Este proyecto ha surgido de la intención de colaborar en la batalla contra un enemigo mundial y en definitiva aportar algo positivo a la literatura.

3.3 Identificación y análisis de soluciones posibles

Las principales decisiones a tomar se centran en elegir:

1. **Sistema de gestión de bases de datos (SGBD):** una variable a considerar es el sistema de gestión de bases de datos a utilizar para almacenar los tuits y los datos. Dos opciones a considerar podrían ser *MongoDB* o *MariaDB*.
2. **Fuente de datos:** otra variable a considerar es la fuente de datos, que en este caso ya se sabe que se ha elegido *Twitter*, pero podrían haber otras opciones, como por ejemplo noticias publicadas en línea, foros u otros tableros de conversación.
3. **Modelos:** unas variables clave sobre las que hay que elegir, una vez ya se sabe el objetivo y el alcance del proyecto, son los modelos que se van a utilizar. Y más aun, las configuraciones o **hiperparámetros** que se van a utilizar con estos modelos.

¹Instituto Tecnológico de Massachusetts

4. **Lenguaje de programación:** también se ha tenido en cuenta una variable esencial para cualquier proyecto informático: el lenguaje de programación sobre el que se va a desarrollar. Este es un tema que siempre suele crear controversia y es por eso que siempre se han de justificar debidamente las decisiones tomadas sobre este. Las opciones para implementar este proyecto eran: *Python*, *R* y *Java*.

A continuación se analizará cada opción y se seleccionará la que se considere más apropiada.

3.4 Solución propuesta

En cuanto al sistema gestor de bases de datos se ha elegido *MongoDB*. Se ha elegido esta opción ya que la forma en la que se puede interactuar con la base de datos es muy sencilla gracias a que utiliza su propio lenguaje de consultas, y no requiere de una especialización para poder empezar a crear prototipos, como podría ocurrir con **SQL**. También se ha elegido esta opción ya que permite una posible distribución de los datos almacenados en varios equipos, y podría ser interesante comprobar como afecta esto al rendimiento del sistema. Finalmente, el motivo principal por el que se ha elegido esta opción es que la estructura de los documentos en una colección (lo que en **SQL** es el esquema de una tabla) no es nada restrictivo, pudiendo así añadir o quitar campos sin tener que hacer una reestructuración completa de la colección, lo cual es muy útil cuando se está experimentando.

En cuanto a la fuente de datos, como ya se ha mencionado en otras partes de la memoria, se ha elegido *Twitter*. Esto es así ya que el acceso a los datos es muy sencillo una vez se dispone de una cuenta de desarrollador de *Twitter*. Además, para obtener los datos de *Twitter* no hay más que hacer una llamada a la **API**, no como si se hubiera elegido otra de las opciones propuestas, donde habría sido necesario implementar también código para extraer los artículos o mensajes de sitios web.

En cuanto a los modelos, se han seleccionado dos modelos para la tarea de clasificación (**SVM** y **ANN**) y tres modelos para la tarea de estimación (regresión lineal, **ANN** y **RNN**). Los modelos elegidos para la tarea de clasificación (**SVM** y **ANN**) son habitualmente utilizados para esta tarea [20] y además ya se disponía de conocimiento previo sobre su funcionamiento. Y en cuanto a los modelos de estimación elegidos (regresión lineal, **ANN** y **RNN**), ocurre lo mismo que con los de clasificación, son modelos que se utilizan con frecuencia en la literatura para llevar a cabo la tarea de estimación [4]. El único inconveniente es que no se dispone de conocimiento previo sobre el funcionamiento de una **RNN**, pero se va a incluir de todas formas a pesar de que lleve algo más de tiempo. Obviamente, al final se deberá de elegir uno de los modelos para cada tarea, pero eso se comenta y justifica en el capítulo 7.

Finalmente, en cuanto al lenguaje de programación, se ha elegido *Python*. En el caso de este proyecto, esta no era una decisión difícil de tomar, ya que *Python* posee algo que las otras opciones no: multitud de librerías que permiten realizar muchas de las tareas de una forma más sencilla, como por ejemplo *Scikit-Learn*, *Keras*, *Numpy* o *Spacy*. También existe otro motivo, y es que *Python* es sin duda el lenguaje de prototipado y experimentación en **aprendizaje automático** por excelencia. La falta de librerías en *R* y *Java* limitan bastante su uso a la hora de utilizarlos para investigación en **PLN** y **aprendizaje automático**. Y *R* (con el cual personalmente no tengo experiencia alguna) tiene un inconveniente más, y es que este tiene una curva de aprendizaje bastante empinada, es decir, que no es un lenguaje sencillo de aprender.

Con todo esto, se propone lo ya mencionado en el apartado 2.1: implementar un sistema capaz de estimar la evolución cuantitativa del COVID-19 a partir de información extraída de *Twitter*, todo ello utilizando técnicas de **aprendizaje automático** y procesamiento del lenguaje natural.

3.5 Plan de trabajo

Para llevar a cabo este proyecto, y dado al gran alcance de las tareas definidas en la metodología que se va a seguir, se ha decidido agrupar las tareas en un esquema de desglose del trabajo (**EDT**).

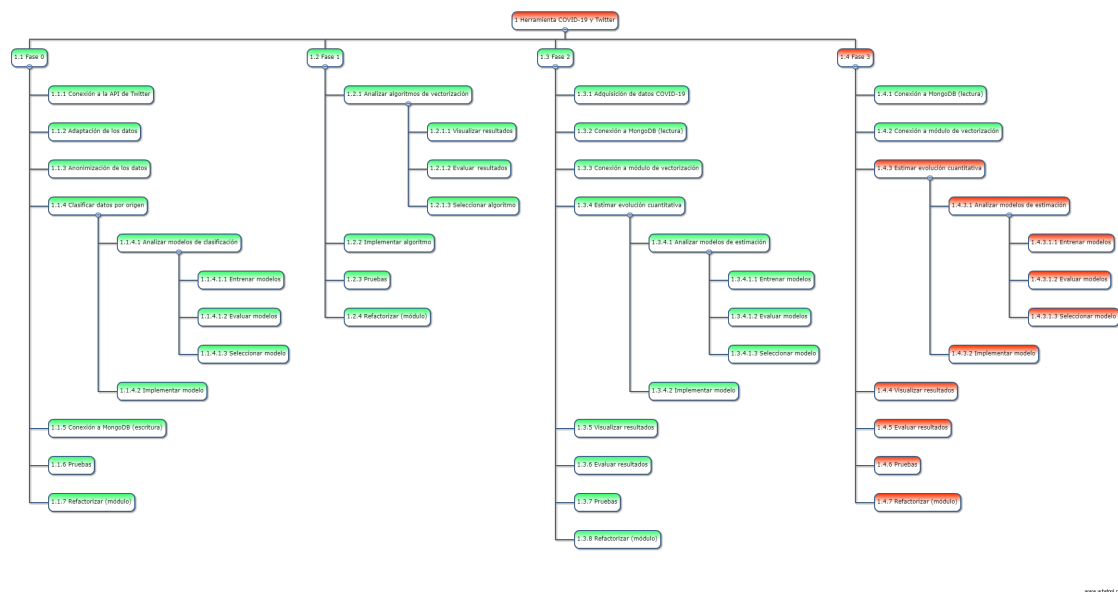


Figura 3.1: Esquema de desglose del trabajo asociado al desarrollo del proyecto.

Como se puede observar, en este esquema se ven representadas las diferentes fases que se habían definido como objetivos anteriormente. Además, también se pueden identificar las tareas definidas en la metodología, pero algunas se han dividido para así representar el trabajo en bloques más concisos.

Debido a la gran amplitud del esquema y al gran número de tareas, se van a analizar por separado cada una de las ramas principales del diagrama, que corresponden directamente con las 4 fases definidas. Y también se hará una breve explicación de cada una de las tareas que las forman, centrándose únicamente en las tareas finales y no en las tareas agrupadoras. Se va a comenzar por la primera rama, la de la *fase 0*.

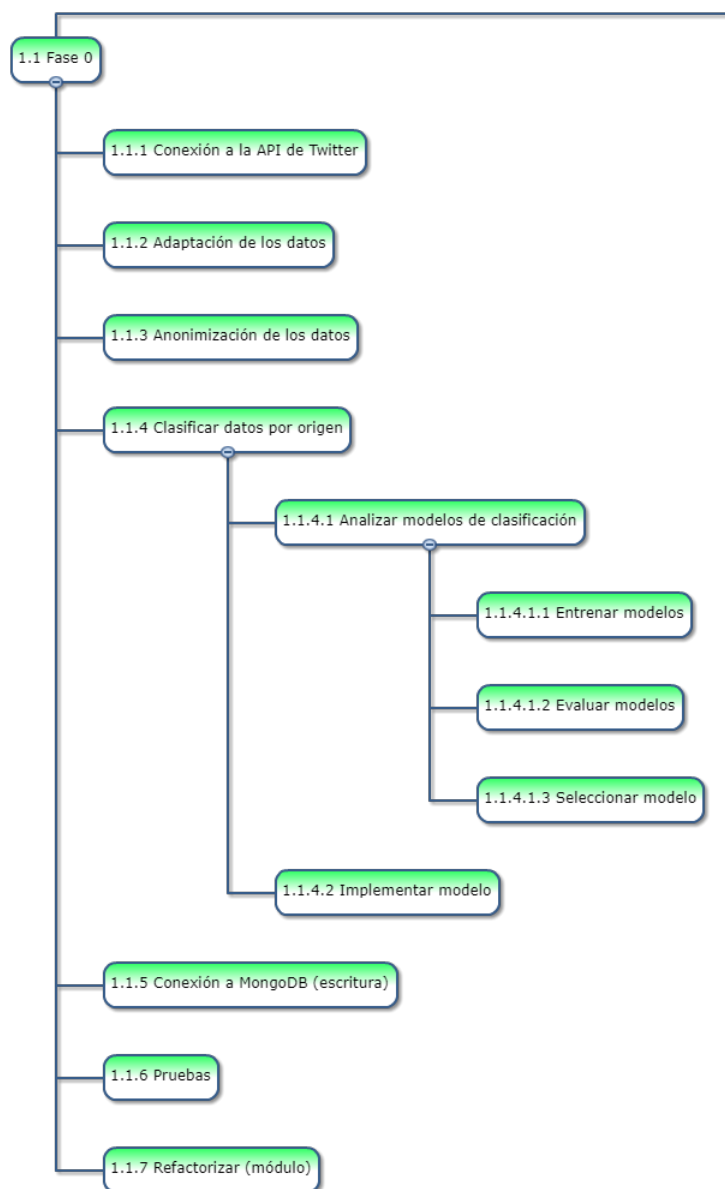


Figura 3.2: Rama de la EDT asociada a la *fase 0*.

Como se puede observar en la figura 3.2, la *fase 0* del proyecto está dividida en diez tareas. A continuación se va a hacer una breve explicación de cada una de las tareas que la componen.

- **Tarea 1.1.1: Conexión a la API de Twitter:** el objetivo de esta tarea es conseguir establecer una conexión correcta a la API de Twitter, utilizando el *endpoint* de la *Stream API* y con la configuración deseada. Esta tarea tiene una duración estimada de 4 horas.

- **Tarea 1.1.2: Adaptación de los datos:** el objetivo de esta tarea es extraer la información relevante para este proyecto de los objetos recibidos. Esto es un detalle importante ya que los objetos recibidos por parte de *Twitter* contienen mucha información² y en este caso solo se necesitarán algunos de los campos: identificador del tuit, identificador del usuario, marca de tiempo de publicación, información acerca de la localización de publicación y el propio texto que contiene el tuit. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.1.3: Adaptación de los datos:** el objetivo de esta tarea es aplicar una transformación a los identificadores de usuarios tal y que se puedan considerar anonimizados. En este caso se ha utilizado la **función de resumen** (*hash function*) llamada *bcrypt* [24]. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.1.4.1.1: Entrenar modelos:** el objetivo de esta tarea es conseguir implementar diferentes modelos de clasificación. En concreto, se quiere llevar a cabo una tarea de clasificación binaria, para poder así clasificar los tuits en dos clases: surgidos del territorio español y surgidos de fuera del territorio español. En cuanto a los modelos, se deberán implementar los siguientes modelos: red neuronal artificial (**ANN**) y máquina de vectores soporte (**SVM**). Cada uno de los experimentos tendrá diferentes **hiperparámetros** a explorar, pero estos serán explicados más adelante en el documento. Esta tarea tiene una duración estimada de 16 horas.
- **Tarea 1.1.4.1.2: Evaluar modelos:** el objetivo de esta tarea es evaluar con diferentes métricas los experimentos realizados en la tarea directamente anterior. En este caso, se utilizarán las siguientes métricas: *precision*, *recall* y *F-score*. Estas métricas serán explicadas más adelante en el documento. Esta tarea tiene una duración estimada de 8 horas.
- **Tarea 1.1.4.1.3: Seleccionar modelo:** el objetivo de esta tarea es seleccionar uno de los modelos y configuraciones con los que se ha experimentado. Este modelo y configuración serán los que se utilizarán en la implementación final del proyecto. En este caso, se seleccionará aquel modelo que cuente con el mejor *F-score*, ya que es la métrica más informada de las tres utilizadas (es decir, es aquella que toma en cuenta más factores a la hora de evaluar). Esta tarea tiene una duración estimada de 8 horas.
- **Tarea 1.1.4.2: Implementar modelo:** el objetivo de esta tarea es implementar el clasificador final con el modelo y configuración que se haya elegido en la tarea directamente anterior. Esta tarea tiene una duración estimada de 8 horas.
- **Tarea 1.1.5: Conexión a MongoDB (escritura):** el objetivo de esta tarea es conseguir implementar el código necesario para poder conectarse a una colección de *MongoDB* desde el código del proyecto y escribir los datos recibidos en ella. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.1.6: Pruebas:** el objetivo de esta tarea es realizar las pruebas necesarias con el fin de comprobar que la base de código de la *fase 0* funciona toda al completo. Esta tarea tiene una duración estimada de 4 horas.

²<https://developer.twitter.com/en/docs/tweets/data-dictionary/overview/tweet-object>

- **Tarea 1.1.7: Refactorizar (módulo):** el objetivo de esta tarea es transformar la base de código escrita hasta el momento en un módulo de *Python*. Esta tarea también es un paso importante, ya que consolida todo el progreso que hubiera hasta el momento en un módulo que ya se puede utilizar en otras aplicaciones de *Python*, ya que todo el código escrito hasta el comienzo de la tarea está en formato de libretas de *Jupyter*. Esta tarea tiene una duración estimada de 8 horas.

Finalmente, la duración total de esta rama de la EDT es de 68 horas. Y seguidamente se va a continuar con la segunda rama de la EDT.

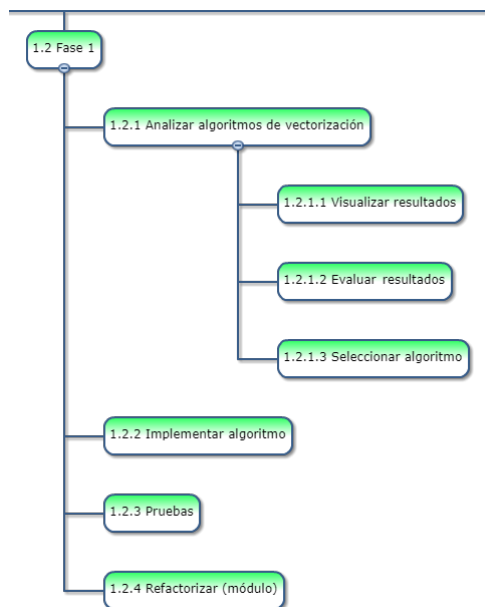


Figura 3.3: Rama de la EDT asociada a la fase 1.

Como se puede observar en la figura 3.3, la fase 1 del proyecto está dividida en seis tareas. A continuación se va a hacer una breve explicación de cada una de las tareas que la componen.

- **Tarea 1.2.1.1: Visualizar resultados:** el objetivo de esta tarea es implementar y experimentar con diferentes algoritmos de **vectorización**. Una vez ya se tienen resultados, se visualizan para así poder tener una idea del funcionamiento del mismo. Esta tarea tiene una duración estimada de 8 horas.
- **Tarea 1.2.1.2: Evaluar resultados:** el objetivo de esta tarea es poder establecer una evaluación de los resultados obtenidos en los experimentos realizados en la tarea directamente anterior. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.2.1.3: Seleccionar algoritmo:** el objetivo de esta tarea es seleccionar el algoritmo de **vectorización** que se va a utilizar en la implementación final del módulo, y para ello se tendrán en cuenta las evaluaciones establecidas en la tarea directamente anterior. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.2.2: Implementar algoritmo:** el objetivo de esta tarea es realizar la implementación final del algoritmo seleccionado en la tarea directamente anterior. Esta será la implementación que nutrirá de datos a los siguientes módulos del sistema. Esta tarea tiene una duración estimada de 8 horas.

- **Tarea 1.2.3: Pruebas:** el objetivo de esta tarea es realizar las pruebas necesarias con el fin de comprobar que la base de código de la *fase 1* funciona toda al completo. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.2.4: Refactorizar (módulo):** el objetivo de esta tarea es transformar la base de código escrita hasta el momento en un módulo de *Python*. Esta tarea también es un paso importante, ya que consolida todo el progreso que hubiera hasta el momento en un módulo que ya se puede utilizar en otras aplicaciones de *Python*, ya que todo el código escrito hasta el comienzo de la tarea está en formato de libretas de *Jupyter*. Esta tarea tiene una duración estimada de 8 horas.

Finalmente, la duración total de esta rama de la EDT es de 36 horas. Y seguidamente se va a continuar con la tercera rama de la EDT.

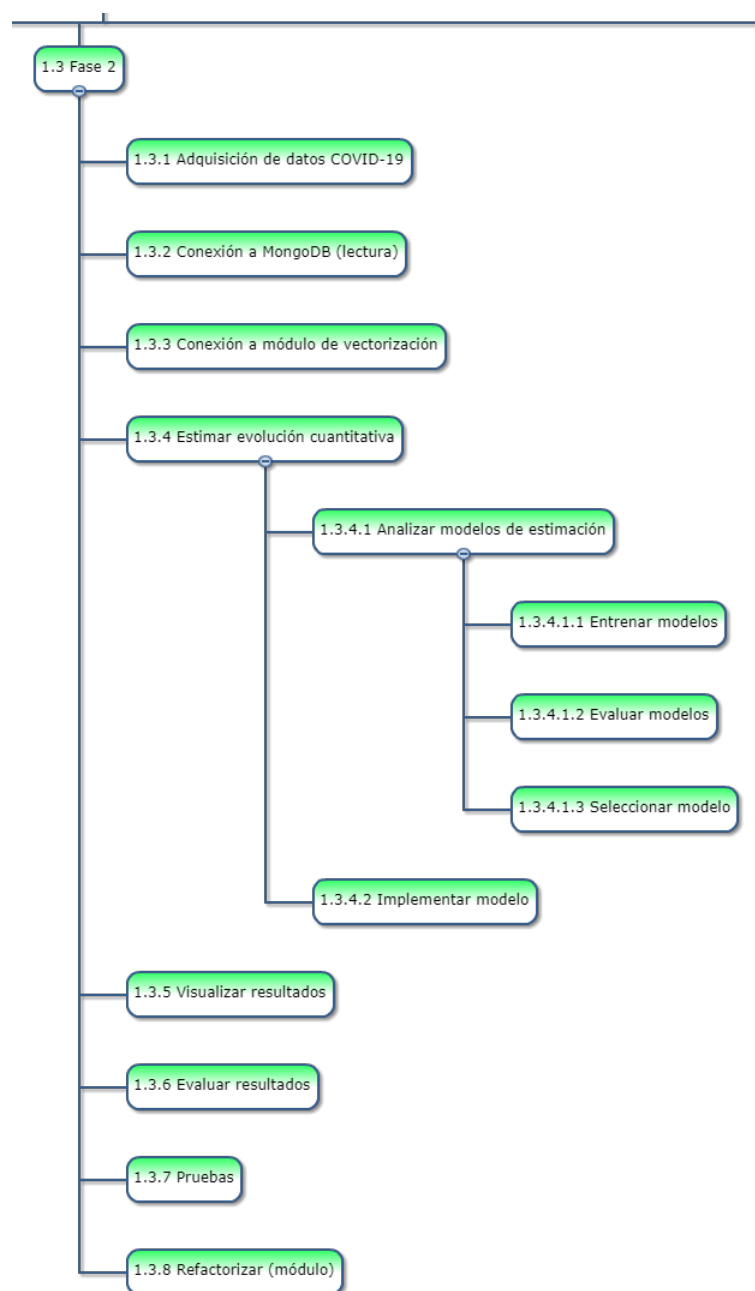


Figura 3.4: Rama de la EDT asociada a la fase 2.

Como se puede observar en la figura 3.4, la *fase 2* del proyecto está dividida en once tareas. A continuación se va a hacer una breve explicación de cada una de las tareas que la componen.

- **Tarea 1.3.1: Adquisición de datos COVID-19:** el objetivo de esta tarea es encontrar una fuente fiable de la cual poder extraer los datos oficiales del COVID-19 en España. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.3.2: Conexión a MongoDB (lectura):** el objetivo de esta tarea es conseguir implementar el código necesario para poder conectarse a una colección de *MongoDB* desde el código del proyecto y leer los datos contenidos en ella. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.3.3: Conexión a módulo de vectorización:** el objetivo de esta tarea es poder establecer una correcta conexión con el módulo de **vectorización** ya existente, ya que este módulo se nutre de los datos generados por el módulo de la *fase 1*. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.3.4.1.1: Entrenar modelos:** el objetivo de esta tarea es conseguir implementar diferentes modelos de estimación. En concreto, lo que se busca es poder estimar la evolución cuantitativa del COVID-19 en España a partir de los datos generados en el módulo de la *fase 1*, por lo que se trataría de una tarea de regresión. En cuanto a los modelos, se deberán implementar los siguientes modelos: regresión lineal (*linreg*), red neuronal artificial (**ANN**) y red neuronal recurrente (**RNN**). Cada uno de los experimentos tendrá diferentes **hiperparámetros** a explorar, pero estos serán explicados más adelante en el documento. Esta tarea tiene una duración estimada de 10 horas.
- **Tarea 1.3.4.1.2: Evaluar modelos:** el objetivo de esta tarea es evaluar con diferentes métricas los experimentos realizados en la tarea directamente anterior. En este caso, se utilizarán las siguientes métricas: error cuadrático medio (MSE), raíz del error cuadrático medio (RMSE), error absoluto medio (MAE) y coeficiente de determinación (R^2). Estas métricas serán explicadas más adelante en el documento. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.3.4.1.3: Seleccionar modelo:** el objetivo de esta tarea es seleccionar uno de los modelos y configuraciones con los que se ha experimentado. Este modelo y configuración serán los que se utilizarán en la implementación final del proyecto. En este caso, se seleccionará aquel modelo que cuente con el mejor R^2 , ya que es la métrica más informada de las cuatro utilizadas (es decir, es aquella que toma en cuenta más factores a la hora de evaluar). Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.3.4.2: Implementar modelo:** el objetivo de esta tarea es implementar el estimador final con el modelo y configuración que se haya elegido en la tarea directamente anterior. Esta tarea tiene una duración estimada de 10 horas.
- **Tarea 1.3.5: Visualizar resultados:** el objetivo de esta tarea es conseguir visualizar las estimaciones que el estimador final implementado proporciona. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.3.6: Evaluar resultados:** el objetivo de esta tarea es evaluar las estimaciones que el estimador final implementado proporciona. Esta tarea tiene una duración estimada de 4 horas.

- **Tarea 1.3.7: Pruebas:** el objetivo de esta tarea es realizar las pruebas necesarias con el fin de comprobar que la base de código de la *fase 2* funciona toda al completo. Esta tarea tiene una duración estimada de 4 horas.

- **Tarea 1.3.8: Refactorizar (módulo):** el objetivo de esta tarea es transformar la base de código escrita hasta el momento en un módulo de *Python*. Esta tarea también es un paso importante, ya que consolida todo el progreso que hubiera hasta el momento en un módulo que ya se puede utilizar en otras aplicaciones de *Python*, ya que todo el código escrito hasta el comienzo de la tarea está en formato de libretas de *Jupyter*. Esta tarea tiene una duración estimada de 8 horas.

Finalmente, la duración total de esta rama de la **EDT** es de 60 horas. Pero en este punto del proyecto aparece un inconveniente, y es que las estimaciones de tiempo asociadas a esta rama son demasiado bajas y estas han llevado mucho más tiempo del estimado. Además de los retrasos y obstáculos surgidos por culpa de la pandemia del COVID-19.

Esto es un fuerte golpe para el proyecto, ya que esto implica que los resultados asociados a la *fase 3* no se pueden proporcionar todavía, ya que el desarrollo de la rama de la *fase 3* aún está en progreso. A continuación se va a continuar con la cuarta y última rama de la **EDT**.

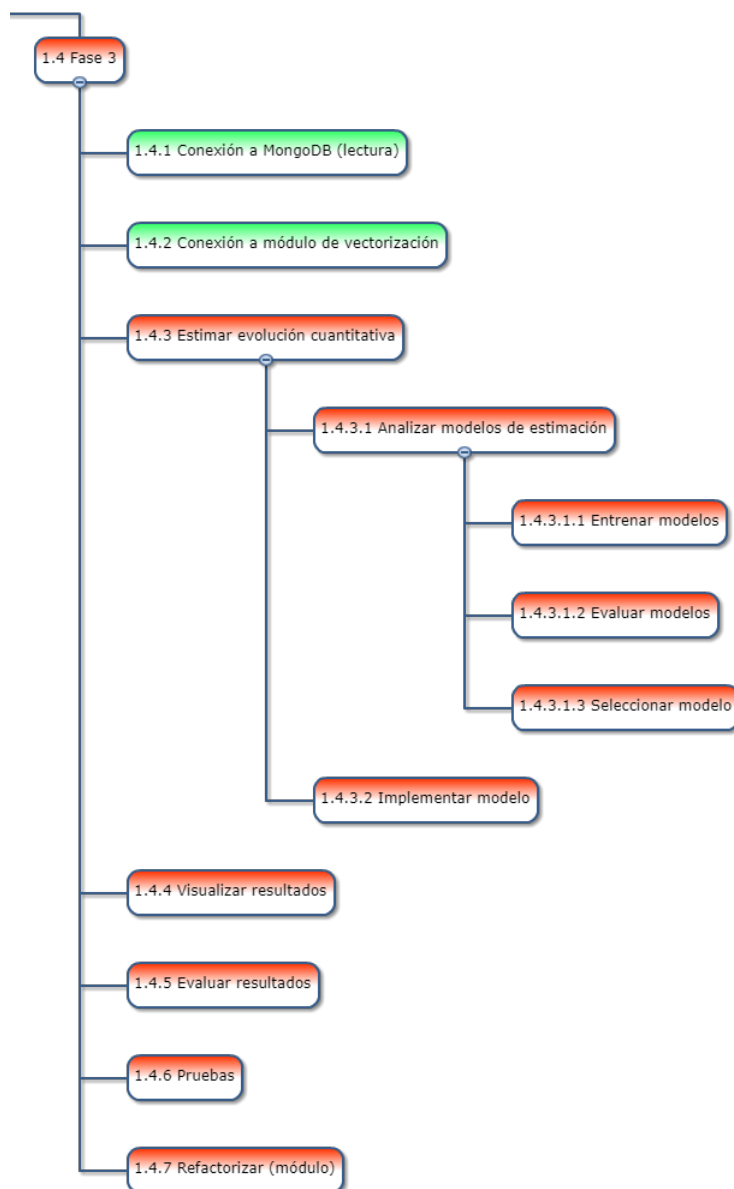


Figura 3.5: Rama de la EDT asociada a la fase 3.

A pesar de lo negativo del inconveniente mencionado, se ha intentado recuperar del error y volver a estimar los tiempos de la fase 3, teniendo en cuenta los tiempos reales de la fase 2. Aunque en el análisis de las tareas se mostrarán los tiempos estimados originales, al final del análisis de esta rama se comentarán los nuevos tiempos estimados.

Como se puede observar en la figura 3.4, la fase 3 del proyecto está dividida en diez tareas. A continuación se va a hacer una breve explicación de cada una de las tareas que la componen.

- **Tarea 1.4.1: Conexión a MongoDB (lectura):** el objetivo de esta tarea es conseguir implementar el código necesario para poder conectarse a una colección de *MongoDB* desde el código del proyecto y leer los datos contenidos en ella. Esta tarea tiene una duración estimada de 4 horas.

- **Tarea 1.4.2: Conexión a módulo de vectorización:** el objetivo de esta tarea es poder establecer una correcta conexión con el módulo de **vectorización** ya existente, ya que este módulo se nutre de los datos generados por el módulo de la *fase 1*. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.4.3.1.1: Entrenar modelos:** el objetivo de esta tarea es conseguir implementar diferentes modelos de estimación. En concreto, lo que se busca es poder estimar la evolución cuantitativa del COVID-19 en España a partir de los datos generados en el módulo de la *fase 1*, por lo que se trataría de una tarea de regresión. La diferencia con la tarea análoga de la *fase 2* es que, en este caso, se va a intentar estimar también el número de hospitalizaciones y no solo el número de casos totales, como ocurre en la *fase 2*. En cuanto a los modelos, se deberán implementar los siguientes modelos: regresión lineal (*linreg*), red neuronal artificial (**ANN**) y red neuronal recurrente (**RNN**). Cada uno de los experimentos tendrá diferentes **hiperparámetros** a explorar, pero estos serán explicados más adelante en el documento. Esta tarea tiene una duración estimada de 14 horas.
- **Tarea 1.4.3.1.2: Evaluar modelos:** el objetivo de esta tarea es evaluar con diferentes métricas los experimentos realizados en la tarea directamente anterior. En este caso, se utilizarán las siguientes métricas: error cuadrático medio (MSE), raíz del error cuadrático medio (RMSE), error absoluto medio (MAE) y coeficiente de determinación (R^2). Estas métricas serán explicadas más adelante en el documento. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.4.3.1.3: Seleccionar modelo:** el objetivo de esta tarea es seleccionar uno de los modelos y configuraciones con los que se ha experimentado. Este modelo y configuración serán los que se utilizarán en la implementación final del proyecto. En este caso, se seleccionará aquel modelo que cuente con el mejor R^2 , ya que es la métrica más informada de las cuatro utilizadas (es decir, es aquella que toma en cuenta más factores a la hora de evaluar). Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.4.3.2: Implementar modelo:** el objetivo de esta tarea es implementar el estimador final con el modelo y configuración que se haya elegido en la tarea directamente anterior. Esta tarea tiene una duración estimada de 10 horas.
- **Tarea 1.4.4: Visualizar resultados:** el objetivo de esta tarea es conseguir visualizar las estimaciones que el estimador final implementado proporciona. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.4.5: Evaluar resultados:** el objetivo de esta tarea es evaluar las estimaciones que el estimador final implementado proporciona. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.4.6: Pruebas:** el objetivo de esta tarea es realizar las pruebas necesarias con el fin de comprobar que la base de código de la *fase 3* funciona toda al completo. Esta tarea tiene una duración estimada de 4 horas.
- **Tarea 1.4.7: Refactorizar (módulo):** el objetivo de esta tarea es transformar la base de código escrita hasta el momento en un módulo de *Python*. Esta tarea también es un paso importante, ya que consolida todo el progreso que hubiera hasta el momento en un módulo que ya se puede utilizar en otras aplicaciones de *Python*, ya que todo el código escrito hasta el comienzo de la tarea esta en formato de libretas de *Jupyter*. Esta tarea tiene una duración estimada de 8 horas.

Finalmente, la duración total de esta rama de la EDT es de 60 horas. Pero, como ya se ha comentado anteriormente, se han vuelto a estimar los tiempos expuestos. Por el bien de la veracidad, en ningún momento se intenta ocultar de ningún modo el error cometido. Como dijo el célebre científico español Santiago Ramón y Cajal, «*Lo peor no es cometer un error, sino tratar de justificarlo, en vez de aprovecharlo como aviso providencial de nuestra ligereza o ignorancia*». Este error ha surgido a partir de una combinación de falta de experiencia a la hora de estimar y de una subestimación del esfuerzo asociado al autoaprendizaje de nuevas técnicas, y sin duda no habrá sido cometido en vano.

Tras volver a estimar los tiempos de esta rama, se estima que la duración total debería de ser de aproximadamente 120 horas, es decir, aproximadamente 60 horas más que las originalmente estimadas. Estas 60 horas de más deberían de ser repartidas entre las tareas más pesadas. Gracias a la experiencia obtenida en la fase 2, se podría decir que estas tareas son: 1.4.3.1.1, 1.4.3.1.1, 1.4.3.2 y 1.4.5.

Por último, mencionar que, como se ha podido observar, en la EDT se puede ver una codificación por color (rojo y verde). Esta codificación se utiliza para poder visualizar de una forma rápida y sencilla el progreso en las tareas: las tareas con color rojo aun no se han completado y las tareas en color verde sí.

3.6 Presupuesto

Aunque este proyecto ha sido llevado a cabo de forma individual y utilizando los recursos materiales de los que ya se disponía de forma personal, se ha realizado una estimación del presupuesto.

Este presupuesto es el asociado a el desarrollo y mantenimiento del sistema durante la duración del mismo. Este incluye todos los recursos humanos y materiales que habrían sido necesarios para poder llevar a cabo el desarrollo de una forma más eficiente y productiva.

En cuanto a los recursos humanos, sería necesario un equipo compuesto de:

- **Un investigador:** el investigador es el encargado de escanear la literatura en busca de contenido relevante, así como también de experimentar y evaluar las propuestas encontradas. Cubrir este puesto conlleva un gasto de 6 € por hora.
- **Un jefe de proyecto:** el jefe de proyecto es el encargado de coordinar y organizar el resto del equipo, así como de llevar un seguimiento de las tareas a realizar. Cubrir este puesto conlleva un gasto de 12,80 € por hora.
- **Un analista:** el analista es el encargado de validar y garantizar que todo el código producido mantiene una calidad adecuada, así como de coordinar y organizar el trabajo del desarrollador. Cubrir este puesto conlleva un gasto de 7,20 € por hora.
- **Un desarrollador con experiencia:** el desarrollador es el encargado de la implementación del código, así como de llevar a cabo cualquier tipo de refactorización necesaria. Cubrir este puesto conlleva un gasto de 12,50 € por hora.
- **Un administrador de sistemas:** por último, el administrador de sistemas es el encargado de garantizar que toda la infraestructura, equipos y servidores funcionan correctamente y también que ningún servicio se interrumpa. Cubrir este puesto conlleva un gasto de 8,80 € por hora.

Mencionar que los salarios previamente expuestos están calculados a partir de los sueldos promedio que se pueden encontrar en el portal de empleo indeed.es³, asumiendo que un mes cuenta de 240 horas. Y por otra parte, en cuanto a los recursos materiales, serían necesarios los siguientes equipos e infraestructuras:

- **Cinco ordenadores personales:** ordenadores básicos, necesarios para que el equipo pueda realizar tareas de desarrollo, organización, etc. Teniendo en cuenta un coste de 893,54€ por unidad (se ha elegido el modelo ThinkPad T495 de Lenovo⁴), el coste total de estos equipos sería de 4.467,70€.
- **Un servidor con alta capacidad de almacenamiento:** equipo necesario para poder mantener el servicio de recopilación, con capacidad suficiente para poder albergar todos los datos que se reciban. Este tendría un coste 1.695,05€, habiendo elegido el modelo HPE ProLiant DL20 Gen10 E-2236, el cual cuenta con 32 *gigabytes* de memoria RAM y dos discos duros de un *terabyte* cada uno.⁵
- **Un equipo de cómputo de altas prestaciones:** equipo necesario para poder llevar a cabo experimentos y evaluaciones de modelos de una forma eficiente y rápida. Idealmente, este equipo estaría dotado de una o varias tarjetas de procesamiento gráfico (**GPU**), las cuales resultan de gran utilidad a la hora de experimentar con modelos de **aprendizaje automático**. En este caso se ha elegido un modelo de Lambda, concretamente el modelo básico de cuatro **GPU**⁶. El precio de este equipo es de 9.752,07€ (sin tener en cuenta impuestos y envío).
- **Infraestructura:** este apartado incluye la instalación de red necesaria para interconectar el resto de equipos, así como también la propia conexión a internet, entre otras cosas. Debido a que este proyecto se desarrolla en un entorno universitario, los costes de este apartado se consideran cubiertos por la propia universidad.
- **Otros gastos:** en este apartado se incluyen los gastos relativos a materiales de oficina, eventualidades, etc. Como ocurre con los gastos de infraestructura, estos gastos varios también se van a considerar cubiertos por parte de la universidad.

Una vez ya se han expuesto los costes individuales, se puede hacer una estimación de lo que sería el coste total del proyecto. Como ya se ha mencionado anteriormente, este presupuesto incluye todos los gastos asociados al desarrollo y mantenimiento del sistema durante la duración del mismo.

En cuanto a los costes no materiales, se puede decir que el coste total de una hora de trabajo del equipo es 47,30€. Teniendo en cuenta que el número de horas estimado para completar el proyecto es de 344 horas (tras una segunda estimación del tiempo para la tercera fase), se puede decir que los costes no materiales ascienden a 16.271,20€.

Y en cuanto a los costes materiales, tras agregar los costes individuales de todos los equipos y materiales, el coste asciende a 15.914,17€. Comentar que a pesar de que estos costes sean elevados, una vez finaliza el desarrollo de este proyecto, estos equipos siguen resultando útiles para proyectos posteriores, por lo que este coste se puede amortizar más allá de este proyecto.

³<https://es.indeed.com/salaries>

⁴<https://www.lenovo.com/es/es/laptops/thinkpad/t-series/T495/p/22TP2TTT495>

⁵<https://buy.hpe.com/es/es/servers/rack-servers/proliant-dl20-servers/proliant-dl20-server/hpe-proliant-dl20-gen10-server/p/1011028697>

⁶<https://lambdalabs.com/deep-learning/amd-workstations/4-gpu/customize>

Categoría	Recurso	Coste
Recursos no materiales	Investigador	2.064 €
	Jefe de proyecto	4.403,20 €
	Analista	2.476,80 €
	Desarrollador	4.300 €
	Administrador de sistemas	3.027,20 €
Recursos materiales	Cinco equipos personales	4.467,70 €
	Servidor de almacenamiento	1.695,05 €
	Equipo de cómputo	9.752,07 €
Coste total		32.185,37 €

Tabla 3.1: Tabla resumen del presupuesto

Finalmente, se puede decir que el coste total estimado para llevar a cabo este proyecto sería de 32.185,37 €. En la tabla 3.1 se puede observar un resumen. Un detalle importante es que los precios aquí mostrados son vigentes a fecha de escritura.

CAPÍTULO 4

Diseño de la solución

A continuación se va a explicar el diseño del sistema, empezando por la arquitectura del sistema, continuando con el diseño del mismo y finalizando con la tecnología utilizada.

4.1 Arquitectura del sistema

Se ha elegido una arquitectura simple para el sistema bajo desarrollo. Esta arquitectura está formada por cuatro módulos que interactúan entre si mediante el uso de una base de datos. Aquí se puede ver un esquema general de la arquitectura y del intercambio de datos entre los componentes del sistema.

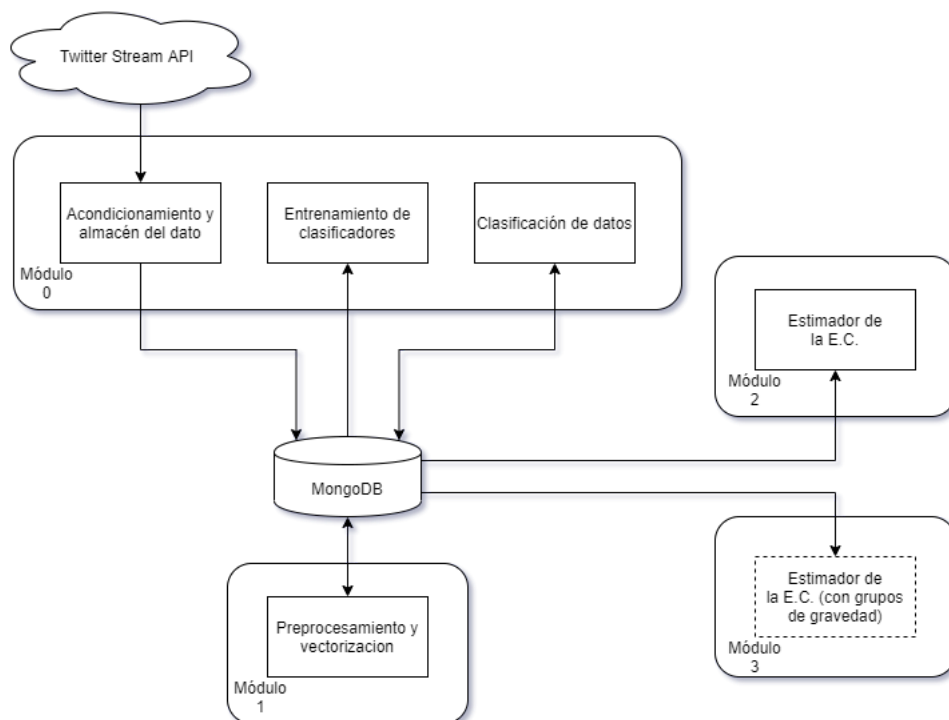


Figura 4.1: Diagrama de la arquitectura del sistema. En él se pueden apreciar los diferentes módulos independientes.

Además, se ha elegido una arquitectura en la que el punto de confluencia de los datos es una base de datos. Esta base de datos estaría idealmente instalada en un servidor accesible desde el resto de equipos, ya que gracias a ese detalle todo el equipo podría trabajar y/o experimentar de forma paralela sobre el mismo conjunto de datos continuamente creciente.

4.2 Diseño detallado

Para comenzar, se va a extender sobre el diagrama de la figura 4.1. Y a continuación, se va a hacer una explicación de cada uno de los casos de uso que tiene el sistema.

Como ya se ha mencionado anteriormente, en la figura 4.1 se pueden observar los diferentes módulos en los que se divide el sistema, los cuales se asocian directamente con las fases definidas en los objetivos.

4.2.1. Módulo 0

El *módulo 0*, el cual se asocia con la fase de recopilación y acondicionamiento de datos (*fase 0*), se encarga de algunas de las tareas clave del sistema.

Primero, es el encargado de establecer una conexión a la *Stream API* de *Twitter* y recibir los tuits filtrados en tiempo real. Estos tuits, una vez ya se han truncado (es decir, se ha eliminado la información que no se considera relevante) y anonimizado, se almacenan en una colección de la base de datos.

La *Stream API* de *Twitter* permite filtrar los tuits por lenguaje y por la aparición de términos. También permite filtrar por la localización de publicación del tuit, pero el volumen de los tuits que contienen información de localización es aproximadamente inferior a un 1 % del total de los tuits publicados [11].

Dado a que el alcance del proyecto se centra principalmente en el ámbito del territorio español y que el castellano es el tercer idioma más utilizado en internet [7], se halla la necesidad de clasificar los tuits que se obtienen en dos clases, es decir, una tarea de clasificación binaria: origen en territorio español y origen fuera del territorio español.

De esta tarea también se encarga este módulo. Para ello utiliza como datos de entrenamiento los tuits que si que incluyen información de la localización. Adicionalmente, el modelo se puede entrenar múltiples veces, ya que cuantos más datos se encuentren disponibles, mejor será el modelo resultante.

Finalmente, este módulo también se encarga de clasificar aquellos tuits que no contengan la información de localización, y para ello hace uso de uno de los modelos que se encuentren disponibles. Los resultados de la clasificación se almacenan junto a cada tuit en la propia base de datos, en forma de un campo adicional.

4.2.2. Módulo 1

El *módulo 1* es el que se asocia con la fase de procesamiento y **vectorización** de los datos (*fase 1*). Este módulo se encarga de la tarea más pesada de todo el sistema: la transformación de los tuits en una serie de vectores.

La tarea de este módulo es seleccionar y leer de la base de datos todos aquellos tuits que se hayan clasificado como que tienen origen en el territorio español.

Una vez está en posesión de esta información, analiza uno a uno los tuits. Para ello se va a utilizar el `CountVectorizer` de *Scikit-Learn*, pero no se van a contar todos los términos.

Lo que se hace es fijar el vocabulario del `CountVectorizer` a una serie de síntomas y términos fuertemente relacionados con el COVID-19. Y tanto este vocabulario como todas las palabras de los tuits son pasados por un transformador antes de aplicar el vectorizador. Este transformador, llamado *lematizador*, convierte cada palabra en su raíz, de tal forma que se agrupan todas las formas verbales de un mismo verbo y todas variaciones de un mismo sustantivo. Para ello, se utilizará la librería *Spacy*.

Finalmente, los vectores se agrupan por la unidad temporal seleccionada, que es el día, y se almacena la matriz resultante en la base de datos. Esta matriz tiene la forma de $M \times N$, siendo M el número de días que se hayan tenido en cuenta y N la longitud del vocabulario seleccionado.

4.2.3. Módulo 2

A continuación, el *módulo 2* es el que se encuentra directamente asociado a la estimación de la evolución cuantitativa (E.C.) del COVID-19. Este se encarga de finalmente darle un valor a los datos procesados, es decir, se podría decir que es uno de los finales de la línea de tratamiento de los datos.

Este módulo lo que hace es cargar una de las matrices producidas por el *módulo 1* y con ella entrena y evalúa un estimador de la E.C. del COVID-19. Además de usar la matriz cargada de la base de datos, utiliza datos adquiridos de un repositorio que mantiene actualizados los datos oficiales de la E.C.¹. Concretamente se utiliza el archivo «`nacional_covid19.csv`».

Finalmente, el módulo produce un informe en el cual se puede observar la evolución estimada junto a los resultados de la evaluación del modelo entrenado. De nuevo, este modelo se beneficia de la continua adquisición de datos, ya que cuantos más volumen de datos este disponible, mejor será el modelo resultante.

4.2.4. Módulo 3

Por último, se va a hablar del *módulo 3*, el cual se encuentra directamente asociado con la estimación de la E.C. del COVID-19 (*fase 3*). El detalle añadido a la tarea que resuelve este módulo es que no estima únicamente la E.C. del COVID-19 en cuanto al número de casos, sino que también estima la E.C. en cuanto al número de hospitalizaciones.

La estructura de este módulo sería idéntica a la del *módulo 2*. Para llevar a cabo este módulo se podría experimentar con diferentes variantes a la hora de transformar los tuits en vectores, como por ejemplo incluir en los vectores un recuento de cuantos tuits podrían ser considerados graves, considerando un tuit grave como un tuit que cuente con más de x términos del vocabulario (x sería un **hiperparámetro** con el que experimentar).

Dado a errores ya mencionados en la estimación del tiempo asociado a las diferentes tareas, este módulo aun se encuentra en proceso de desarrollo, por lo que la configuración final de mismo aun no se encuentra disponible, aun está en fase de experimentación.

¹<https://github.com/datadista/datasets/tree/master/COVID%2019>

4.2.5. Casos de uso del sistema

Después de realizar un análisis exhaustivo, se han detectado dos actores: i) el usuario final y ii) la API de *Twitter*. La figura 4.2 muestra los casos de uso correspondientes tanto al usuario final como a la API de *Twitter*.

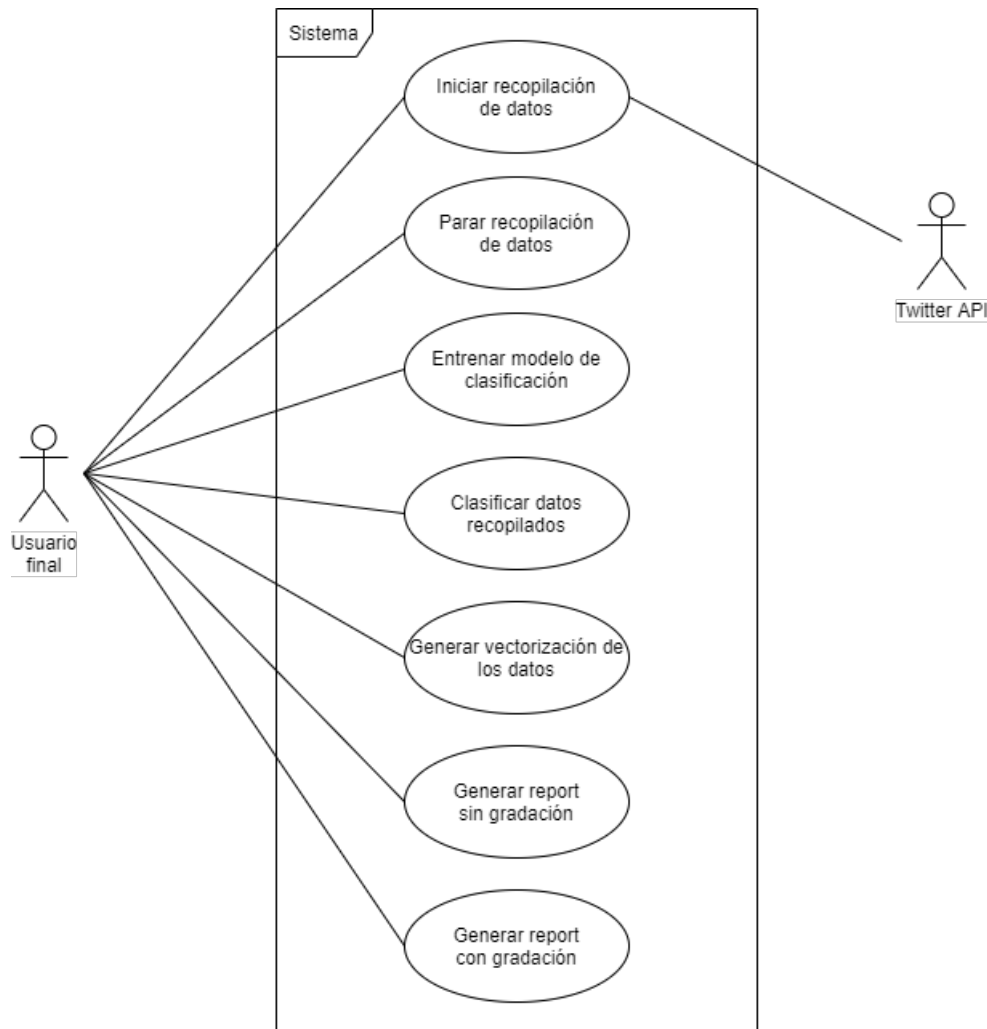


Figura 4.2: Diagrama de casos de uso del sistema.

A continuación se describe cada uno de los casos de uso del usuario final.

- **Caso de uso 1: Iniciar recopilación de datos:** este caso de uso pertenece al *módulo 0*. En este caso, el propio nombre del caso de uso es descriptivo en cuanto a las acciones que implica. El desencadenante de este caso de uso es el usuario final, el cual al ejecutar el *módulo 0* puede decidir iniciar la recopilación de datos. Estas acciones pueden ser llevadas a cabo siempre y cuando el usuario se encuentre en el menú de selección de acciones del *módulo 0* y se harán efectivas siempre que la recopilación no estuviera ya iniciada. En el caso contrario simplemente se muestra un mensaje de error.

- **Caso de uso 2: Parar recopilación de datos:** este caso de uso también pertenece al *módulo 0*. Igual que en el caso anterior (y porque es el caso directamente contrario), el nombre de este caso también es descriptivo. El desencadenante de este caso de uso es el usuario final, el cual puede decidir detener la recopilación de datos. Estas acciones pueden ser llevadas a cabo siempre y cuando el usuario se encuentre en el menú de selección de acciones del *módulo 0* y se harán efectivas siempre que la recopilación estuviera ya iniciada. En el caso contrario simplemente se muestra un mensaje de error.
- **Caso de uso 3: Entrenar modelo de clasificación:** este caso de uso también pertenece al *módulo 0*. El desencadenante de este caso de uso es el usuario final, el cual al ejecutar el *módulo 0* puede decidir entrenar un nuevo modelo de clasificación de localización. Estas acciones pueden ser llevadas a cabo siempre y cuando el usuario se encuentre en el menú de selección de acciones del *módulo 0* y se harán efectivas siempre y cuando se disponga de datos válidos para entrenar. En el caso contrario se muestra un mensaje de error y se cierra la ejecución del módulo.
- **Caso de uso 4: Clasificar datos recopilados:** este caso de uso también pertenece al *módulo 0*. El desencadenante de este caso de uso es el usuario final, el cual al ejecutar el *módulo 0* puede decidir clasificar los datos utilizando uno de los modelos previamente entrenados. Estas acciones pueden ser llevadas a cabo siempre y cuando el usuario se encuentre en el menú de selección de acciones del *módulo 0* y se harán efectivas siempre y cuando se disponga de datos válidos a clasificar y de un modelo previamente entrenado por el sistema. En el caso contrario se muestra un mensaje de error y se cierra la ejecución del módulo.
- **Caso de uso 5: Generar **vectorización** de los datos:** este caso de uso es el único que pertenece al *módulo 1*. El desencadenante de este caso de uso es el usuario final, el cual puede generar una **vectorización** mediante el uso del *módulo 1* en una aplicación de *Python 3*. Estas acciones pueden ser llevadas a cabo siempre y cuando el usuario haga un uso correcto del *módulo 1* en su aplicación de *Python 3* y se harán efectivas siempre y cuando se disponga de datos previamente clasificados. En el caso contrario se muestra un mensaje de error y se cierra la ejecución de la aplicación.
- **Caso de uso 6: Generar informe de la E.C. sin gradación:** este caso de uso es el único que pertenece al *módulo 2*. El desencadenante de este caso de uso es el usuario final, el cual puede generar un informe sobre la E.C. (sin gradación) estimada del COVID-19 mediante el uso del *módulo 2* en una aplicación de *Python 3*. Estas acciones pueden ser llevadas a cabo siempre y cuando el usuario haga un uso correcto del *módulo 2* en su aplicación de *Python 3* y se harán efectivas siempre y cuando se disponga de una **vectorización** realizada previamente. En el caso contrario se muestra un mensaje de error y se cierra la ejecución de la aplicación.
- **Caso de uso 7: Generar informe de la E.C. con gradación:** este caso de uso es el único que pertenece al *módulo 3*, es un caso de uso análogo al caso de uso 6. El desencadenante de este caso de uso es el usuario final, el cual puede generar un informe sobre la E.C. (con gradación) estimada del COVID-19 mediante el uso del *módulo 3* en una aplicación de *Python 3*. Estas acciones pueden ser llevadas a cabo siempre y cuando el usuario haga un uso correcto del *módulo 3* en su aplicación de *Python 3* y se harán efectivas siempre y cuando se disponga de una **vectorización** realizada previamente. En el caso contrario se muestra un mensaje de error y se cierra la ejecución de la aplicación.

4.3 Tecnología utilizada

En este apartado se describen todas aquellas tecnologías que se prevé que serán utilizadas en el desarrollo del sistema, describiendo también el uso que se hará de cada una de ellas.

4.3.1. Python 3

Python [17, 10] es un lenguaje de programación cuya popularidad ha explotado sorprendentemente en estos últimos años, y esta será la tecnología base del proyecto. El sistema estará compuesto por una serie de archivos fuente de *Python* que funcionarán todos en conjunto para obtener los resultados esperados.



Figura 4.3: Logotipo de *Python*

Se ha elegido *Python* debido a que es un lenguaje sencillo y rápido para escribir prototipos, a pesar de que la velocidad de ejecución de los programas no será comparable con el mismo programa escrito en C o C++, por ejemplo. Y también porque existen multitud de librerías para el tratamiento del lenguaje natural y **aprendizaje automático**, haciendo estas tareas más simples y transparentes.

Concretamente, se ha elegido la versión 3 de *Python* porque las librerías externas que se va a utilizar son todas compatibles con esta. Para ser más específicos, se va a utilizar la versión 3.8.2 de *Python*.

A continuación se van a mencionar las diferentes utilidades y librerías que se van a utilizar en *Python*.

Jupyter Notebook

Jupyter Notebook [23] es una aplicación de servidor que funciona como un entorno de desarrollo para *Python* y para acceder a este solo es necesario un navegador. Se ha elegido este entorno porque se pueden tener varias ejecuciones de código simultáneas y se puede identificar cada una de ellas de una forma muy visual.



Figura 4.4: Logotipo de *Jupyter Project*

En *Jupyter Notebook*, el código de *Python* se ve dividido en bloques de ejecución, de los cuales se pueden tener tantos como sea necesarios, y luego estos bloques se ejecutan de forma independiente y en el orden deseado, pero compartiendo todos el mismo contexto de ejecución.

Se va a utilizar esta aplicación para llevar a cabo todo el proceso de desarrollo de la parte de código en *Python*.

Visual Studio Code

Visual Studio Code es un entorno de desarrollo integrado (IDE). Este IDE es muy ligero y además permite el fácil acceso a multitud de complementos (oficiales y creados por la comunidad) gracias a los que se puede extender las utilidades que ofrece.




Figura 4.5: Logotipo de *Visual Studio Code*

Se va a usar este IDE en las tareas de desarrollo de los módulos de *Python 3*, una vez la experimentación haya concluido. El uso de terminales dentro del propio IDE y el depurador facilitan la tarea de desarrollar los módulos a partir de las libretas de *Jupyter*.

Tweepy

Tweepy [29] es una librería para *Python* que hace la conexión con la API de *Twitter* más transparente. Para utilizarla, previamente se ha de obtener acceso a la API de *Twitter* y una vez ya se tiene una clave es solo cuestión de introducir las credenciales de la API en el código de *Python* y comenzar a utilizarla.

Se va a utilizar concretamente la funcionalidad de la API para filtrar tuits en tiempo real (*Stream API*), con la cual se van a filtrar aquellos tuits que contengan el término *coronavirus* y que estén escritos en castellano.

PyMongo

PyMongo [19] es la librería que se va a utilizar a modo de *middleware* (o lógica de intercambio de información entre aplicaciones) entre el sistema en *Python* y el sistema gestor de bases de datos documentales *MongoDB*, donde se encuentra almacenada la información a analizar.

Spacy

Spacy [1] es la librería que se va a utilizar para resolver las sub tareas que aparezcan en el sistema, un par de ejemplos son la lematización de *tokens* (o palabras) y el análisis de dependencias (análisis sintáctico) de una sentencia en lenguaje natural (en este caso castellano).



Figura 4.6: Logotipo de *Spacy*

Spacy también es muy útil como herramienta general para PLN, ya que ayuda a crear un flujo de trabajo, haciendo que este sea fácilmente entendible y modificable.

Pandas

Pandas [33] es una librería de *Python* que permite de una forma sencilla y flexible la manipulación de datos, como por ejemplo el acoplamiento correcto de dos series temporales, o el acondicionamiento o eliminación de datos mal formados.



Figura 4.7: Logotipo de *Pandas*

Se va a utilizar esta herramienta y no otra ya que la cantidad y la variedad del dato que se va a tratar no es trivial y *Pandas* facilita bastante su tratamiento y manipulación de información variada.

Numpy

Numpy [21, 32] es la librería por excelencia para realizar cualquier tipo de computación matemática en *Python*. Esta permite realizar operaciones matriciales con una alta eficiencia.




Figura 4.8: Logotipo de *Numpy*

Se va a utilizar *Numpy* para realizar el tratamiento de la información una vez que ya ha sido vectorizada, es decir, transformada en un vector numérico.

Scikit-Learn

Scikit-Learn [22] es una librería para *Python* que implementa multitud de algoritmos, clasificadores y herramientas que resultan útiles para cualquier proyecto de análisis de datos.

Los modelos de esta librería que se van a utilizar son concretamente *LinearRegression* (que es un modelo para llevar a cabo una regresión lineal estándar) y *LinearSVC* (que es un modelo de máquina de vectores soporte, un clasificador).



Figura 4.9: Logotipo de *Scikit-Learn*

Además de incluir clasificadores y regresores clásicos (los cuales operan sobre vectores numéricos), también incluye herramientas para el tratamiento de texto. De estas, se utilizarán un par de los vectorizadores que incluye, más concretamente, el *CountVectorizer* y el *TfidfVectorizer*.

Keras

Keras [8] es una de las librerías para el aprendizaje profundo en *Python* de las más utilizadas. Su uso es a muy alto nivel, lo que permite crear, entrenar y evaluar una infinidad de modelos de una forma sencilla.



Figura 4.10: Logotipo de *Keras*

Se utilizarán modelos de *Keras* para realizar las varias tareas de clasificación y estimación que hay repartidas a lo largo del proyecto.

Matplotlib

Matplotlib [13] es una librería de *Python* que va a permitir visualizar los resultados obtenidos hasta el momento en cualquier punto del proyecto. Se va a utilizar para generar todos los gráficos que se expondrán en este trabajo.



Figura 4.11: Logotipo de *Matplotlib*

bcrypt

bcrypt [2] es la librería que aporta la funcionalidad de utilizar la **función de resumen** (*hash function*) que porta el mismo nombre que la librería: *bcrypt*.

4.3.2. MongoDB

Finalmente, *MongoDB* [18] es el sistema gestor de bases de datos documentales que se va a utilizar a lo largo de todo el sistema. Las bases de datos documentales están enfocadas en alcanzar buenos rendimientos al tratar con conjuntos de datos distribuidos muy grandes.



Figura 4.12: Logotipo de *MongoDB*

A diferencia de las bases de datos relacionales convencionales, *MongoDB* no almacena los datos estructurados en tablas predefinidas, sino que almacena datos no estructurados en lo que se denominan colecciones, donde no hay una estructura predefinida.

Estos datos no estructurados se asemejan bastante al formato **JSON** y los datos que se va a recibir de la **API** de *Twitter* vienen en un formato similar, así que la tarea de almacenar y consumir la información se hace de una forma más transparente si se utiliza *MongoDB*, ese es el motivo principal por el que se ha elegido.

Desarrollo de la solución propuesta

En este capítulo se describirán los detalles de implementación del proyecto. Con el fin de estructurar mejor el capítulo, este se verá dividido en tres secciones, una por cada fase (o módulos) del proyecto, exceptuando la *fase 3*. Debido a las complicaciones ya mencionadas, es imposible detallar la implementación de la *fase 3*, ya que todavía se encuentra en progreso.

También se enunciarán y se hará una breve explicación de los modelos utilizados, con el fin de aportarle completitud a la memoria.

5.1 Fase 0: recopilación, adecuación y almacenamiento de los datos

Como ya se ha explicado, este módulo es el que agrupa las tareas de recopilación, adecuación y almacenamientos de los datos. Cabe destacar que cuando se hace referencia a adecuación, se hace referencia a la anonimización y al truncamiento de los datos, pero también al entrenamiento de los modelos de localización y a la propia clasificación de las muestras.

Como se puede observar, este módulo, a pesar de encargarse de tareas básicas, es el módulo más denso del proyecto.

5.1.1. Recopilación de los datos

Para la recopilación de los datos se ha utilizado la librería *Tweepy*. Para ello, se utilizan las clases *MyStreamListener* y la clase *Stream*.

La clase *MyStreamListener* es de implementación propia y extiende a la clase *StreamListener* de *Tweepy*, que se podría decir que es algo similar a una interfaz. Esta clase es la que se encarga de recibir los mensajes de la **API** de *Twitter* y aplicar la función correspondiente. En este caso, la clase propia solamente implementa las funciones `__init__`, `on_status` y `on_error`

En la función `__init__`, lo único que se hace es almacenar en una variable la colección de *MongoDB* en la que se van a almacenar los datos.

La `on_status` es la encargada de realizar el almacenamiento en sí. Es la que se ejecuta cada vez que se recibe un nuevo objeto de tuit por parte de la **API**. Esta función también es donde se incluyen los pasos de truncamiento, anonimización y almacenamiento de los datos, que más adelante se comentarán.

Finalmente, la función `on_error` es simplemente la función que se ejecuta en el caso de que la **API** devuelva un mensaje de error, en cuyo caso se cierra la conexión con el `Stream` y se lanza una excepción.

Y volviendo a la clase `Stream`, esta es la clase que se instancia utilizando el objeto con las autorizaciones y claves de *Twitter* y la clase propia `MyStreamListener`.

Para finalizar y comenzar a recopilar datos, lo que hay que hacer es invocar a la función `filter` de la instancia de `Stream`. Esta llamada es la que va a encargarse de manejar la comunicación con la **API** de *Twitter*, más concretamente con la *Stream API*. En la llamada se incluyen los términos sobre los que se desea filtrar (en este caso, únicamente «coronavirus») y el idioma sobre el que se desea filtrar (en este caso, el castellano, el cual se denomina como «es»).

5.1.2. Truncamiento de los datos

El truncamiento de los datos consiste en seleccionar los campos que se deseen y descartar el resto. Lo primero que se hace es comprobar si existe el campo `status.retweeted_status`, ya que si este existe significa que este objeto es el correspondiente a un retuit y este tipo de tuits no son los que se busca recopilar.

Seguidamente, se comprueba que el tuit no existiera ya previamente en la colección y si existe se descarta. A continuación, lo que se hace es crear un diccionario vacío, donde se van a ir incluyendo los campos y valores que se deseen almacenar. Se ha elegido un diccionario porque es necesario para posteriormente poder almacenarlo en la colección de *MongoDB*.

Finalmente, se procede a incluir en este diccionario únicamente los campos deseados, que son: `status.id` (el identificador de tuit), `status.user.id` (el identificador del usuario), `status.created_at` (la marca de tiempo de publicación del tuit), `status.text` (o `status.extended_tweet['full_text']` si se trata de un tuit extendido) y `status.place` (el objeto donde se almacena toda la información de localización, si es que la contiene).

Además, también se incluye un nuevo campo en el diccionario, este campo es «predicted». Este campo se va a utilizar más adelante para almacenar la información relativa a la clasificación del tuit (en caso de tener un campo `status.place` vacío).

5.1.3. Anonimización de los datos

Para llevar a cabo la anonimización de los datos, lo que se hace es aplicar la función `hashpw` de *bcrypt* al identificador del usuario, sustituyéndolo por el resultado de la función.

De este modo, no existe un método eficiente y rápido para poder extraer la información de usuario a partir del identificador anonimizado.

5.1.4. Almacenamiento de los datos

Al final del proceso, se utiliza la colección que tiene almacenada el objeto `MyStreamListener` para almacenar el diccionario final. Para ello se utiliza la función `insert_one` de la colección, a la cual se le pasa únicamente el diccionario asociado al dato a almacenar.

Lo que todavía no se ha comentado es como se consigue obtener el objeto de la colección. Y es que esto se hace antes del proceso de iniciar la recopilación, mediante el uso de la clase `MongoClient` de *PyMongo*. Al instanciar esta clase es cuando se establecen las credenciales de uso y direcciones de servidor donde se encuentra alojada la base de datos.

Con esta instancia ya creada, se pueden llamar a las funciones `get_database` y `get_collection` para finalmente adquirir un objeto con el cual comunicarse directamente con la colección.

5.1.5. Entrenamiento de modelos de clasificación de localización

Ya que este es el primer apartado sobre la implementación donde se va a hablar sobre uno de los modelos del proyecto, es importante mencionar que en este capítulo se va a comentar la implementación de los modelos finales.

Las evaluaciones de los diferentes modelos y configuraciones se llevarán a cabo en el capítulo 7, donde también se explicarán los motivos por los cuales se elige uno u otro modelo/configuración.

Dado al gran volumen de datos, para entrenar este modelo se va a utilizar la clase `Sequence` de *Keras*. Esta clase ofrece la posibilidad de cargar al vuelo las muestras de entrenamiento, eliminando así la necesidad de mantener el *dataset* al completo en memoria, lo cual sería muy costoso. De esta forma, se ha creado la clase `TrainSequence`, que extiende a la clase `Sequence`.

El problema es que los modelos de *Keras* se van a entrenar directamente a partir de los datos que la secuencia le proporcione, pero los datos necesitan un preprocesamiento antes de poder ser utilizados. Es por eso que se ha visto la necesidad de incluir toda la funcionalidad de preprocesamiento en la clase de la secuencia.

Pero surge otro problema, y es que las transformaciones del preprocesamiento necesitan un contexto que abarca todo el conjunto de entrenamiento. Por ese mismo motivo, lo primero que se hace es una pasada completa por las transformaciones con una versión básica de la secuencia.

Una vez ya se tiene el contexto de las transformaciones, se amplía la versión básica de la secuencia a una versión que contiene el contexto de todo el conjunto de entrenamiento (mediante una función de implementación propia). Y esta es la secuencia sobre la que se entrena el modelo de *Keras*.

A continuación, se desean tres instancia de la secuencia con el contexto: una será la que devolverá el conjunto de entrenamiento, otra el conjunto de evaluación y otra el conjunto de test. Esta división se ha hecho acorde con los porcentajes 70 %, 10 % y 20 %, respectivamente.

El preprocesamiento que se realiza es utilizando las clases `TfidfVectorizer` y `StandardScaler` de *Scikit-Learn*. Con la clase `TfidfVectorizer` se transforma cada uno de los tuits en un vector numérico, este tiene una dimensionalidad que se fija a la hora de instanciar el vectorizador. Esto lo hace teniendo en cuenta la ecuación 5.1 [15].

$$w_{i,j} = tf_{i,j} \times \log\left(\frac{N}{df_i}\right) \quad (5.1)$$

En la ecuación 5.1, $w_{i,j}$ es el peso o valor que se va a asignar al elemento (término) i asociado al vector (tuit) j . Este peso será el producto entre la frecuencia del término i en el tuit j ($tf_{i,j}$) y el logaritmo del número de documentos entre el número de documentos en los que aparece el término i ($\log(\frac{N}{df_i})$).

De esta forma, no solo se tiene en cuenta la frecuencia de los términos en un documento, sino que también se tiene en cuenta el número de documentos en los que aparece este término, dándole más peso a los términos que aparecen en menos documentos.

La segunda y última transformación es un simple escalado: $z = \frac{x}{s}$, donde z es el vector resultante tras el escalado, x es el vector original y s es la desviación estándar del conjunto de vectores.

Una vez ya se tienen las tres instancias de secuencias con las transformaciones globales incluidas, se procede a entrenar el modelo de clasificación. En este caso, se ha elegido una red neuronal artificial [34] (también conocida como un perceptrón multicapa), cuyos parámetros y configuración serán discutidos en el capítulo 7.

Para implementar esta red neuronal se ha utilizado la *Sequential API* de *Keras*, que permite instanciar modelos de **aprendizaje automático** de una forma muy rápida y sencilla. Y para comenzar el entrenamiento, se llama a la función `fit` de la instancia del modelo.

Finalmente, se evalúa el modelo, se muestran al usuario las métricas y se almacenan los tres objetos que componen el modelo (vectorizador, escalador y clasificador) en forma de archivos binarios.

5.1.6. Clasificación de localización de los datos

A la hora de clasificar, lo primero que se hace es cargar los objetos que componen el modelo, para ello se requieren los nombres de los archivos binarios. Para llevar a cabo la tarea de clasificación ocurre lo mismo que con la de entrenamiento, pero incluso en un grado mayor (ya que son muchas más las muestras sin etiquetar que las de entrenamiento).

Es por eso que para esta tarea también se necesita una clase que extienda a la *Sequence* de *Keras*, pero en este caso se instancia directamente con las transformaciones de preprocesamiento que se han cargado.

Una vez ya se han obtenido las clasificaciones de los tuits sin localización, es el momento de actualizar los objetos de la colección, más concretamente el campo «predicted», el cual inicialmente tiene el valor de `None`.

Estas actualizaciones podrían ser llevadas a cabo una por una, pero se ha elegido utilizar las operaciones en masa (*bulk operations*) de *MongoDB*. Este tipo de operaciones permiten llevar a cabo unas 1000 operaciones de una sola llamada, pero ya que lo que se desea realizar son actualizaciones, el número máximo será de 500 actualizaciones (ya que una actualización implica una búsqueda y una modificación, es decir, dos operaciones).

5.2 Fase 1: vectorización de los datos

Este módulo es el encargado de transformar los tuits (los que se han clasificado como que tienen origen en territorio español) en un conjunto de vectores que formen una serie temporal.

La unidad de tiempo que se ha elegido para la serie temporal es el día. Esto quiere decir que los tuits que se hayan publicado en el mismo día se verán transformados en un solo vector. Se ha elegido así ya que la serie de la evolución del COVID-19 también tiene como unidad de tiempo el día.

5.2.1. Lectura de los datos

Para poder empezar a procesar los tuits, lo primero que se necesita es agrupar los identificadores de los tuits por la fecha de publicación. Y para ello se necesita saber las fechas en las que se dispone de tuits. Lo que se ha hecho para conseguir las fechas es una operación de agregación (*aggregation*) de *MongoDB*. En esta operación de agregación se han utilizado los operadores *match* (para filtrar y agrupar únicamente por los tuits que se hayan clasificado como localización en España) y *group* (para finalmente agrupar por las fechas).

Una vez teniendo las fechas, se puede iterar por cada una de ellas y hacer una búsqueda en la colección con cada una de las fechas. Este es el punto en el que la **vectorización** se lleva a cabo.

5.2.2. Vectorización de los datos

Una vez se dispone de las fechas, antes de comenzar a iterar sobre ellas, lo que se hace es inicializar una matriz en la cual se van a almacenar los resultados de las vectorizaciones. Esta matriz será lo que finalmente se considerara como la **vectorización** de los datos.

La **vectorización** como tal la llevara a cabo la clase `CountVectorizer` de *Scikit-Learn*. Esta clase lo único que hace es contabilizar ocurrencias de términos, pero en este caso solo contabilizará algunos términos clave que se han considerado relevantes, estos formarán el vocabulario del vectorizador.

Este vocabulario está formado por los siguientes términos: fiebre, tos, toser, cansado, cansancio, diarrea, conjuntivitis, cabeza, sabor, olor, respirar, pecho, presión, contagiado y hospital. Esta lista en ningún caso es una lista cerrada y una posible ampliación a este proyecto podría ser experimentar con diferentes términos. Esto no ha podido ser llevado a cabo en este proyecto ya que una sola **vectorización** completa lleva realizarla aproximadamente unas tres horas y media, y a esto habría que sumarle el coste temporal de los experimentos con los estimadores, lo que haría que el coste temporal explotara.

Tanto los términos del vocabulario como los términos de los tuits, antes de ser procesados para contabilizar ocurrencias pasan por un transformador. Este transformador se trata de un lematizador, que lo que hace es transformar un término en su palabra raíz. De esta forma, se asegura que, por ejemplo, todas las formas verbales de un mismo verbo cuentan como ocurrencia (si el vocabulario es «andar», tanto «andaré» como «andado» cuentan como ocurrencia).

La matriz final de **vectorización** tiene tantas filas como días se vayan a vectorizar y tantas columnas como términos tenga el vocabulario de términos. Esta será la matriz que finalmente se almacenará para su posterior análisis.

Finalmente, se comienza a iterar sobre las fechas de los tuits y se acumulan las vectorizaciones asociadas a un mismo día.

5.2.3. Almacenamiento de la vectorización

Una vez ya se tiene la matriz de la **vectorización** final, esta se almacena en una colección diferente a donde están almacenados los tuits. La matriz se almacena en formato binario, de tal manera que es posible recuperarla en cualquier momento de una forma sencilla y transparente.

5.3 Fase 2: estimación básica de la evolución cuantitativa del COVID-19

Finalmente, se va a hablar del módulo de estimación. Este módulo, como su nombre indica, es el encargado de realizar la estimación de la evolución cuantitativa del COVID-19. Dicha estimación se lleva a cabo tomando como entrada únicamente una de las vectorizaciones previamente realizadas.

5.3.1. Lectura de la vectorización

Para obtener la **vectorización**, lo que se hace (como ya se ha hecho previamente otras veces) es establecer una conexión a la colección donde se encuentre almacenada y recuperarla. Esta se encontrará almacenada en formato binario, así que al leerla hay que interpretarla. Y tras esta interpretación ya se debería disponer del objeto de la matriz.

5.3.2. Transformaciones previas a la estimación

Previamente a la estimación con el modelo, hay que transformar un poco la serie temporal cargada, así como cargar los datos oficiales sobre la evolución del COVID-19.

Estas transformaciones son: desplazar relativamente la **vectorización** propia y la serie de la evolución cuantitativa real (de tal forma que a partir del día d_x se va a estimar la evolución del día d_{x+2}); y transformar la serie temporal resultante en un formato adecuado para la red neuronal recurrente, que será el modelo estimador final.

Para llevar a cabo la primera transformación, no es necesario más que una simple operación con *Pandas*, concretamente *shift*. Pero para llevar a cabo la segunda transformación se ha usado una clase de utilidad de *Keras*, llamada *TimeseriesGenerator*.

En este caso, la red neuronal recurrente implementada necesita de la entrada de cinco días para poder estimar la de un único día, es decir, que por cada día que se desee estimar (o sobre el que se desee entrenar) se necesitan las vectorizaciones de cinco días. Es para esto que la clase *TimeseriesGenerator* es útil, ya que realiza las transformaciones necesarias para acomodar los datos a este formato.

Una vez ya se han realizado estas estimaciones, se puede proceder a instanciar el modelo y entrenarlo.

5.3.3. Estimación de la evolución cuantitativa

Como ya se ha mencionado, el modelo estimador seleccionado es una red neuronal recurrente. Esta, de nuevo, será implementada utilizando la *Sequential API* de *Keras*. La única diferencia es que en este caso también se incluirán en el modelo capas de memoria (*memory layers*), las cuales estarán compuestas de unidades de memoria a largo y corto plazo (*long short term memory* o **LSTM**) [27].

De nuevo, el entrenamiento del modelo se hace mediante la llamada a la función `fit` del mismo. Una vez se tiene el modelo entrenado, se almacena con el fin de poder utilizarlo en cualquier momento para poder estimar la evolución del COVID-19.

CAPÍTULO 6

Implantación

Este sistema no se ha podido implantar en un entorno real, donde habría apoyado a la toma de decisiones relativas a la gestión de la pandemia. Esta implantación no ha podido ser llevada a cabo debido a algunos inconvenientes surgidos.

Esto no se ha podido realizar por motivos relacionados con la pandemia del COVID-19 en España. Las limitaciones de movilidad y de actividad impuestas por el gobierno han impedido que esta implantación haya podido ser llevada a cabo.

De todas formas, la instalación y configuración del sistema no es especialmente difícil, basta tener unos conocimientos básicos de informática para llevarla a cabo. Lo que sí que requiere un poco más de conocimiento es el uso del mismo, ya que requiere entender como funciona el sistema y como utilizarlo en un entorno de desarrollo con *Python 3*.

A pesar de no haber podido ser implantada, el desarrollo de la aplicación sigue su curso y futuras publicaciones están planeadas.

CAPÍTULO 7

Pruebas y evaluaciones

En este capítulo se presentan y explican todos experimentos realizados con los modelos. Porque, como ya se ha comentado, inicialmente se propusieron varios modelos para cada una de las dos tareas, pero al final se ha de elegir únicamente uno, el que se verá implementado en la versión final del proyecto.

Se comenzará analizando la correlación entre la serie temporal oficial de la evolución del COVID-19 y los datos recopilados. Y seguidamente se comentarán los experimentos y evaluaciones de los modelos.

7.1 Análisis de la correlación entre las series temporales

Inicialmente se tienen dos series temporales: la serie temporal del acumulado de casos totales de COVID-19 en España («casos_total») y la **vectorización** obtenida a partir del *módulo 1* del proyecto («vector»). En este caso, para realizar un análisis básico, se va a utilizar el sumatorio de los vectores de cada día, es decir, que la **vectorización** estará compuesta de un único elemento por cada día.

Pero, para realizar un estudio más amplio, se van a añadir tres series más: la serie que se obtiene de calcular la diferencia entre los elementos de «casos_total» («casos_total_diff_1»), la serie que se obtiene de calcular la diferencia entre los elementos de «casos_total_diff_1» («casos_total_diff_2») y la serie que se obtiene de calcular la diferencia entre los elementos de «vector» («vector_diff_1»).

La técnica de obtener otra serie temporal a partir de la diferencia entre los elementos de la original es una técnica que se utiliza para mitigar la auto-correlación en las series temporales. De esta forma, se obtienen las cinco series temporales que se van a analizar. El objetivo de este análisis es elegir las dos series temporales (una de las relacionadas con los datos oficiales y otra de las relacionadas con los datos recopilados) que más adelante se utilizarán como entrada para los estimadores.

Lo primero que se ha de hacer es estudiar la auto-correlación de las series temporales, es decir, la correlación que tiene cada una consigo misma. La métrica de correlación que se va a utilizar en el análisis es el coeficiente de correlación de Pearson (*Pearson correlation coefficient*) [5]. Este coeficiente puede servir para medir el grado de relación que existe entre dos series temporales. La gráfica resultado del análisis se puede observar en la figura 7.1.

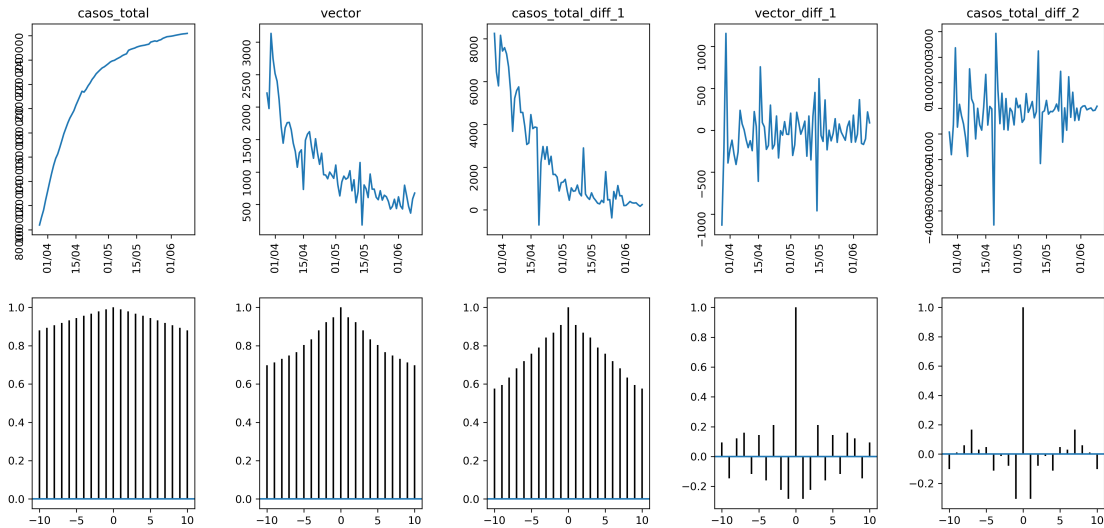


Figura 7.1: Gráfica de la auto-correlación

En la parte superior de la figura 7.1 se encuentran las gráficas de cada una de las series temporales a analizar, y en la parte inferior se encuentran las gráficas de los coeficientes de auto-correlación (cada gráfica de las series temporales tiene su gráfica de la auto-correlación directamente debajo). En las gráficas de la auto-correlación (al igual que las del análisis de la correlación entre las series) el eje X representa el número de desplazamientos relativo entre las series y el eje Y representa el coeficiente de correlación en cada uno de los desplazamientos.

Como se puede observar, la serie «casos_total» tiene un alto coeficiente de auto-correlación, por lo que es preferible usar alguna de las que derivan de ella. También se puede observar que la técnica de calcular las diferencias funciona como es debido, siendo mucho más efectiva en la segunda de sus aplicaciones.

De este análisis inicial se puede extraer que, exceptuando la serie «casos_totales», todas las series podrían ser utilizadas como entrada para los estimadores.

Ahora llega el momento de analizar las correlaciones entre todas las series. Para ello se ha creado una suerte de matriz de gráficas, donde cada gráfica es la gráfica de la correlación entre la serie de la fila y la de la columna. Esta gráfica se puede encontrar en la figura 7.2.

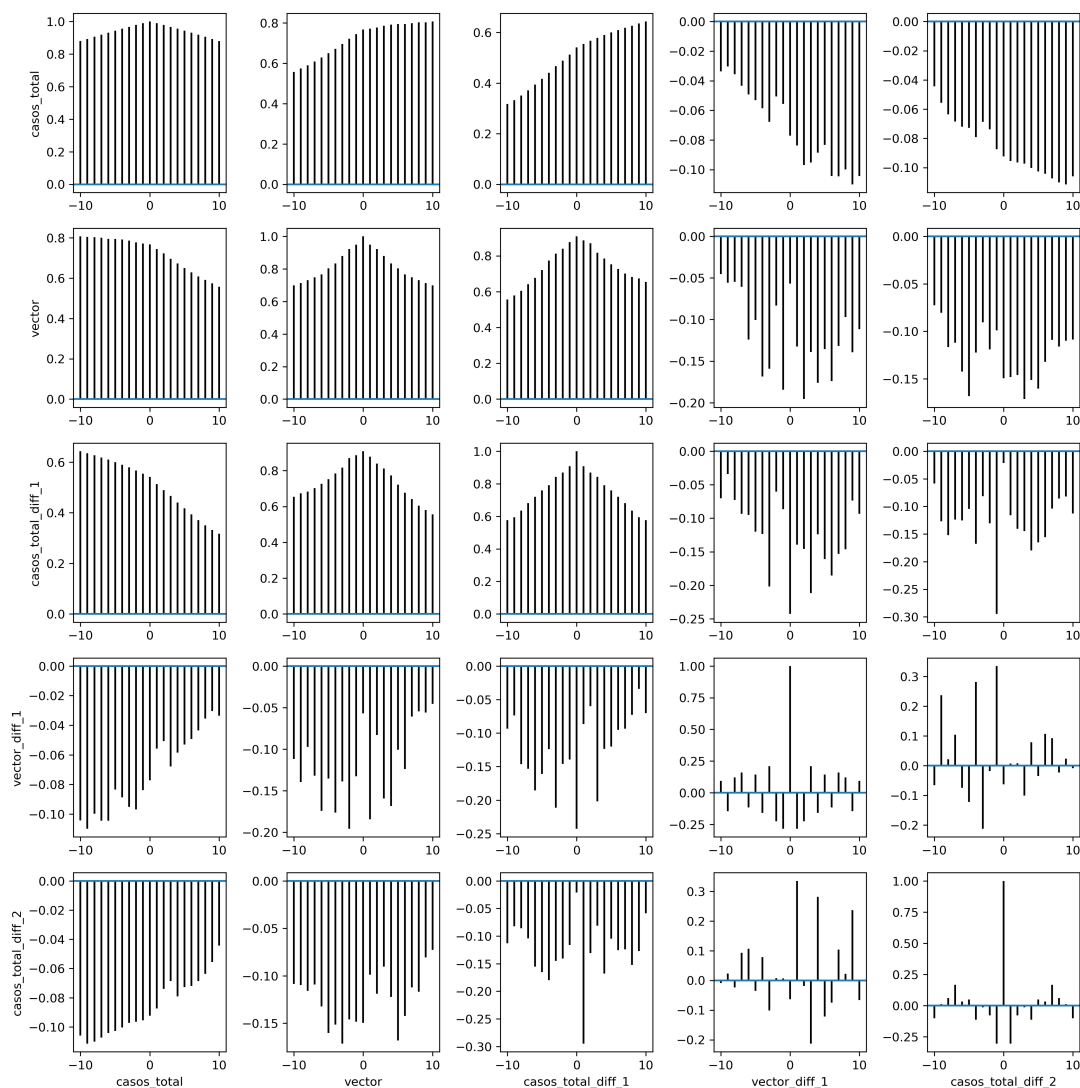


Figura 7.2: Gráfica de la correlación entre las series temporales

Como se observa en la figura 7.2, la correlación entre la serie «casos_total_diff_2» y «vector_diff_1» (las dos series con el mejor coeficiente de auto-correlación) no es demasiado buena. La correlación entre estas series alcanza su máximo con un número de desplazamientos igual a uno, alcanzando un coeficiente de correlación de aproximadamente 0,3.

En cambio, la correlación observada entre las series «casos_total_diff_1» y «vector» es bastante más alta, alcanzando un valor cercano a 0,8 con un número de desplazamientos igual a uno. Por este mismo motivo, se van a elegir estas dos series para fabricar la entrada de los estimadores.

Para finalizar este apartado de análisis de la correlación, se va a llevar a cabo un análisis de causalidad sobre las series. Concretamente, se va a realizar el test de causalidad de Granger (*Granger causality test*) [12], con el cual no se prueba si «Y causa X», sino que la relación de causalidad que demuestra es «Y causa en el sentido de Granger X» (Y *Granger-causes* X).

En este test, lo que se intenta es comprobar si la hipótesis nula (H_0) se puede aceptar como verdadera. Concretamente, la hipótesis nula es que Y no causa en el sentido de Granger X. Entonces, en el caso de obtener valores de p menores a 0,05, se puede rechazar con seguridad H_0 , lo que implica que Y causa en el sentido de Granger X.

Al igual que ocurre con la anterior gráfica, la figura del test de causalidad de Granger (figura 7.3) también es una suerte de matriz de gráficas, donde en cada gráfica se ve representado si la serie de la columna causa en el sentido de Granger la serie de la fila.

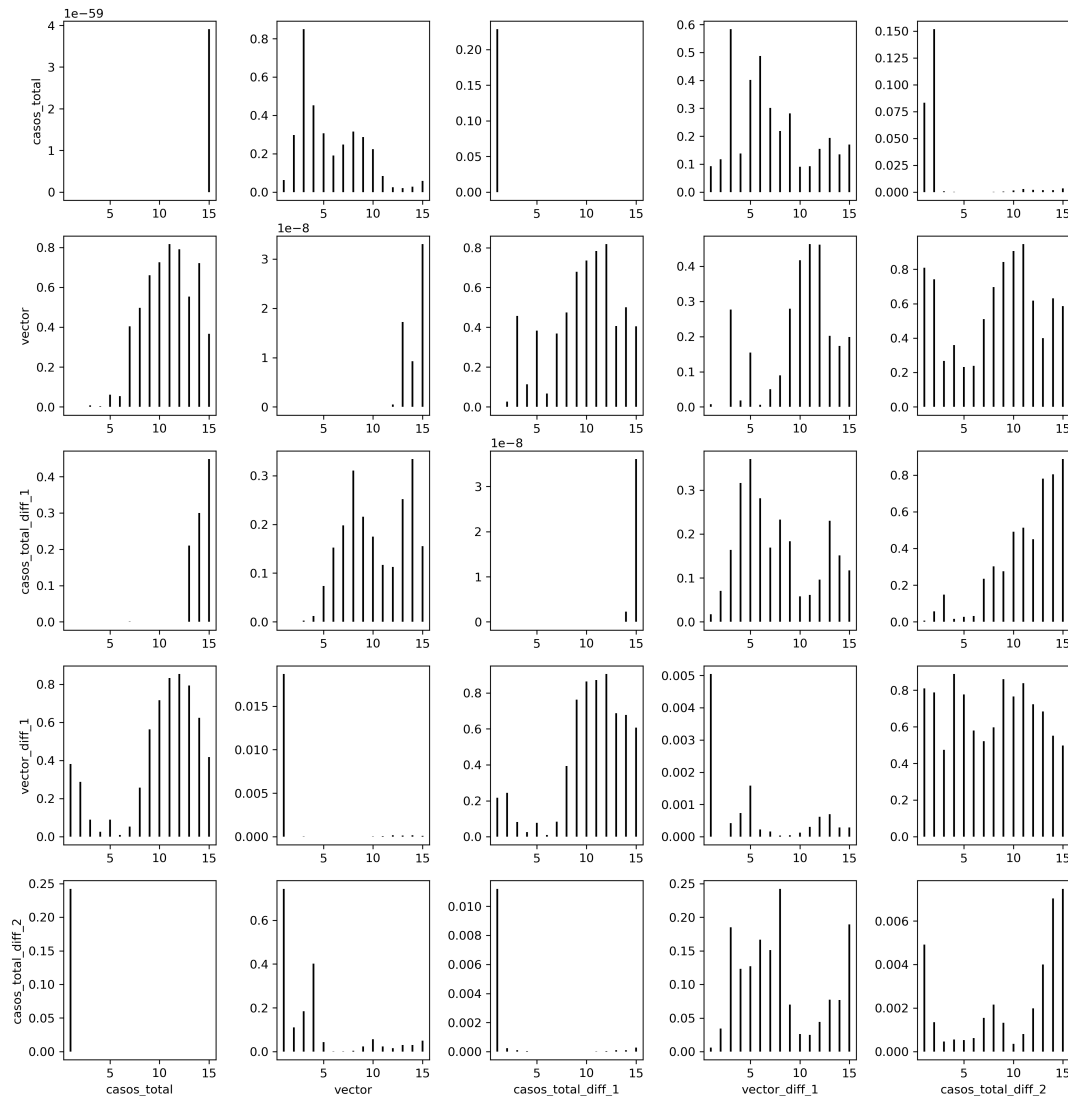


Figura 7.3: Gráfica del test de Granger entre las series temporales

En la figura 7.3, el eje X de cada una de las gráficas representa el número de desplazamientos relativos entre las series (al igual que ocurre con la figura 7.2) y el eje Y representa la probabilidad p de aprobar la hipótesis nula.

Como se puede observar, se puede establecer la relación «Y causa en el sentido de Granger X» entre varias de las series, pero debido a los coeficientes de correlación, las únicas series candidatas son «casos_total_diff_1» y «vector». En este caso, la relación «vector causa en el sentido de Granger casos_total_diff_1» tiene unos valores de p mucho más pequeños que la relación «casos_total_diff_1 causa en el sentido de Granger vector» (a pesar de que esta también se puede aceptar para uno de los desplazamientos). Por este motivo, se establece que existe la relación «vector causa en el sentido de Granger casos_total_diff_1» y se rechaza H_0 .

Gracias al análisis llevado a cabo en este apartado, se ha podido demostrar y probar cuales son las series temporales más prometedoras sobre las que realizar la estimación. Concretamente, se ha demostrado gracias a una serie de procedimientos y test estadísticos que las dos series más prometedoras para estimar la una con la otra son «casos_total_diff_1» (la serie temporal de los datos oficiales con la técnica de las diferencias aplicada una sola vez) y «vector» (la serie temporal obtenida de los datos recopilados de *Twitter*).

7.2 Evaluación de los clasificadores de localización

La primera tarea de aprendizaje que se presenta en el proyecto es la clasificación de los tuits en dos clases: tuits surgidos en el territorio español y tuits surgidos fuera del territorio español. Esta es una tarea de clasificación binaria, y, como ya se ha mencionado anteriormente, en este proyecto se probarán dos modelos para llevar esta tarea a cabo: un clasificador basado en una máquina de vectores soporte (SVM) [9] y un clasificador basado en una red neuronal artificial (ANN) [34].

7.2.1. Métricas para los experimentos de clasificación

En cuanto a las métricas que se usarán para evaluar los modelos, van a ser tres: i) *Precision*, ii) *Recall* y iii) *F-score*. Estas son métricas características para evaluar tareas de clasificación. Comentar que en todas estas métricas de clasificación, si $p > q$, entonces el modelo con el que se obtiene p es mejor (en resumen, que se desea obtener valores mayores). A continuación se va a explicar cada una de ellas.

La ecuación 7.1 es la correspondiente a la métrica *Precision*. Esta métrica asume que las clases en las que se clasifica son «positivo» y «negativo», lo cual no es ningún problema. En la ecuación, *TP* se refiere a los verdaderos positivos (*true positives*), es decir, al número de muestras que eran de clase «positivo» y se han clasificado correctamente. Análogamente, *FP* se refiere a los falsos positivos (*false positives*), este es el número de muestras que eran de clase «negativo» y se han clasificado incorrectamente.

$$Precision = \frac{TP}{TP + FP} \quad (7.1)$$

La ecuación 7.2 es la correspondiente a la métrica *Recall*. Esta métrica, al igual que *Precision*, asume que las clases en las que se clasifica son «positivo» y «negativo». La única diferencia entre *Recall* y *Precision* es el segundo término de la suma del denominador. En este caso, lo que antes era *TP* pasa a ser *FN*, que se refiere a los falsos negativos (*false negatives*), es decir, al número de muestras que eran de clase «positivo» y se han clasificado incorrectamente.

$$Recall = \frac{TP}{TP + FN} \quad (7.2)$$




Figura 7.4: Gráfico representativo de las métricas *Precision* y *Recall*. En este caso, la «P» representa a la *Precision* y «R» al *Recall*. Las secciones en verde son las clasificadas correctamente y las rojas las clasificadas incorrectamente.

En la figura 7.4 se puede visualizar de una forma más didáctica el significado de la *Precision* y el *Recall*. Se puede ver como la *Precision* representa el porcentaje de muestras correctamente clasificadas como «positivo», y también como el *Recall* representa el porcentaje de muestras «positivas» que se han clasificado correctamente.

Finalmente, la ecuación 7.3 es la correspondiente a la métrica *F-score* [26]. Esta métrica utiliza los valores de la *Precision* y el *Recall*, por eso se dice que es una métrica más informada que las otras. En esta métrica, un valor igual a 1 es el máximo alcanzable y significaría que el modelo tiene una *Precision* y *Recall* perfectos.

$$F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (7.3)$$

Se ha elegido el *F-score* como métrica determinante para los experimentos, ya que de las métricas seleccionadas es la más informada.

7.2.2. Experimentos con los clasificadores

A continuación se va a proceder a explicar los experimentos realizados y las configuraciones utilizadas. Para realizar estos experimentos se ha utilizado una técnica basada en «búsqueda en cuadrícula» (*grid search*), también conocida como una «búsqueda exhaustiva». Más adelante se van a mostrar unos extractos de las mejores configuraciones, pero se puede remitir a los apéndices A y B donde se presentan las tablas completas.

En los experimentos de clasificación con máquina de vectores soporte se ha elegido una partición para entrenamiento y test del 70 % y 30 %, y en los experimentos con el modelo de red neuronal artificial se utiliza un 63 %, 7 % y 30 % para entrenamiento, validación y test, respectivamente. El conjunto de muestras para esta tarea estaba formado por los tuits recopilados con localización desde el 24 de marzo de 2020 hasta el 20 de junio de 2020, siendo estos aproximadamente 250.000 tuits. Un detalle importante es que debido al coste temporal de los experimentos, no se ha podido hacer una **validación cruzada** (*cross-validation*) de todos ellos y solo se ha podido realizar con la mejor de las configuraciones.

En los experimentos realizados con los clasificadores hay algunas variables comunes. Primero se van a comentar estas y luego se pasará a comentar las específicas a cada modelo:

- **Clases equilibradas («Eq.»):** en el conjunto de tuits, el número de tuits obtenidos de fuera del territorio español es mucho mayor a los obtenidos de dentro, por eso se ha de considerar si equilibrar este conjunto antes de utilizarlo para clasificar. Los valores contemplados para esta variable son: ningún equilibrio («No») y equilibrio mediante recorte (*downsampling*) de la clase mayoritaria.
- **Vectorizador a utilizar («Vec.»):** ya que parte del preprocesamiento que hay que aplicar a los tuits antes de poder clasificarlos (o utilizarlos para entrenar un clasificador) es una **vectorización**, otra de las variables es la que concierne al vectorizador que se va a utilizar. Los valores contemplados para esta variable son: el `CountVectorizer` («Frec.») y el `TfidfVectorizer` («Tf-Idf»).
- **Rango de n-gramas al vectorizar («n-gs»):** otra variable que concierne al vectorizador es el rango de n-gramas que va a utilizar para obtener los *tokens*. Por ejemplo, si se tiene un texto y el rango es (1,1), el vocabulario del vectorizador serían los términos del texto; pero si el rango fuera (1,2), el vocabulario estaría formado por los términos y por los bigramas del texto. Los valores contemplados para esta variable son: (1,1), (1,2) y (2,2).
- **Tamaño máximo del vocabulario («Max d»):** otro de los parámetros clave del vectorizador es el tamaño máximo del vocabulario. Esta variable también se podría interpretar como la dimensionalidad máxima de los vectores resultantes de la **vectorización**. Los valores contemplados para esta variable son: 50, 500, 2000, 3000.
- **Eliminación de palabras vacías o *stop words* («S-W»):** este es el último parámetro común a todos los modelos de clasificación. La eliminación de palabras vacías resulta dar buenos resultados en algunas tareas relacionadas con el lenguaje natural, pero se puede intuir que, para una tarea tan específica del lenguaje, el hecho de dejar las palabras vacías puede ser positivo, por eso se explora también esa posibilidad. Los valores contemplados para esta variable son: no eliminar las palabras vacías («No») y sí eliminar las palabras vacías («Sí»).

Una vez explicadas las variables comunes a los experimentos con ambos modelos, se van a explicar las variables específicas de cada modelo y se van a mostrar los mejores resultados obtenidos (teniendo en cuenta la métrica escogida como determinante: el *F-score*).

Para el modelo de clasificación por máquina de vectores soporte solo hay una variable adicional: **el valor del margen («C»)**. Cuanto mayor es este parámetro, el modelo da más margen a la separación de las clases, afectando también al tiempo de entrenamiento, siendo este mayor cuanto mayor es el valor del margen. Los valores contemplados para esta variable son: 2^{-3} (0,125), 2^{-1} (0,5), 2^1 (2), 2^3 (8) y 2^4 (16).

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
Down	Tf-Idf	(1, 1)	3000	No	0.125	0.7628	0.7283	0.7452
Down	Tf-Idf	(1, 1)	3000	No	2.0	0.7614	0.728	0.7443
Down	Tf-Idf	(1, 1)	3000	No	16.0	0.7614	0.7278	0.7442
Down	Tf-Idf	(1, 1)	3000	No	8.0	0.7613	0.7278	0.7442
Down	Tf-Idf	(1, 1)	3000	No	0.5	0.7607	0.7278	0.7439
Down	Frec.	(1, 1)	3000	No	0.125	0.7671	0.7181	0.7418
Down	Frec.	(1, 1)	3000	No	0.5	0.7657	0.7184	0.7413
Down	Frec.	(1, 1)	3000	No	2.0	0.7652	0.7184	0.7411

Tabla 7.1: Tabla de los mejores resultados para clasificación con SVM

Como se puede observar en la tabla 7.1, el mejor resultado se obtiene de la siguiente configuración: recortar el número de muestras de la clase dominante, utilizar `TfidfVectorizer` como vectorizador, analizar los tuits únicamente por los términos, establecer un tamaño máximo del vocabulario a 3000, no eliminar palabras vacías (se confirma la intuición) y utilizar un valor de «C» igual a 0,125. Con esta configuración se alcanza un *F-score* igual a 0,7452.

Se ha utilizado esta configuración para llevar a cabo una **validación cruzada** de 10 iteraciones (*10-fold cross-validation*). Los resultados obtenidos de esta **validación cruzada** son incluso mejores que los de la evaluación con la partición básica del conjunto. Los resultados obtenidos son: 0,7776 de *Precision*, 0,7401 de *Recall* y 0,7584 de *F-score*.

Ahora se pasará a hablar del modelo de clasificación por red neuronal artificial. Para este modelo hay un par de variables adicionales a las comunes:

- **Configuración de las capas ocultas de la red («H.L.»):** esta variable es la que configura tanto el número de capas ocultas de la red (profundidad) como el número de unidades de cada capa (anchura). Los valores contemplados para esta variable son un poco particulares, ya que no están fijados, sino que se calculan en función del tamaño máximo del vocabulario de cada experimento. Los posibles valores de esta variable son cinco funciones que toman como entrada un número y devuelven la configuración de las capas ocultas. Estas funciones se pueden observar en la figura 7.5.

```

12 dense_nparams_s = [
13     lambda x: [x],
14     lambda x: [x//i for i in range(1,3)],
15     lambda x: [x//i for i in range(1,4)],
16     lambda x: [sum([x//j for j in range(i,3)]) for i in range(1,3)],
17     lambda x: [sum([x//j for j in range(i,4)]) for i in range(1,4)]
18 ]

```

Figura 7.5: Funciones generadoras de la configuración de las capas ocultas para el clasificador ANN

- **Valor de la probabilidad de *dropout* («Drop»):** este parámetro es el que se introduce en las capas de *dropout*. Las capas de *dropout* lo que hacen es «ignorar» las unidades de las capas ocultas con una probabilidad establecida. Esta es una conocida y sencilla técnica para mitigar el **sobreajuste** (*overfitting*) [28]. Los valores contemplados para esta variable son: 0 (no se aplica) y 0,2 (se aplica con una probabilidad del 20%).

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Tf-Idf	(1, 1)	3000	No	[4500, 1500]	0.2	0.7245	0.8104	0.765
Down	Frec.	(1, 1)	3000	No	[3000, 1500, 1000]	0.2	0.7323	0.7843	0.7574
Down	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500]	0.2	0.7016	0.8208	0.7565
Down	Tf-Idf	(1, 1)	3000	No	[3000, 1500, 1000]	0.0	0.7688	0.7426	0.7555
Down	Frec.	(1, 1)	3000	Sí	[5500, 2500, 1000]	0.0	0.74	0.7691	0.7543
Down	Frec.	(1, 2)	3000	Sí	[4500, 1500]	0.2	0.6998	0.817	0.7538
Down	Frec.	(1, 1)	3000	Sí	[3000, 1500, 1000]	0.2	0.7466	0.7592	0.7528
Down	Frec.	(1, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.7355	0.7699	0.7523

Tabla 7.2: Tabla de los mejores resultados para clasificación con ANN

Como se puede observar en la tabla 7.2, el mejor resultado se obtiene de la siguiente configuración: recortar el número de muestras de la clase dominante, utilizar `TfidfVectorizer` como vectorizador, analizar los tuits únicamente por los términos, establecer un tamaño máximo del vocabulario a 3000, no eliminar palabras vacías (se confirma la intuición), utilizar una configuración para las capas ocultas [4500, 1500] (dos capas ocultas: la primera con 4500 unidades y la segunda con 1500 unidades) y utilizar una probabilidad de *dropout* igual a 0,2. Con esta configuración (que como se puede observar es todo lo similar que puede ser a la mejor de máquina de vectores soporte) se alcanza un *F-score* igual a 0,7650.

Se ha utilizado esta configuración para también llevar a cabo una **validación cruzada** de 10 iteraciones (*10-fold cross-validation*). Los resultados obtenidos de esta **validación cruzada** son un poco peores que los de la evaluación con la partición básica del conjunto. Los resultados obtenidos son: 0,7777 de *Precision*, 0,7083 de *Recall* y 0,7401 de *F-score*.

Finalmente, y a pesar de haber obtenido unos resultados ligeramente mejores con el modelo de máquina de vectores soporte, se ha elegido el modelo de red neuronal artificial como modelo de clasificación final. El principal motivo para esto es que *Keras* ofrece la posibilidad de ir obteniendo las muestras a clasificar «al vuelo», evitando así mantener el conjunto de muestras completo en memoria. Esto sería mucho más complicado de llevar a cabo si se eligiera un modelo de *Scikit-Learn*, cuando el tamaño del conjunto de muestras supera los 15 millones de tuits, esto es algo a tener muy en cuenta. De todas formas, la diferencia en el rendimiento es minúscula, así que el sistema no debería verse perjudicado por ello.

7.3 Evaluación de los estimadores de la evolución

La segunda y última tarea de aprendizaje que se presenta en el proyecto es la estimación de la evolución cuantitativa del COVID-19 a partir de los datos recopilados, es decir, estimar la serie temporal «casos_total_diff_1» utilizando la serie temporal «vector». Para llevar a cabo esta tarea de estimación, se va a experimentar con tres modelos: un modelo de regresión lineal [16], un modelo de red neuronal artificial (ANN) [34] y un modelo de red neuronal recurrente (RNN) [27].

Se comenzará mencionando y explicando las métricas utilizadas para evaluar los modelos y seguidamente se comentarán los experimentos realizados con los modelos y sus configuraciones.

7.3.1. Métricas para los experimentos de estimación

En cuanto a las métricas que se utilizarán para evaluar los modelos, van a ser cuatro: i) el error cuadrático medio (MSE), ii) la raíz del error cuadrático medio ($RMSE$), iii) el error absoluto medio (MAE) y iv) el coeficiente de determinación (R^2). Todas ellas son métricas características para evaluar tareas de regresión o estimación. Comentar que en el error cuadrático medio, la raíz del error cuadrático medio y en el error absoluto medio, si $p > q$, entonces el modelo con el que se obtiene q es mejor (en resumen, que se desea obtener valores menores). Esto es justo lo contrario que ocurre con el coeficiente de determinación, en el que se desea obtener valores mayores. A continuación se va a explicar cada una de ellas.

La ecuación 7.4 es la correspondiente al error cuadrático medio. En ella, Y representa el vector de los valores reales sobre los que evaluar (siendo Y_i el elemento i del vector), \hat{Y} representa el vector de los valores estimados por el modelo a evaluar (siendo \hat{Y}_i el elemento i del vector) y n representa el número de muestras, es decir, la longitud de los vectores.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (7.4)$$

La ecuación 7.5 es la correspondiente al error cuadrático medio. Los símbolos que se pueden observar en ella son los mismos que se explican en el párrafo anterior. Esta métrica es únicamente la raíz cuadrada del error cuadrático medio y esto se puede observar en la ecuación.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (7.5)$$

La ecuación 7.6 es la correspondiente a la media del error absoluto. De nuevo, los símbolos que se pueden observar en ella son los mismos que aparecen en la ecuación 7.4. Esta métrica sirve para cuantificar la precisión del estimador, cuanto menor es el valor, mayor es la precisión.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (7.6)$$

Para explicar correctamente el coeficiente de determinación, hace falta explicar tres ecuaciones. Primero, en la ecuación 7.7 está representada la suma de los errores cuadráticos con respecto a la media del vector. En ella, Y es el vector de los datos reales (al igual que ocurre en el resto de métricas) y \bar{Y} representa la media del vector Y . Esta ecuación se puede interpretar como la suma de los errores al cuadrado de un estimador que estime siempre la media del vector a estimar.

$$SS_{tot} = \sum_i (Y_i - \bar{Y})^2 \quad (7.7)$$

Análogamente a la anterior ecuación explicada, en la ecuación 7.8 está representada la suma de los errores cuadráticos del estimador a evaluar. Los símbolos que aparecen en esta ecuación son los mismos que aparecen anteriormente.

$$SS_{res} = \sum_i (Y_i - \hat{Y}_i)^2 \quad (7.8)$$

Y en la ecuación 7.9 está la ecuación del coeficiente de determinación [6], que para poder ser calculada necesita los valores de las ecuaciones 7.7 y 7.8. La interpretación de esta métrica es que el resultado de aplicarla es como comparar el estimador a evaluar con un estimador que siempre estima la media. Obtener un valor de 0 para esta métrica querría decir que el estimador a evaluar funciona igual que estimar siempre la media. En cambio, un valor negativo en esta métrica (para los cuales no tiene límite inferior) implicaría que el estimador funciona peor que estimar siempre la media. Por último, el mejor valor que se puede obtener es 1, ya que este implica que el estimador no comete ningún error. Se ha elegido el coeficiente de determinación como métrica determinante para los experimentos, ya esta métrica sirve para comparar como de buenos son los modelos.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (7.9)$$

7.3.2. Experimentos con los estimadores

A continuación se va a pasar a explicar los experimentos realizados y las configuraciones utilizadas. Para realizar estos experimentos, se ha utilizado la misma técnica ya utilizada anteriormente, es decir, una búsqueda exhaustiva. Más adelante se van a mostrar unos extractos de las mejores configuraciones, pero se puede remitir a los apéndices C, D y E donde se hayan las tablas completas.

En todos los experimentos de estimación se han utilizado los valores de 15 días para el conjunto de test y el resto de días se han utilizado para entrenar los modelos. Para esta tarea, el conjunto de muestras utilizado está formado por los vectores de los días comprendidos entre el 24 de marzo de 2020 y el 22 de mayo de 2020, es decir, 58 días. Esto es así ya que las autoridades sanitarias dejaron de publicar la serie de los casos totales el día 22 de mayo de 2020, limitando bastante el tamaño del conjunto. Además del motivo previamente expuesto por el cual no se ha podido llevar a cabo una **validación cruzada** con todos los experimentos (el coste temporal), en este caso también hay que tener en cuenta el número total de muestras, el cual es muy pequeño. El número de muestras es tan pequeño que realizar una **validación cruzada** para la estimación de estas series temporales no tiene sentido.

En los experimentos realizados con los estimadores hay algunas variables comunes. Primero se van a comentar estas y luego se pasará a comentar las específicas a cada modelo:

- **Sumatorio de los vectores («Sum.»):** una de las variables a tener en cuenta es si se van a utilizar los vectores de entrada tal cual o si se van a colapsar a un solo número por día. Los valores contemplados para esta variable son: sí se realiza el sumatorio al vector de cada día («Sí») y no se realiza sumatorio al vector de cada día («No»).
- **Desplazamientos relativos entre la serie de entrada y la de salida («Lags»):** otra variable sobre la que era interesante experimentar era el número de desplazamientos relativos entre las series. Por ejemplo, un número de desplazamientos (o *lag*) igual a 1 quiere decir que con el vector de entrada del día d_i se va a estimar la salida para el día d_{i+1} (el día inmediatamente posterior). Los valores contemplados para esta variable son: 1, 2, 3, 4, 5, 6 y 7.

- **El número de días a contemplar en cada muestra de entrada («Prev.»):** esta variable es interesante ya que puede dotar a los modelos de la información relativa a la evolución previa a la entrada sobre la que se parte. Concretamente, si esta variable es igual a 1, en la entrada solo se encontrará representado un día de los datos recopilados; pero si esta variable es igual a 3, la entrada del modelo se verá extendida y también contendrá la información de los otros dos días anteriores (en total contendrá los datos de tres días). Esta variable no se aplica a los experimentos con la red neuronal recurrente (RNN), ya que la naturaleza de este modelo ya tiene embebido el mecanismo de incluir múltiples días para una sola estimación. Los valores contemplados para esta variable son: 1, 2 y 3.
- **Aplicar una transformación logarítmica («Log»):** esta es la última variable común a todos los experimentos. A lo que se refiere esta variable es a si se ha de aplicar una transformación logarítmica a los datos de entrada o no. Esta transformación puede apoyar y facilitar al modelo la tarea de la optimización de los parámetros. Los valores contemplados para esta variable son: sí se aplica la transformación («Sí») y no se aplica la transformación («No»).

Y una vez explicados las variables comunes a los experimentos con ambos modelos, se van a explicar las variables específicas de cada modelo y se van a mostrar los mejores resultados obtenidos (teniendo en cuenta la métrica escogida como determinante: el coeficiente de determinación, R^2).

Para el modelo de estimación por regresión lineal no hay ninguna variable adicional a las comunes y se va a pasar directamente a analizar los resultados obtenidos.

Sum.	Lags	Prev.	Log	MSE	RMSE	MAE	R2
No	5	3	Sí	0.0579	0.2407	0.196	0.4697
Sí	4	3	Sí	0.1102	0.3319	0.2761	-0.0089
Sí	5	2	Sí	0.1208	0.3476	0.2718	-0.1064
Sí	3	3	Sí	0.1166	0.3414	0.2704	-0.1456
Sí	6	3	Sí	0.1313	0.3623	0.2882	-0.1565
Sí	5	3	Sí	0.1265	0.3556	0.2769	-0.158
Sí	6	2	Sí	0.1303	0.3609	0.2835	-0.1929
Sí	6	1	Sí	0.1329	0.3645	0.2803	-0.2166

Tabla 7.3: Tabla de los mejores resultados para estimación con regresión lineal

Como se puede observar en la tabla 7.3, el mejor resultado se obtiene de la siguiente configuración: no realizar el sumatorio de los vectores de cada día, un número de desplazamientos relativos entre las series igual a 5 días, la inclusión de 3 días consecutivos en la entrada para una misma muestra y sí aplicar la transformación logarítmica a la entrada. Con esta configuración se alcanza un R^2 igual a 0,4697. En estos experimentos se puede observar como el modelo empieza a realizar estimaciones significantes cuando se le dota de la información completa del séptimo día anterior, del sexto día anterior y del quinto día anterior. Esto concuerda con los estudios realizados acerca de cuando el virus empieza a expresar su sintomatología [14].

Ahora se pasará a hablar del modelo de estimación por red neuronal artificial. Para este modelo hay un par de variables adicionales a las comunes:

- Configuración de las capas ocultas de la red («H.L.»):** esta variable es la que configura tanto el número de capas ocultas de la red (profundidad) como el número de unidades de cada capa (anchura). Con esta variable ocurre lo mismo que con la variable análoga para la clasificación con red neuronal artificial: este parámetro está calculado en función de la dimensionalidad total del vector de entrada, la cual depende del número de días que se incluyan y de si se realiza el sumatorio de cada día o no. Estas funciones se pueden observar en la figura 7.6.

```

7 dense_nparams_s = [
8     lambda x: [],
9     lambda x: [x],
10    lambda x: [max(x//i, 1) for i in range(1,3)],
11    lambda x: [max(x//i, 1) for i in range(1,4)],
12    lambda x: [sum([max(x//j, 1) for j in range(i,3)]) for i in range(1,3)],
13    lambda x: [sum([max(x//j, 1) for j in range(i,4)]) for i in range(1,4)]
14 ]

```

Figura 7.6: Funciones generadoras de la configuración de las capas ocultas para el estimador ANN

- Valor de la probabilidad de dropout («Drop»):** este parámetro es el que se introduce en las capas de *dropout*. Las capas de *dropout* lo que hacen es «ignorar» las unidades de las capas ocultas con una probabilidad establecida. Esta variable es completamente equivalente a la variable de *dropout* del clasificador con red neuronal artificial. Los valores contemplados para esta variable son: 0 (no se aplica) y 0,2 (se aplica con una probabilidad del 20%).

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	7	2	Sí	[32]	0.2	0.0613	0.2476	0.2084	0.4597
No	6	3	No	[48]	0.0	0.0124	0.1112	0.0912	0.4577
No	2	2	Sí	[32]	0.0	0.0627	0.2505	0.1957	0.3833
Sí	6	2	Sí	[]	0.0	0.0694	0.2635	0.2134	0.3642
No	1	1	No	[16]	0.0	0.0087	0.0932	0.0759	0.3565
Sí	6	3	Sí	[]	0.0	0.0797	0.2824	0.2394	0.2974
No	3	2	No	[32]	0.0	0.0125	0.1118	0.091	0.2899
No	2	3	Sí	[48]	0.2	0.0729	0.27	0.2224	0.2836

Tabla 7.4: Tabla de los mejores resultados para estimación con ANN

Como se puede observar en la tabla 7.4, el mejor resultado se obtiene de la siguiente configuración: no realizar el sumatorio de los vectores de cada día, un número de desplazamientos relativos entre las series igual a 7 días, la inclusión de 2 días consecutivos en la entrada para una misma muestra, sí aplicar la transformación logarítmica a la entrada, una sola capa oculta compuesta por 32 unidades y una probabilidad de *dropout* igual a 0,2. Con esta configuración se alcanza un R^2 igual a 0,4597. De nuevo, estos experimentos han dado mejor resultado cuando se le dota de la información completa del octavo día anterior y del séptimo día anterior. También de nuevo, estos resultados concuerdan con los estudios realizados acerca de cuando el virus empieza a expresar su sintomatología [14].

Ahora se pasará a hablar del modelo de estimación por red neuronal recurrente. Es importante volver a comentar que la variable que afecta a cuantos días previos incluir en la entrada se ha sustituido por la variable del número de pasos temporales (*timesteps*). De esta forma para este modelo hay cuatro variables adicionales a las comunes (contando también la de los *timesteps*):

- **Número de pasos temporales o *timesteps* («Tim.»):** este parámetro (junto a las capas de memoria) es el que dota a la red neuronal recurrente la posibilidad de tomar en cuenta más valores previos para realizar la estimación. Esta variable se puede entender como el número de días previos que el modelo necesita para realizar una estimación. Los valores contemplados para esta variable son: 2, 3 y 5.
- **Configuración de las capas de memoria LSTM de la red («M.L.»):** esta variable es la que configura tanto el número de capas de memoria de la red como el número de unidades LSTM de cada capa. Estas capas son aquellas que dotan al sistema de la capacidad de utilizar las entradas previas para la estimación final (junto con la variable del número de *timesteps*). Con esta variable ocurre lo mismo que con la variable que configura las capas ocultas de la red: este parámetro está calculado en función de la dimensionalidad total del vector de entrada, la cual, en este caso, depende de si se realiza el sumatorio de cada día o no. Estas funciones se pueden observar en la figura 7.7.

```

7 lstm_unit_s = [
8     lambda x: [max(x//2, 10)],
9     lambda x: [max(x//i, 10) for i in range(1,3)],
10 ]

```

Figura 7.7: Funciones generadoras de la configuración de las capas de memoria LSTM para el estimador RNN

- **Configuración de las capas ocultas de la red («H.L.»):** esta variable es la que configura tanto el número de capas ocultas de la red como el número de unidades de cada capa. Con esta variable ocurre lo mismo que con la variable análoga para la clasificación con red neuronal artificial: este parámetro también está calculado en función de la dimensionalidad total del vector de entrada, la cual, en este caso, depende de si se realiza el sumatorio de cada día o no. Estas funciones se pueden observar en la figura 7.8.

```

12 dense_nparams_s = [
13     lambda x: [x],
14     lambda x: [max(x//i, 1) for i in range(1,3)],
15     lambda x: [sum([max(x//j, 1) for j in range(i,3)]) for i in range(1,3)],
16 ]

```

Figura 7.8: Funciones generadoras de la configuración de las capas ocultas para el estimador RNN

- **Valor de la probabilidad de *dropout* («Drop»):** este parámetro es el que se introduce en las capas de *dropout*. Las capas de *dropout* lo que hacen es «ignorar» las unidades de las capas ocultas con una probabilidad establecida. Esta variable es completamente equivalente a la variable de *dropout* del estimador con red neuronal artificial. Los valores contemplados para esta variable son: 0 (no se aplica) y 0,2 (se aplica con una probabilidad del 20%).

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	2	No	5	[16, 10]	[16]	0.0	0.0031	0.0558	0.0447	0.5269
Sí	2	Sí	5	[10]	[1]	0.0	0.0416	0.204	0.1723	0.4084
No	5	Sí	2	[10]	[16]	0.2	0.0569	0.2386	0.1903	0.3912
No	2	Sí	5	[16, 10]	[16]	0.2	0.0498	0.2231	0.1794	0.2925
Sí	1	Sí	5	[10]	[1]	0.0	0.0484	0.2199	0.1774	0.2417
No	1	No	5	[16, 10]	[16]	0.0	0.0042	0.0648	0.0564	0.1875
No	5	No	3	[16, 10]	[16]	0.0	0.0108	0.1038	0.072	0.1651
No	4	No	3	[10]	[16]	0.0	0.0109	0.1045	0.0658	0.1534

Tabla 7.5: Tabla de los mejores resultados para estimación con RNN

Como se puede observar en la tabla 7.5, el mejor resultado se obtiene de la siguiente configuración: no realizar el sumatorio de los vectores de cada día, un número de desplazamientos relativos entre las series igual a 2 días, no aplicar la transformación logarítmica a la entrada, la inclusión de 5 días consecutivos en la entrada para una misma muestra mediante el uso de los *timesteps*, dos capas de memoria compuestas por 16 y 10 unidades, una sola capa oculta compuesta por 16 unidades y una probabilidad de *dropout* igual a 0,2. Con esta configuración se alcanza un R^2 igual a 0,5269. De nuevo, estos experimentos han dado mejor resultado cuando se le dota de la información completa del séptimo día anterior, del sexto día anterior, del quinto día anterior, del cuarto día anterior y del tercer día anterior. También de nuevo, estos resultados concuerdan con los estudios realizados acerca de cuando el virus empieza a expresar su sintomatología [14].

Finalmente, se ha elegido el modelo de red neuronal recurrente como modelo de estimación final. Se ha elegido este modelo porque, además de haber dado unos resultados ligeramente mejores, igual que ocurre con las secuencias, *Keras* también ofrece una funcionalidad para poder crear las muestras teniendo en cuenta los *timesteps*, esta sería una tarea más compleja si no se dispusiera de esta herramienta.

Como un último apunte, remarcar que estos experimentos con los modelos de estimación habrían sido llevados a cabo idealmente utilizando una **validación cruzada**, pero por el pequeño volumen de días del que se dispone esto no es posible.

CAPÍTULO 8

Conclusiones

En este proyecto se ha diseñado un sistema cuyo objetivo primario es el de «estimar la evolución cuantitativa del COVID-19 en España, a partir de la información que se publica en Twitter», y como objetivo secundario es que se pueda «estimar la evolución cuantitativa de la gravedad de la pandemia, introduciendo una gradación en la gravedad de los casos estimados por el sistema». El sistema que se ha diseñado consta de 4 fases, utilizando las *fases 0, 1 y 2* en conjunto se cumple con el objetivo primario y la *fase 3* se ha diseñado para cumplir con el objetivo secundario. Los objetivos concretos de estas fases son:

- **Fase 0.** Conectarse a una fuente de datos externa (la [API de Twitter](#)), procesar y almacenar los datos recopilados.
- **Fase 1.** Transformar los datos recopilados en vectores numéricos con los que poder trabajar.
- **Fase 2.** Estimar la evolución cuantitativa del COVID-19 en España
- **Fase 3.** Estimar la evolución cuantitativa de la gravedad de la pandemia, introduciendo una gradación en la gravedad de los casos estimados por el sistema.

Se ha cumplido con los objetivos de las *fases 0, 1 y 2*, y el sistema que se ha implementado y se entrega consta de estas fases, cumpliendo así con los objetivos concretos de estas fases y el objetivo primario del trabajo de fin de grado.

Cabe destacar que se ha desarrollado una metodología para poder llevar a cabo la correcta implementación del sistema. Esta metodología se encuentra detallada en el la sección [1.4](#). Siguiendo la metodología propuesta, los resultados obtenidos son esperanzadores, tomando en cuenta que el volumen de datos y la calidad de estos no era la deseable, y es un logro haber podido obtener algo de valor a partir de dichos datos.

En cuanto al número de muestras para entrenar los estimadores (que al final es equivalente al número de días de los que se disponen datos), el número de muestras ha sido muy bajo, siendo este número de alrededor de 58 días. En otras tareas de estimación de series temporales similares se llegan a utilizar varias anualidades enteras de datos y en este proyecto apenas se han llegado a utilizar alrededor de dos meses de datos.

Otro indicio de que los resultados obtenidos son coherentes con otros estudios es que los modelos obtenidos han funcionado mejor cuando se introduce un adelanto de entre cinco u ocho días. Resulta que este número de días son los días que se ha demostrado que los casos de COVID-19 tardan de media en empeorar [\[14\]](#). Esto quiere decir que los días de adelanto que han funcionado mejor con los modelos coinciden con los días que se han podido observar que tarda la sintomatología del COVID-19 en empeorar.

Y en cuanto a la calidad del dato, se ha de tener en cuenta que en este proyecto se trabaja a un nivel nacional y los datos ofrecidos por las fuentes oficiales son los acumulados de las comunidades autónomas. Y lo que ocurre es que las series individuales de las comunidades autónomas no se han creado siguiendo el mismo procedimiento, lo cual introduce ruido en la serie temporal y hace que disminuya su calidad.

Respecto a la *fase 3*, sobre todo por falta de tiempo, no se ha podido terminar la implementación de la *fase 3*. Sin embargo, a pesar de que no se hayan podido mostrar resultados acerca de la *fase 3* del proyecto, cabe mencionar que esta ya se encuentra en desarrollo, ya que se ha realizado su diseño. Además, se ha hecho la división del trabajo y la estimación de tiempos para la implementación de esta fase y se disponen de los datos y los medios para llevarla a cabo, es únicamente una cuestión de tiempo poder finalizar su implementación.

En resumen, se puede considerar que el resultado de este proyecto ha sido un éxito y que la estrategia seguida con la utilización de las técnicas de PLN y aprendizaje automático ha demostrado un gran potencial.

8.1 Relación del trabajo desarrollado con los estudios cursados

Este trabajo integra conocimientos obtenidos en muchas de las asignaturas cursadas en el grado, y a continuación se van a mencionar y describir las influencias más importantes obtenidas en el grado que se han aplicado en este trabajo.

Una de las competencias o conocimientos más utilizados a lo largo de todo el trabajo es la calidad del código y la habilidad a la hora de programar. A lo largo del grado se está continuamente aprendiendo a programar: desde que se aprende a programar de cero en «Introducción a la Informática y la Programación» (IIP) o «Programación» (PRG) de primer curso, hasta que se aprende acerca de la programación asíncrona y paralela en «Tecnologías de los Sistemas de Información en la Red» (TSR) y «Computación Paralela» (CPA).

Está claro que si un proyecto trata sobre la implementación de una herramienta informática, la base sobre la que se asienta ese proyecto es la capacidad de programar, y ese es el caso de este trabajo. Así que la primera relación con el grado que se puede encontrar es esa: la capacidad de producir código correcto y de calidad.

En relación con esa primera influencia mencionada, también se puede destacar la influencia recibida de «Sistemas de Almacenamiento y Recuperación de información» (SAR) y «Algorítmica» (ALG) en cuanto a la habilidad obtenida a la hora de programar en *Python* en esas asignaturas. La primera aparición de *Python* en el grado fue en SAR (al menos en mi caso) y, sin duda, después de haber trabajado bastante utilizándolo, me habría gustado que hubiera aparecido más pronto en el grado, incluso como lenguaje de programación complementario para algunas tareas.

De SAR también se puede extraer una de las influencias más importantes: el primer contacto con el PLN. En SAR se aprenden técnicas y procesos que sin duda son básicos en cualquier sistema que utilice PLN, como puede ser la representación en «bolsa de palabras» (*bag of words*) o los espacios vectoriales que permiten calcular la distancia entre términos y oraciones. Haber cursado SAR ha sido de gran ayuda a lo largo de todo el desarrollo.

También han sido una influencia clave «Sistemas Inteligentes» (SIN), «Percepción» (PER) y «Aprendizaje» (APR), ya que en ellas se tratan temas de aprendizaje automático (tanto supervisado como no supervisado) y la habilidad de aplicar este tipo de técnicas y modelos son un pilar central sobre el que se apoya este trabajo.

Y otra de las influencias a considerar es la obtenida de asignaturas como «Ingeniería de Software» (ISW) o «Gestión de Proyectos» (GPR). Gracias a asignaturas de esta índole se ha obtenido experiencia y habilidad a la hora de estructurar, organizar y llevar a cabo proyectos.

A continuación también se va a establecer la relación que tiene el trabajo aquí llevado a cabo con las competencias transversales de la Universidad Politécnica de Valencia (UPV):

- **CT-01. Comprensión e integración:** para diseñar el sistema ha sido necesario agrupar y sintetizar conocimientos adquiridos a lo largo de todo el grado, así como también conocimientos extraídos de fuentes externas a la universidad.
- **CT-02. Aplicación y pensamiento práctico:** en este proyecto ha sido necesario hacer una profunda interpretación de los datos y también se ha realizado un análisis exhaustivo de los mismos, con el fin de poder implementar el sistema de una forma correcta.
- **CT-03. Análisis y resolución de problemas:** esta competencia se ha desarrollado al llevar a cabo este proyecto, ya que para su correcta implementación han sido necesarias las fases de análisis del problema (3) y diseño de la solución (4).
- **CT-04. Innovación, creatividad y emprendimiento:** este proyecto se ha creado teniendo en mente cubrir un área de la literatura que se encontraba un poco vacía: fusionar las técnicas de procesamiento del lenguaje natural con las de **aprendizaje automático**, con el fin de estimar la evolución del COVID-19.
- **CT-05. Diseño y proyecto:** para llevar a cabo el diseño y la división del trabajo de este proyecto, han sido necesarias técnicas características de la gestión de proyectos.
- **CT-06. Trabajo en equipo y liderazgo:** esta competencia se ha desarrollado ya que han sido necesarias múltiples reuniones con diferentes personas para apoyar el análisis y el diseño del sistema.
- **CT-07. Responsabilidad ética, medioambiental y profesional:** en la sección 3.2 se ha realizado un análisis de los aspectos legales y éticos que conlleva este proyecto.
- **CT-08. Comunicación efectiva:** en la redacción de esta memoria se han respetado todos los formatos convencionales y también se ha intentado organizar la información de forma que sea más clara.
- **CT-09. Pensamiento crítico:** se ha analizado el estado de la cuestión en el capítulo 2 y se han tomado decisiones acerca del diseño y la implementación del sistema.
- **CT-10. Conocimiento de problemas contemporáneos:** las tareas de estimación y clasificación mediante modelos de **aprendizaje automático** son sin duda alguna dos problemas contemporáneos, así como también lo es el uso de información en lenguaje natural para alimentar modelos.
- **CT-11. Aprendizaje permanente:** para llevar a cabo este proyecto se ha tenido que investigar y aprender sobre tecnologías que no se habían estudiado o utilizado previamente.
- **CT-12. Planificación y gestión del tiempo:** para llevar a cabo este proyecto se ha definido una división del trabajo (la cual se ve representada en la figura 3.1), estimando también los tiempos requeridos para cada tarea.

- **CT-13. Instrumental específica:** en este proyecto se han utilizado tecnologías muy especializadas y para su integración en el sistema ha sido necesario mucho tiempo y dedicación.

Finalmente, un detalle importante es que los estudios cursados en la universidad han servido como punto de entrada a otras técnicas y tecnologías. Estas tecnologías no han sido estudiadas como tal en ninguna asignatura, pero gracias a la educación y experiencia adquirida, ha sido posible realizar una tarea de auto-aprendizaje, con el fin de poder experimentar y explotar tecnologías más avanzadas.

CAPÍTULO 9

Trabajos futuros

A lo largo del desarrollo del sistema, se han detectado algunas mejoras y ampliaciones a este sistema. A continuación se van a enunciar y comentar algunas.

Una de estas mejoras hace referencia a algunos de los procesos por los que pasan los datos. Hay algunos de los procesos que serían fácilmente paralelizables gracias a la existencia de un índice en la base de datos. Por ejemplo, tanto la clasificación de localización como la **vectorización** se podrían ejecutar en un entorno paralelo, esto podría llevar a que se redujera considerablemente el tiempo de procesamiento.

Otra mejora tendría en cuenta el uso de la base de datos. En el caso de este sistema, la base de datos se encuentra centralizada en un único equipo/servidor. Hoy en día existen técnicas denominadas como *sharding*, las cuales permiten dividir una base de datos en secciones (o *shards*) que se distribuyen entre varios equipos o servidores. Podría ser interesante intentar aplicar alguna de estas técnicas a la base de datos y ver como afectan estas modificaciones al rendimiento del sistema, tanto si son mejoras como no.

Una de las ampliaciones que quedan claras tras leer esta memoria sería la de implementar la *fase 3* del proyecto, es decir, realizar la estimación conjunta de la evolución del número de casos y del número de hospitalizaciones. A pesar de que esta fase ya se encuentra en desarrollo por parte de este proyecto, se invita a futuras personas y equipos a tratar de llevar a cabo esta tarea, probando diferentes técnicas de **vectorización** o incluso diferentes modelos de estimación.

Otra mejora podría ser la referente al volumen de datos. Dado que este proyecto ha surgido de una forma muy sobreenvenida, los datos de los que se disponen son muy reducidos. Por este motivo, también sería interesante poder llevar a cabo toda la experimentación con un volumen de datos mayor. En este proyecto se disponen de los tuits correspondientes a 58 días ¹. Un buen inicio podría ser analizar el *dataset* publicado por *Panacea Lab* [3], un grupo de la Universidad del Estado de Georgia en Estados Unidos, dedicado a el **PLN** y el **aprendizaje automático**.

Una de las posibles ampliaciones más interesantes sería la referente a las técnicas de **vectorización**. En este proyecto, para vectorizar se utiliza un simple contador de ocurrencias sobre un vocabulario concreto y definido. Esta técnica es una técnica muy simple, pero que como se ha podido ver ha dado resultados significantes. De todas formas, existen muchas otras técnicas de **PLN** a partir de las cuales se puede extraer el significado de la información. Estas técnicas se podrían utilizar a modo de apoyo o incluso de sustitución del contador de ocurrencias, ya que son capaces de extraer una cantidad de información mucho mayor.

¹Este número es correcto a fecha de escritura.

Una ampliación a este proyecto que también se podría realizar es una experimentación mucho más exhaustiva. A pesar de que el número de experimentos llevados a cabo en este proyecto es muy grande ², todavía existen muchos hiperparámetros con los que experimentar, los cuales se han fijado debido al límite de recursos materiales y temporales de los que se disponen.

Finalmente, otra mejora también muy interesante podría ser el uso de diferentes modelos de aprendizaje automático a la hora de estimar la E.C. del COVID-19. En este proyecto se ha experimentado con tres tipos de modelos (regresión lineal, red neuronal artificial y red neuronal recurrente), pero existen muchos más con los que se podría experimentar, como por ejemplo redes de residuales o redes neuronales recurrentes con mecanismos de atención.

²Se remite a los apéndices A, B, C, D y E para poder observar su extensión total.

Glosario

middleware Software que asiste a una aplicación para interactuar o comunicarse con otras aplicaciones, o paquetes de programas, redes, hardware o sistemas operativos. En castellano *lógica de intercambio de información entre aplicaciones*.

ANN Red neuronal artificial, del inglés *Artificial Neural Network*.

API Interfaz de programación de aplicaciones, del inglés *Application Programming Interface*.

aprendizaje automático El aprendizaje automático es un subcampo de las ciencias de la computación y una rama de la inteligencia artificial, cuyo objetivo es desarrollar técnicas que permitan que las computadoras *aprendan*.

Bluetooth Especificación industrial para redes inalámbricas de área personal (WPAN) creado por *Bluetooth Special Interest Group, Inc.*

EDT Esquema de Desglose del Trabajo.

función de resumen Función que tiene como entrada un conjunto de elementos, que suelen ser cadenas, y en la salida los convierte en un rango de salida finito, normalmente cadenas de longitud fija.

GPU Unidad de procesamiento gráfico, del inglés *Graphics Processing Unit*.

hiperparámetro Un hiperparámetro es un parámetro cuyo valor se establece antes de que comience el proceso de entrenamiento. Teniendo en cuenta estos hiperparámetros, el algoritmo de entrenamiento aprende los parámetros a partir de los datos.

IDE Entorno de desarrollo integrado, del inglés *Integrated Development Environment*.

JSON Notación de objeto de *JavaScript*, del inglés *JavaScript Object Notation*.

LSTM Memoria largo-corto plazo, del inglés *Long Short-Term Memory*.

PLN Procesamiento del Lenguaje Natural, en inglés *Natural Language Processing (NLP)*.

RNN Red neuronal recurrente, del inglés *Recurrent Neural Network*.

SGBD Sistema Gestor de Bases de Datos.

sobreajuste El efecto de sobreentrenar un algoritmo de aprendizaje con unos ciertos datos para los que se conoce el resultado deseado. Cuando un sistema se entrena demasiado (se sobreentrena) o se entrena con datos extraños, el algoritmo de aprendizaje puede quedar ajustado a unas características muy específicas de los datos de entrenamiento que no tienen relación causal con la función objetivo.

SQL Lenguaje de consulta estructurada, del inglés *Structured Query Language*.

SVM Máquina de vectores soporte, del inglés *Support Vector Machine*.

UCI Unidad de Cuidados Intensivos.

validación cruzada Técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de las métricas de evaluación sobre diferentes particiones.

vectorización Transformación que, al aplicarse a un texto, lo convierte en un vector numérico.

wifi Sistema de conexión inalámbrica, dentro de un área determinada, entre dispositivos electrónicos, y frecuentemente para acceso a internet.

Bibliografía

- [1] Explosion AI. spacy · industrial-strength natural language processing in python. <https://spacy.io/>. (Último acceso el 05/05/2020).
- [2] Python Cryptographic Authority. Github - pyca/bcrypt: Modern(-ish) password hashing for your software and your servers. <https://github.com/pyca/bcrypt/>. (Último acceso el 07/02/2020).
- [3] Juan M. Banda, Ramya Tekumalla, Guanyu Wang, Jingyuan Yu, Tuo Liu, Yuning Ding, Katya Artemova, Elena Tutubalina, and Gerardo Chowell. A large-scale COVID-19 Twitter chatter dataset for open scientific research - an international collaboration, June 2020.
- [4] Mónica Bocco, Enrique Willington, and Mónica Arias. Comparison of Regression and Neural Networks Models to Estimate Solar Radiation. *Chilean journal of agricultural research*, 70(3), 2010.
- [5] Royal Society (Great Britain). *Proceedings of the Royal Society of London*. Number v. 58. Taylor & Francis, 1895.
- [6] A. [Colin Cameron] and Frank A.G. Windmeijer. An r-squared measure of goodness of fit for some common nonlinear regression models. *Journal of Econometrics*, 77(2):329 – 342, 1997.
- [7] Instituto Cervantes. El español, una lengua que hablan 580 millones de personas, 483 millones de ellos nativos. https://www.cervantes.es/sobre_instituto_cervantes/prensa/2019/noticias/presentacion_anuario_madrid.htm. (Último acceso el 29/06/2020).
- [8] François Chollet et al. Keras. <https://keras.io>, 2015. (Último acceso el 04/05/2020).
- [9] Corinna Cortes and Vladimir Vapnik. Support-vector networks. In *Machine Learning*, pages 273–297, 1995.
- [10] Python Software Foundation. Python 3.8.3rc1 documentation. <https://docs.python.org/3/>. (Último acceso el 05/05/2020).
- [11] Mark Graham, Scott A Hale, and Devin Gaffney. Where in the World Are You? Geolocation and Language Identification in Twitter. *Professional Geographer*, 66(4):568–578, 2014.
- [12] C. W. J. Granger. Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3):424–438, 1969.
- [13] John D. Hunter. Matplotlib: A 2D graphics environment. *Computing in Science and Engineering*, 9(3):99–104, may 2007.

- [14] Stephen Lauer, Kyra Grantz, Qifang Bi, Forrest Jones, Qulu Zheng, Hannah Meredith, Andrew Azman, Nicholas Reich, and Justin Lessler. The incubation period of coronavirus disease 2019 (covid-19) from publicly reported confirmed cases: Estimation and application. *Annals of internal medicine*, 172, 03 2020.
- [15] Christopher D. Manning, Prabhakar Raghavan, and Hinrich Schütze. *Scoring, term weighting, and the vector space model*, page 100–123. Cambridge University Press, 2008.
- [16] Keith A. Marill. Advanced statistics: Linear regression, part ii: Multiple linear regression. *Academic Emergency Medicine*, 11(1):94–102, 2004.
- [17] K. Jarrod Millman and Michael Aivazis. *Python for scientists and engineers*, mar 2011.
- [18] Inc. MongoDB. The mongodb 4.2 manual — mongodb manual. <https://docs.mongodb.com/manual/>. (Último acceso el 04/05/2020).
- [19] Inc. MongoDB. Pymongo 3.10.1 documentation. <https://pymongo.readthedocs.io/en/stable/>. (Último acceso el 05/05/2020).
- [20] Rodrigo Moraes, João Francisco Valiati, and Wilson P. [Gavião Neto]. Document-level sentiment classification: An empirical comparison between svm and ann. *Expert Systems with Applications*, 40(2):621 – 633, 2013.
- [21] Travis E Oliphant. *A guide to NumPy*, volume 1. Trelgol Publishing USA, 2006.
- [22] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, Jake Vanderplas, Alexandre Passos, David Cournapeau, Matthieu Brucher, Matthieu Perrot, and Édouard Duchesnay. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12(85):2825–2830, 2011.
- [23] Fernando Pérez and Brian E. Granger. IPython: A system for interactive scientific computing. *Computing in Science and Engineering*, 9(3):21–29, may 2007.
- [24] Niels Provos and David Mazieres. A future-adaptable password scheme. 03 2001.
- [25] Enrique Pérez. Probamos radar covid: así funciona la aplicación de rastreo de contactos que usaremos en españa. <https://www.xataka.com/aplicaciones/probamos-radar-covid-asi-funciona-aplicacion-rastreo-contactos-que-usaremos-espana>. (Último acceso el 01/07/2020).
- [26] Yutaka Sasaki. The truth of the F-measure The truth of the F-measure. (January 2007):1–6, 2015.
- [27] Alex Sherstinsky. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *CoRR*, abs/1808.03314, 2018.
- [28] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15:1929–1958, 2014.
- [29] Tweepy. Tweepy. <https://www.tweepy.org/>. (Último acceso el 05/05/2020).
- [30] Inc. Twitter. Developer terms – twitter developers. <https://developer.twitter.com/en/developer-terms>. (Último acceso el 30/06/2020).
- [31] Naciones Unidas. Salud – desarrollo sostenible. <https://www.un.org/sustainabledevelopment/es/health/>. (Último acceso el 23/06/2020).

-
- [32] Stéfan Van Der Walt, S. Chris Colbert, and Gaël Varoquaux. The NumPy array: A structure for efficient numerical computation. *Computing in Science and Engineering*, 13(2):22–30, mar 2011.
- [33] Wes McKinney. Data Structures for Statistical Computing in Python. In Stéfan van der Walt and Jarrod Millman, editors, *Proceedings of the 9th Python in Science Conference*, pages 56 – 61, 2010.
- [34] Andreas Zell. *Simulation neuronaler netze*. Number 5.3. Addison-Wesley Bonn, 1994.

APÉNDICE A

Tabla comparativa de configuraciones de localización: red neuronal artificial

En esta búsqueda exhaustiva se han entrenado y evaluado 960 configuraciones.

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Tf-Idf	(1, 1)	50	No	[50]	0.2	0.6039	0.0360	0.0679
No	Tf-Idf	(1, 1)	50	No	[50]	0	0.6061	0.0490	0.0907
No	Tf-Idf	(1, 1)	50	No	[50, 25]	0.2	0.5789	0.0563	0.1026
No	Tf-Idf	(1, 1)	50	No	[50, 25]	0	0.6016	0.0504	0.0929
No	Tf-Idf	(1, 1)	50	No	[50, 25, 16]	0.2	0.6695	0.0264	0.0508
No	Tf-Idf	(1, 1)	50	No	[50, 25, 16]	0	0.6085	0.0472	0.0876
No	Tf-Idf	(1, 1)	50	No	[75, 25]	0.2	0.6656	0.0329	0.0626
No	Tf-Idf	(1, 1)	50	No	[75, 25]	0	0.6667	0.0201	0.0391
No	Tf-Idf	(1, 1)	50	No	[91, 41, 16]	0.2	0.6144	0.0324	0.0615
No	Tf-Idf	(1, 1)	50	No	[91, 41, 16]	0	0.6290	0.0451	0.0841
No	Tf-Idf	(1, 1)	50	Sí	[50]	0.2	0.6471	0.0948	0.1653
No	Tf-Idf	(1, 1)	50	Sí	[50]	0	0.6410	0.1111	0.1894
No	Tf-Idf	(1, 1)	50	Sí	[50, 25]	0.2	0.6417	0.1091	0.1866
No	Tf-Idf	(1, 1)	50	Sí	[50, 25]	0	0.6449	0.0978	0.1698
No	Tf-Idf	(1, 1)	50	Sí	[50, 25, 16]	0.2	0.6073	0.1238	0.2057
No	Tf-Idf	(1, 1)	50	Sí	[50, 25, 16]	0	0.5982	0.1237	0.2050
No	Tf-Idf	(1, 1)	50	Sí	[75, 25]	0.2	0.6572	0.0915	0.1606
No	Tf-Idf	(1, 1)	50	Sí	[75, 25]	0	0.6472	0.1078	0.1849
No	Tf-Idf	(1, 1)	50	Sí	[91, 41, 16]	0.2	0.5988	0.1316	0.2158
No	Tf-Idf	(1, 1)	50	Sí	[91, 41, 16]	0	0.6475	0.1044	0.1797
No	Tf-Idf	(1, 1)	500	No	[500]	0.2	0.7076	0.2609	0.3812
No	Tf-Idf	(1, 1)	500	No	[500]	0	0.7202	0.2427	0.3631
No	Tf-Idf	(1, 1)	500	No	[500, 250]	0.2	0.7539	0.2317	0.3544
No	Tf-Idf	(1, 1)	500	No	[500, 250]	0	0.7260	0.2568	0.3794
No	Tf-Idf	(1, 1)	500	No	[500, 250, 166]	0.2	0.7139	0.2802	0.4025
No	Tf-Idf	(1, 1)	500	No	[500, 250, 166]	0	0.7181	0.2936	0.4168
No	Tf-Idf	(1, 1)	500	No	[750, 250]	0.2	0.7572	0.2533	0.3796
No	Tf-Idf	(1, 1)	500	No	[750, 250]	0	0.7196	0.2611	0.3831
No	Tf-Idf	(1, 1)	500	No	[916, 416, 166]	0.2	0.6849	0.3119	0.4286
No	Tf-Idf	(1, 1)	500	No	[916, 416, 166]	0	0.7714	0.2607	0.3897

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Tf-Idf	(1, 1)	500	Sí	[500]	0.2	0.6672	0.2616	0.3758
No	Tf-Idf	(1, 1)	500	Sí	[500]	0	0.6784	0.2543	0.3699
No	Tf-Idf	(1, 1)	500	Sí	[500, 250]	0.2	0.7120	0.2584	0.3792
No	Tf-Idf	(1, 1)	500	Sí	[500, 250]	0	0.7449	0.2454	0.3691
No	Tf-Idf	(1, 1)	500	Sí	[500, 250, 166]	0.2	0.7107	0.2738	0.3953
No	Tf-Idf	(1, 1)	500	Sí	[500, 250, 166]	0	0.7514	0.2280	0.3499
No	Tf-Idf	(1, 1)	500	Sí	[750, 250]	0.2	0.7128	0.2672	0.3887
No	Tf-Idf	(1, 1)	500	Sí	[750, 250]	0	0.6738	0.2954	0.4107
No	Tf-Idf	(1, 1)	500	Sí	[916, 416, 166]	0.2	0.7616	0.2269	0.3496
No	Tf-Idf	(1, 1)	500	Sí	[916, 416, 166]	0	0.7117	0.2703	0.3918
No	Tf-Idf	(1, 1)	2000	No	[2000]	0.2	0.6653	0.4103	0.5076
No	Tf-Idf	(1, 1)	2000	No	[2000]	0	0.6590	0.4282	0.5191
No	Tf-Idf	(1, 1)	2000	No	[2000, 1000]	0.2	0.8179	0.3182	0.4582
No	Tf-Idf	(1, 1)	2000	No	[2000, 1000]	0	0.7189	0.4252	0.5343
No	Tf-Idf	(1, 1)	2000	No	[2000, 1000, 666]	0.2	0.8522	0.2905	0.4333
No	Tf-Idf	(1, 1)	2000	No	[2000, 1000, 666]	0	0.7239	0.4359	0.5442
No	Tf-Idf	(1, 1)	2000	No	[3000, 1000]	0.2	0.7742	0.3595	0.4910
No	Tf-Idf	(1, 1)	2000	No	[3000, 1000]	0	0.7687	0.3890	0.5166
No	Tf-Idf	(1, 1)	2000	No	[3666, 1666, 666]	0.2	0.8051	0.3568	0.4945
No	Tf-Idf	(1, 1)	2000	No	[3666, 1666, 666]	0	0.7636	0.4059	0.5300
No	Tf-Idf	(1, 1)	2000	Sí	[2000]	0.2	0.6355	0.3771	0.4734
No	Tf-Idf	(1, 1)	2000	Sí	[2000]	0	0.6513	0.4115	0.5044
No	Tf-Idf	(1, 1)	2000	Sí	[2000, 1000]	0.2	0.7313	0.3722	0.4933
No	Tf-Idf	(1, 1)	2000	Sí	[2000, 1000]	0	0.7304	0.3852	0.5044
No	Tf-Idf	(1, 1)	2000	Sí	[2000, 1000, 666]	0.2	0.7965	0.3367	0.4733
No	Tf-Idf	(1, 1)	2000	Sí	[2000, 1000, 666]	0	0.7075	0.4126	0.5213
No	Tf-Idf	(1, 1)	2000	Sí	[3000, 1000]	0.2	0.7587	0.3608	0.4890
No	Tf-Idf	(1, 1)	2000	Sí	[3000, 1000]	0	0.7425	0.3928	0.5138
No	Tf-Idf	(1, 1)	2000	Sí	[3666, 1666, 666]	0.2	0.8376	0.2870	0.4275
No	Tf-Idf	(1, 1)	2000	Sí	[3666, 1666, 666]	0	0.7263	0.3575	0.4791
No	Tf-Idf	(1, 1)	3000	No	[3000]	0.2	0.6142	0.4912	0.5459
No	Tf-Idf	(1, 1)	3000	No	[3000]	0	0.6942	0.4194	0.5229
No	Tf-Idf	(1, 1)	3000	No	[3000, 1500]	0.2	0.7250	0.4414	0.5487
No	Tf-Idf	(1, 1)	3000	No	[3000, 1500]	0	0.7974	0.3861	0.5202
No	Tf-Idf	(1, 1)	3000	No	[3000, 1500, 1000]	0.2	0.7986	0.3871	0.5214
No	Tf-Idf	(1, 1)	3000	No	[3000, 1500, 1000]	0	0.7411	0.4485	0.5588
No	Tf-Idf	(1, 1)	3000	No	[4500, 1500]	0.2	0.7247	0.4434	0.5501
No	Tf-Idf	(1, 1)	3000	No	[4500, 1500]	0	0.7091	0.4650	0.5617
No	Tf-Idf	(1, 1)	3000	No	[5500, 2500, 1000]	0.2	0.7548	0.4065	0.5284
No	Tf-Idf	(1, 1)	3000	No	[5500, 2500, 1000]	0	0.7416	0.4313	0.5454
No	Tf-Idf	(1, 1)	3000	Sí	[3000]	0.2	0.6468	0.4290	0.5158
No	Tf-Idf	(1, 1)	3000	Sí	[3000]	0	0.7366	0.3190	0.4452
No	Tf-Idf	(1, 1)	3000	Sí	[3000, 1500]	0.2	0.7481	0.4085	0.5285
No	Tf-Idf	(1, 1)	3000	Sí	[3000, 1500]	0	0.7646	0.4082	0.5322
No	Tf-Idf	(1, 1)	3000	Sí	[3000, 1500, 1000]	0.2	0.8379	0.3345	0.4782
No	Tf-Idf	(1, 1)	3000	Sí	[3000, 1500, 1000]	0	0.7154	0.4549	0.5562
No	Tf-Idf	(1, 1)	3000	Sí	[4500, 1500]	0.2	0.8162	0.3205	0.4603
No	Tf-Idf	(1, 1)	3000	Sí	[4500, 1500]	0	0.7707	0.3968	0.5239
No	Tf-Idf	(1, 1)	3000	Sí	[5500, 2500, 1000]	0.2	0.8072	0.3610	0.4989
No	Tf-Idf	(1, 1)	3000	Sí	[5500, 2500, 1000]	0	0.8304	0.3250	0.4671

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Tf-Idf	(1, 2)	50	No	[50]	0.2	0.6111	0.0073	0.0144
No	Tf-Idf	(1, 2)	50	No	[50]	0	0.5872	0.0228	0.0439
No	Tf-Idf	(1, 2)	50	No	[50, 25]	0.2	0.6102	0.0119	0.0233
No	Tf-Idf	(1, 2)	50	No	[50, 25]	0	0.5879	0.0193	0.0374
No	Tf-Idf	(1, 2)	50	No	[50, 25, 16]	0.2	0.6923	0.0015	0.0030
No	Tf-Idf	(1, 2)	50	No	[50, 25, 16]	0	0.5908	0.0317	0.0602
No	Tf-Idf	(1, 2)	50	No	[75, 25]	0.2	0.6036	0.0168	0.0328
No	Tf-Idf	(1, 2)	50	No	[75, 25]	0	0.7407	0.0066	0.0131
No	Tf-Idf	(1, 2)	50	No	[91, 41, 16]	0.2	0.6312	0.0314	0.0598
No	Tf-Idf	(1, 2)	50	No	[91, 41, 16]	0	0.5723	0.0301	0.0571
No	Tf-Idf	(1, 2)	50	Sí	[50]	0.2	0.6412	0.0859	0.1514
No	Tf-Idf	(1, 2)	50	Sí	[50]	0	0.6556	0.0880	0.1552
No	Tf-Idf	(1, 2)	50	Sí	[50, 25]	0.2	0.6468	0.0862	0.1521
No	Tf-Idf	(1, 2)	50	Sí	[50, 25]	0	0.5771	0.1224	0.2019
No	Tf-Idf	(1, 2)	50	Sí	[50, 25, 16]	0.2	0.6375	0.0781	0.1392
No	Tf-Idf	(1, 2)	50	Sí	[50, 25, 16]	0	0.5835	0.1143	0.1911
No	Tf-Idf	(1, 2)	50	Sí	[75, 25]	0.2	0.6510	0.0755	0.1352
No	Tf-Idf	(1, 2)	50	Sí	[75, 25]	0	0.5990	0.1159	0.1942
No	Tf-Idf	(1, 2)	50	Sí	[91, 41, 16]	0.2	0.6732	0.0735	0.1325
No	Tf-Idf	(1, 2)	50	Sí	[91, 41, 16]	0	0.5743	0.1308	0.2130
No	Tf-Idf	(1, 2)	500	No	[500]	0.2	0.6233	0.2546	0.3615
No	Tf-Idf	(1, 2)	500	No	[500]	0	0.6475	0.2284	0.3376
No	Tf-Idf	(1, 2)	500	No	[500, 250]	0.2	0.6697	0.2280	0.3402
No	Tf-Idf	(1, 2)	500	No	[500, 250]	0	0.7091	0.2133	0.3280
No	Tf-Idf	(1, 2)	500	No	[500, 250, 166]	0.2	0.6810	0.2302	0.3441
No	Tf-Idf	(1, 2)	500	No	[500, 250, 166]	0	0.6425	0.2579	0.3681
No	Tf-Idf	(1, 2)	500	No	[750, 250]	0.2	0.6508	0.2302	0.3401
No	Tf-Idf	(1, 2)	500	No	[750, 250]	0	0.7028	0.2089	0.3220
No	Tf-Idf	(1, 2)	500	No	[916, 416, 166]	0.2	0.7210	0.2095	0.3247
No	Tf-Idf	(1, 2)	500	No	[916, 416, 166]	0	0.6752	0.2495	0.3644
No	Tf-Idf	(1, 2)	500	Sí	[500]	0.2	0.6546	0.2706	0.3829
No	Tf-Idf	(1, 2)	500	Sí	[500]	0	0.6297	0.3094	0.4150
No	Tf-Idf	(1, 2)	500	Sí	[500, 250]	0.2	0.6891	0.2774	0.3956
No	Tf-Idf	(1, 2)	500	Sí	[500, 250]	0	0.6835	0.2756	0.3928
No	Tf-Idf	(1, 2)	500	Sí	[500, 250, 166]	0.2	0.7266	0.2422	0.3633
No	Tf-Idf	(1, 2)	500	Sí	[500, 250, 166]	0	0.6763	0.2857	0.4017
No	Tf-Idf	(1, 2)	500	Sí	[750, 250]	0.2	0.7224	0.2561	0.3782
No	Tf-Idf	(1, 2)	500	Sí	[750, 250]	0	0.7297	0.2229	0.3415
No	Tf-Idf	(1, 2)	500	Sí	[916, 416, 166]	0.2	0.6724	0.2650	0.3802
No	Tf-Idf	(1, 2)	500	Sí	[916, 416, 166]	0	0.6601	0.2969	0.4096
No	Tf-Idf	(1, 2)	2000	No	[2000]	0.2	0.6458	0.3646	0.4661
No	Tf-Idf	(1, 2)	2000	No	[2000]	0	0.6467	0.3757	0.4752
No	Tf-Idf	(1, 2)	2000	No	[2000, 1000]	0.2	0.7731	0.3336	0.4660
No	Tf-Idf	(1, 2)	2000	No	[2000, 1000]	0	0.7157	0.3879	0.5031
No	Tf-Idf	(1, 2)	2000	No	[2000, 1000, 666]	0.2	0.7332	0.3676	0.4897
No	Tf-Idf	(1, 2)	2000	No	[2000, 1000, 666]	0	0.7007	0.4044	0.5128
No	Tf-Idf	(1, 2)	2000	No	[3000, 1000]	0.2	0.6911	0.4009	0.5075
No	Tf-Idf	(1, 2)	2000	No	[3000, 1000]	0	0.7186	0.3813	0.4982
No	Tf-Idf	(1, 2)	2000	No	[3666, 1666, 666]	0.2	0.7626	0.3156	0.4464
No	Tf-Idf	(1, 2)	2000	No	[3666, 1666, 666]	0	0.8202	0.2929	0.4317

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Tf-Idf	(1, 2)	2000	Sí	[2000]	0.2	0.5831	0.4434	0.5037
No	Tf-Idf	(1, 2)	2000	Sí	[2000]	0	0.7132	0.3289	0.4502
No	Tf-Idf	(1, 2)	2000	Sí	[2000, 1000]	0.2	0.8064	0.3136	0.4516
No	Tf-Idf	(1, 2)	2000	Sí	[2000, 1000]	0	0.7652	0.3407	0.4714
No	Tf-Idf	(1, 2)	2000	Sí	[2000, 1000, 666]	0.2	0.7466	0.3732	0.4976
No	Tf-Idf	(1, 2)	2000	Sí	[2000, 1000, 666]	0	0.7886	0.3350	0.4703
No	Tf-Idf	(1, 2)	2000	Sí	[3000, 1000]	0.2	0.7448	0.3331	0.4603
No	Tf-Idf	(1, 2)	2000	Sí	[3000, 1000]	0	0.7890	0.3210	0.4563
No	Tf-Idf	(1, 2)	2000	Sí	[3666, 1666, 666]	0.2	0.7754	0.3317	0.4647
No	Tf-Idf	(1, 2)	2000	Sí	[3666, 1666, 666]	0	0.8348	0.2971	0.4382
No	Tf-Idf	(1, 2)	3000	No	[3000]	0.2	0.5383	0.5147	0.5263
No	Tf-Idf	(1, 2)	3000	No	[3000]	0	0.6943	0.3705	0.4832
No	Tf-Idf	(1, 2)	3000	No	[3000, 1500]	0.2	0.7217	0.3875	0.5043
No	Tf-Idf	(1, 2)	3000	No	[3000, 1500]	0	0.7574	0.3928	0.5173
No	Tf-Idf	(1, 2)	3000	No	[3000, 1500, 1000]	0.2	0.7517	0.3913	0.5147
No	Tf-Idf	(1, 2)	3000	No	[3000, 1500, 1000]	0	0.7727	0.3918	0.5200
No	Tf-Idf	(1, 2)	3000	No	[4500, 1500]	0.2	0.7362	0.3862	0.5067
No	Tf-Idf	(1, 2)	3000	No	[4500, 1500]	0	0.7804	0.3674	0.4996
No	Tf-Idf	(1, 2)	3000	No	[5500, 2500, 1000]	0.2	0.7667	0.3750	0.5037
No	Tf-Idf	(1, 2)	3000	No	[5500, 2500, 1000]	0	0.7551	0.4062	0.5282
No	Tf-Idf	(1, 2)	3000	Sí	[3000]	0.2	0.5790	0.4586	0.5118
No	Tf-Idf	(1, 2)	3000	Sí	[3000]	0	0.6549	0.3748	0.4768
No	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500]	0.2	0.7564	0.3778	0.5039
No	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500]	0	0.6515	0.4792	0.5522
No	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.7299	0.4105	0.5255
No	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500, 1000]	0	0.7827	0.3861	0.5171
No	Tf-Idf	(1, 2)	3000	Sí	[4500, 1500]	0.2	0.8315	0.3326	0.4751
No	Tf-Idf	(1, 2)	3000	Sí	[4500, 1500]	0	0.6991	0.4171	0.5225
No	Tf-Idf	(1, 2)	3000	Sí	[5500, 2500, 1000]	0.2	0.8299	0.3294	0.4716
No	Tf-Idf	(1, 2)	3000	Sí	[5500, 2500, 1000]	0	0.7777	0.3946	0.5236
No	Tf-Idf	(2, 2)	50	No	[50]	0.2	0.4762	0.0083	0.0162
No	Tf-Idf	(2, 2)	50	No	[50]	0	0.5979	0.0096	0.0189
No	Tf-Idf	(2, 2)	50	No	[50, 25]	0.2	0.0000	0.0000	0.0000
No	Tf-Idf	(2, 2)	50	No	[50, 25]	0	0.5000	0.0005	0.0010
No	Tf-Idf	(2, 2)	50	No	[50, 25, 16]	0.2	0.0000	0.0000	0.0000
No	Tf-Idf	(2, 2)	50	No	[50, 25, 16]	0	0.5319	0.0041	0.0082
No	Tf-Idf	(2, 2)	50	No	[75, 25]	0.2	0.6667	0.0030	0.0059
No	Tf-Idf	(2, 2)	50	No	[75, 25]	0	0.4734	0.0147	0.0285
No	Tf-Idf	(2, 2)	50	No	[91, 41, 16]	0.2	0.0000	0.0000	0.0000
No	Tf-Idf	(2, 2)	50	No	[91, 41, 16]	0	0.5721	0.0196	0.0380
No	Tf-Idf	(2, 2)	50	Sí	[50]	0.2	0.6019	0.0312	0.0593
No	Tf-Idf	(2, 2)	50	Sí	[50]	0	0.6280	0.0215	0.0415
No	Tf-Idf	(2, 2)	50	Sí	[50, 25]	0.2	0.4925	0.0162	0.0313
No	Tf-Idf	(2, 2)	50	Sí	[50, 25]	0	0.5976	0.0162	0.0315
No	Tf-Idf	(2, 2)	50	Sí	[50, 25, 16]	0.2	0.6957	0.0106	0.0208
No	Tf-Idf	(2, 2)	50	Sí	[50, 25, 16]	0	0.8333	0.0008	0.0016
No	Tf-Idf	(2, 2)	50	Sí	[75, 25]	0.2	0.5391	0.0330	0.0622
No	Tf-Idf	(2, 2)	50	Sí	[75, 25]	0	0.5957	0.0231	0.0445
No	Tf-Idf	(2, 2)	50	Sí	[91, 41, 16]	0.2	0.6729	0.0119	0.0234
No	Tf-Idf	(2, 2)	50	Sí	[91, 41, 16]	0	0.5445	0.0343	0.0646

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Tf-Idf	(2, 2)	500	No	[500]	0.2	0.5689	0.1460	0.2323
No	Tf-Idf	(2, 2)	500	No	[500]	0	0.5713	0.1428	0.2285
No	Tf-Idf	(2, 2)	500	No	[500, 250]	0.2	0.6810	0.0941	0.1654
No	Tf-Idf	(2, 2)	500	No	[500, 250]	0	0.6249	0.1078	0.1839
No	Tf-Idf	(2, 2)	500	No	[500, 250, 166]	0.2	0.6538	0.0982	0.1708
No	Tf-Idf	(2, 2)	500	No	[500, 250, 166]	0	0.6690	0.0941	0.1650
No	Tf-Idf	(2, 2)	500	No	[750, 250]	0.2	0.6392	0.1267	0.2114
No	Tf-Idf	(2, 2)	500	No	[750, 250]	0	0.6648	0.1202	0.2036
No	Tf-Idf	(2, 2)	500	No	[916, 416, 166]	0.2	0.6434	0.1141	0.1938
No	Tf-Idf	(2, 2)	500	No	[916, 416, 166]	0	0.6488	0.0940	0.1641
No	Tf-Idf	(2, 2)	500	Sí	[500]	0.2	0.7381	0.0945	0.1675
No	Tf-Idf	(2, 2)	500	Sí	[500]	0	0.5713	0.1362	0.2200
No	Tf-Idf	(2, 2)	500	Sí	[500, 250]	0.2	0.8016	0.0840	0.1521
No	Tf-Idf	(2, 2)	500	Sí	[500, 250]	0	0.7457	0.1002	0.1767
No	Tf-Idf	(2, 2)	500	Sí	[500, 250, 166]	0.2	0.7158	0.1148	0.1978
No	Tf-Idf	(2, 2)	500	Sí	[500, 250, 166]	0	0.6938	0.1126	0.1938
No	Tf-Idf	(2, 2)	500	Sí	[750, 250]	0.2	0.6835	0.1052	0.1823
No	Tf-Idf	(2, 2)	500	Sí	[750, 250]	0	0.7512	0.1002	0.1769
No	Tf-Idf	(2, 2)	500	Sí	[916, 416, 166]	0.2	0.7087	0.1141	0.1966
No	Tf-Idf	(2, 2)	500	Sí	[916, 416, 166]	0	0.7100	0.1055	0.1837
No	Tf-Idf	(2, 2)	2000	No	[2000]	0.2	0.5316	0.2596	0.3488
No	Tf-Idf	(2, 2)	2000	No	[2000]	0	0.5023	0.2716	0.3526
No	Tf-Idf	(2, 2)	2000	No	[2000, 1000]	0.2	0.8150	0.1484	0.2512
No	Tf-Idf	(2, 2)	2000	No	[2000, 1000]	0	0.7075	0.2173	0.3325
No	Tf-Idf	(2, 2)	2000	No	[2000, 1000, 666]	0.2	0.7345	0.1996	0.3139
No	Tf-Idf	(2, 2)	2000	No	[2000, 1000, 666]	0	0.6908	0.2272	0.3419
No	Tf-Idf	(2, 2)	2000	No	[3000, 1000]	0.2	0.8032	0.1476	0.2494
No	Tf-Idf	(2, 2)	2000	No	[3000, 1000]	0	0.7509	0.2061	0.3234
No	Tf-Idf	(2, 2)	2000	No	[3666, 1666, 666]	0.2	0.7173	0.1848	0.2939
No	Tf-Idf	(2, 2)	2000	No	[3666, 1666, 666]	0	0.7506	0.2023	0.3187
No	Tf-Idf	(2, 2)	2000	Sí	[2000]	0.2	0.6295	0.1866	0.2879
No	Tf-Idf	(2, 2)	2000	Sí	[2000]	0	0.5361	0.2379	0.3296
No	Tf-Idf	(2, 2)	2000	Sí	[2000, 1000]	0.2	0.7041	0.1835	0.2911
No	Tf-Idf	(2, 2)	2000	Sí	[2000, 1000]	0	0.7837	0.1729	0.2833
No	Tf-Idf	(2, 2)	2000	Sí	[2000, 1000, 666]	0.2	0.7538	0.1825	0.2938
No	Tf-Idf	(2, 2)	2000	Sí	[2000, 1000, 666]	0	0.7771	0.1785	0.2903
No	Tf-Idf	(2, 2)	2000	Sí	[3000, 1000]	0.2	0.8512	0.1191	0.2089
No	Tf-Idf	(2, 2)	2000	Sí	[3000, 1000]	0	0.7926	0.1653	0.2735
No	Tf-Idf	(2, 2)	2000	Sí	[3666, 1666, 666]	0.2	0.7859	0.1679	0.2767
No	Tf-Idf	(2, 2)	2000	Sí	[3666, 1666, 666]	0	0.8013	0.1612	0.2684
No	Tf-Idf	(2, 2)	3000	No	[3000]	0.2	0.4627	0.3606	0.4053
No	Tf-Idf	(2, 2)	3000	No	[3000]	0	0.4753	0.3088	0.3744
No	Tf-Idf	(2, 2)	3000	No	[3000, 1500]	0.2	0.7192	0.2262	0.3442
No	Tf-Idf	(2, 2)	3000	No	[3000, 1500]	0	0.7234	0.2203	0.3377
No	Tf-Idf	(2, 2)	3000	No	[3000, 1500, 1000]	0.2	0.7174	0.2356	0.3548
No	Tf-Idf	(2, 2)	3000	No	[3000, 1500, 1000]	0	0.7229	0.2447	0.3657
No	Tf-Idf	(2, 2)	3000	No	[4500, 1500]	0.2	0.7627	0.1937	0.3089
No	Tf-Idf	(2, 2)	3000	No	[4500, 1500]	0	0.8159	0.1420	0.2419
No	Tf-Idf	(2, 2)	3000	No	[5500, 2500, 1000]	0.2	0.7224	0.2226	0.3403
No	Tf-Idf	(2, 2)	3000	No	[5500, 2500, 1000]	0	0.7622	0.2016	0.3189

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Tf-Idf	(2, 2)	3000	Sí	[3000]	0.2	0.5569	0.2596	0.3541
No	Tf-Idf	(2, 2)	3000	Sí	[3000]	0	0.5896	0.2206	0.3211
No	Tf-Idf	(2, 2)	3000	Sí	[3000, 1500]	0.2	0.7668	0.1813	0.2933
No	Tf-Idf	(2, 2)	3000	Sí	[3000, 1500]	0	0.7256	0.2100	0.3258
No	Tf-Idf	(2, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.8043	0.1554	0.2604
No	Tf-Idf	(2, 2)	3000	Sí	[3000, 1500, 1000]	0	0.7915	0.1868	0.3022
No	Tf-Idf	(2, 2)	3000	Sí	[4500, 1500]	0.2	0.8141	0.1663	0.2762
No	Tf-Idf	(2, 2)	3000	Sí	[4500, 1500]	0	0.7434	0.2033	0.3192
No	Tf-Idf	(2, 2)	3000	Sí	[5500, 2500, 1000]	0.2	0.7854	0.1674	0.2760
No	Tf-Idf	(2, 2)	3000	Sí	[5500, 2500, 1000]	0	0.7746	0.1833	0.2964
No	Frec.	(1, 1)	50	No	[50]	0.2	0.5838	0.0535	0.0980
No	Frec.	(1, 1)	50	No	[50]	0	0.5353	0.0614	0.1102
No	Frec.	(1, 1)	50	No	[50, 25]	0.2	0.6471	0.0381	0.0720
No	Frec.	(1, 1)	50	No	[50, 25]	0	0.5427	0.0588	0.1061
No	Frec.	(1, 1)	50	No	[50, 25, 16]	0.2	0.6235	0.0175	0.0341
No	Frec.	(1, 1)	50	No	[50, 25, 16]	0	0.5852	0.0510	0.0939
No	Frec.	(1, 1)	50	No	[75, 25]	0.2	0.6506	0.0289	0.0553
No	Frec.	(1, 1)	50	No	[75, 25]	0	0.5963	0.0527	0.0968
No	Frec.	(1, 1)	50	No	[91, 41, 16]	0.2	0.6163	0.0538	0.0990
No	Frec.	(1, 1)	50	No	[91, 41, 16]	0	0.5695	0.0616	0.1112
No	Frec.	(1, 1)	50	Sí	[50]	0.2	0.6485	0.0826	0.1465
No	Frec.	(1, 1)	50	Sí	[50]	0	0.6510	0.0986	0.1712
No	Frec.	(1, 1)	50	Sí	[50, 25]	0.2	0.5981	0.1359	0.2215
No	Frec.	(1, 1)	50	Sí	[50, 25]	0	0.6162	0.1270	0.2106
No	Frec.	(1, 1)	50	Sí	[50, 25, 16]	0.2	0.7033	0.0497	0.0928
No	Frec.	(1, 1)	50	Sí	[50, 25, 16]	0	0.6250	0.1181	0.1986
No	Frec.	(1, 1)	50	Sí	[75, 25]	0.2	0.6543	0.0672	0.1219
No	Frec.	(1, 1)	50	Sí	[75, 25]	0	0.6429	0.1103	0.1883
No	Frec.	(1, 1)	50	Sí	[91, 41, 16]	0.2	0.6628	0.0760	0.1363
No	Frec.	(1, 1)	50	Sí	[91, 41, 16]	0	0.6537	0.1078	0.1851
No	Frec.	(1, 1)	500	No	[500]	0.2	0.6484	0.3210	0.4294
No	Frec.	(1, 1)	500	No	[500]	0	0.6176	0.3747	0.4664
No	Frec.	(1, 1)	500	No	[500, 250]	0.2	0.7354	0.2763	0.4016
No	Frec.	(1, 1)	500	No	[500, 250]	0	0.7576	0.2312	0.3543
No	Frec.	(1, 1)	500	No	[500, 250, 166]	0.2	0.7495	0.2535	0.3788
No	Frec.	(1, 1)	500	No	[500, 250, 166]	0	0.7327	0.2761	0.4011
No	Frec.	(1, 1)	500	No	[750, 250]	0.2	0.7622	0.2313	0.3550
No	Frec.	(1, 1)	500	No	[750, 250]	0	0.7313	0.2517	0.3744
No	Frec.	(1, 1)	500	No	[916, 416, 166]	0.2	0.7576	0.2523	0.3785
No	Frec.	(1, 1)	500	No	[916, 416, 166]	0	0.6943	0.3260	0.4436
No	Frec.	(1, 1)	500	Sí	[500]	0.2	0.7147	0.2569	0.3780
No	Frec.	(1, 1)	500	Sí	[500]	0	0.7083	0.2490	0.3685
No	Frec.	(1, 1)	500	Sí	[500, 250]	0.2	0.7447	0.2437	0.3673
No	Frec.	(1, 1)	500	Sí	[500, 250]	0	0.7180	0.2548	0.3761
No	Frec.	(1, 1)	500	Sí	[500, 250, 166]	0.2	0.7137	0.2688	0.3905
No	Frec.	(1, 1)	500	Sí	[500, 250, 166]	0	0.7298	0.2381	0.3591
No	Frec.	(1, 1)	500	Sí	[750, 250]	0.2	0.7487	0.2346	0.3573
No	Frec.	(1, 1)	500	Sí	[750, 250]	0	0.7063	0.2637	0.3840
No	Frec.	(1, 1)	500	Sí	[916, 416, 166]	0.2	0.7453	0.2242	0.3448
No	Frec.	(1, 1)	500	Sí	[916, 416, 166]	0	0.7026	0.2688	0.3889

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Frec.	(1, 1)	2000	No	[2000]	0.2	0.7521	0.3767	0.5019
No	Frec.	(1, 1)	2000	No	[2000]	0	0.7142	0.4031	0.5153
No	Frec.	(1, 1)	2000	No	[2000, 1000]	0.2	0.8525	0.3187	0.4639
No	Frec.	(1, 1)	2000	No	[2000, 1000]	0	0.7591	0.4008	0.5246
No	Frec.	(1, 1)	2000	No	[2000, 1000, 666]	0.2	0.8364	0.3377	0.4811
No	Frec.	(1, 1)	2000	No	[2000, 1000, 666]	0	0.8089	0.3606	0.4989
No	Frec.	(1, 1)	2000	No	[3000, 1000]	0.2	0.8191	0.3395	0.4800
No	Frec.	(1, 1)	2000	No	[3000, 1000]	0	0.7526	0.4098	0.5307
No	Frec.	(1, 1)	2000	No	[3666, 1666, 666]	0.2	0.7425	0.4176	0.5346
No	Frec.	(1, 1)	2000	No	[3666, 1666, 666]	0	0.7859	0.3838	0.5157
No	Frec.	(1, 1)	2000	Sí	[2000]	0.2	0.6617	0.4193	0.5133
No	Frec.	(1, 1)	2000	Sí	[2000]	0	0.6896	0.3885	0.4970
No	Frec.	(1, 1)	2000	Sí	[2000, 1000]	0.2	0.7836	0.3468	0.4808
No	Frec.	(1, 1)	2000	Sí	[2000, 1000]	0	0.8191	0.3253	0.4657
No	Frec.	(1, 1)	2000	Sí	[2000, 1000, 666]	0.2	0.7245	0.4156	0.5282
No	Frec.	(1, 1)	2000	Sí	[2000, 1000, 666]	0	0.7593	0.3672	0.4950
No	Frec.	(1, 1)	2000	Sí	[3000, 1000]	0.2	0.7599	0.3763	0.5034
No	Frec.	(1, 1)	2000	Sí	[3000, 1000]	0	0.6846	0.4369	0.5334
No	Frec.	(1, 1)	2000	Sí	[3666, 1666, 666]	0.2	0.8443	0.3098	0.4532
No	Frec.	(1, 1)	2000	Sí	[3666, 1666, 666]	0	0.7627	0.3730	0.5010
No	Frec.	(1, 1)	3000	No	[3000]	0.2	0.6751	0.4415	0.5339
No	Frec.	(1, 1)	3000	No	[3000]	0	0.7213	0.4090	0.5220
No	Frec.	(1, 1)	3000	No	[3000, 1500]	0.2	0.8058	0.3980	0.5328
No	Frec.	(1, 1)	3000	No	[3000, 1500]	0	0.7862	0.4148	0.5431
No	Frec.	(1, 1)	3000	No	[3000, 1500, 1000]	0.2	0.8467	0.3438	0.4890
No	Frec.	(1, 1)	3000	No	[3000, 1500, 1000]	0	0.7609	0.4562	0.5705
No	Frec.	(1, 1)	3000	No	[4500, 1500]	0.2	0.6805	0.4987	0.5756
No	Frec.	(1, 1)	3000	No	[4500, 1500]	0	0.7796	0.4252	0.5503
No	Frec.	(1, 1)	3000	No	[5500, 2500, 1000]	0.2	0.7915	0.4105	0.5406
No	Frec.	(1, 1)	3000	No	[5500, 2500, 1000]	0	0.7301	0.4744	0.5751
No	Frec.	(1, 1)	3000	Sí	[3000]	0.2	0.5562	0.4767	0.5134
No	Frec.	(1, 1)	3000	Sí	[3000]	0	0.6975	0.4178	0.5226
No	Frec.	(1, 1)	3000	Sí	[3000, 1500]	0.2	0.7730	0.3993	0.5266
No	Frec.	(1, 1)	3000	Sí	[3000, 1500]	0	0.8309	0.3554	0.4978
No	Frec.	(1, 1)	3000	Sí	[3000, 1500, 1000]	0.2	0.7723	0.4026	0.5293
No	Frec.	(1, 1)	3000	Sí	[3000, 1500, 1000]	0	0.7553	0.4323	0.5499
No	Frec.	(1, 1)	3000	Sí	[4500, 1500]	0.2	0.8388	0.3506	0.4945
No	Frec.	(1, 1)	3000	Sí	[4500, 1500]	0	0.8389	0.3405	0.4844
No	Frec.	(1, 1)	3000	Sí	[5500, 2500, 1000]	0.2	0.8208	0.3397	0.4805
No	Frec.	(1, 1)	3000	Sí	[5500, 2500, 1000]	0	0.7196	0.4404	0.5464
No	Frec.	(1, 2)	50	No	[50]	0.2	0.5721	0.0216	0.0417
No	Frec.	(1, 2)	50	No	[50]	0	0.5083	0.0454	0.0834
No	Frec.	(1, 2)	50	No	[50, 25]	0.2	0.5695	0.0284	0.0541
No	Frec.	(1, 2)	50	No	[50, 25]	0	0.5740	0.0474	0.0876
No	Frec.	(1, 2)	50	No	[50, 25, 16]	0.2	0.5075	0.0056	0.0111
No	Frec.	(1, 2)	50	No	[50, 25, 16]	0	0.5283	0.0139	0.0270
No	Frec.	(1, 2)	50	No	[75, 25]	0.2	0.5274	0.0206	0.0397
No	Frec.	(1, 2)	50	No	[75, 25]	0	0.5078	0.0431	0.0795
No	Frec.	(1, 2)	50	No	[91, 41, 16]	0.2	0.5876	0.0094	0.0185
No	Frec.	(1, 2)	50	No	[91, 41, 16]	0	0.5000	0.0059	0.0117

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Frec.	(1, 2)	50	Sí	[50]	0.2	0.6490	0.0888	0.1563
No	Frec.	(1, 2)	50	Sí	[50]	0	0.6539	0.0845	0.1497
No	Frec.	(1, 2)	50	Sí	[50, 25]	0.2	0.6454	0.0883	0.1554
No	Frec.	(1, 2)	50	Sí	[50, 25]	0	0.5977	0.1111	0.1874
No	Frec.	(1, 2)	50	Sí	[50, 25, 16]	0.2	0.6707	0.0646	0.1178
No	Frec.	(1, 2)	50	Sí	[50, 25, 16]	0	0.6123	0.1004	0.1725
No	Frec.	(1, 2)	50	Sí	[75, 25]	0.2	0.6542	0.0753	0.1351
No	Frec.	(1, 2)	50	Sí	[75, 25]	0	0.6101	0.1034	0.1768
No	Frec.	(1, 2)	50	Sí	[91, 41, 16]	0.2	0.5793	0.1267	0.2079
No	Frec.	(1, 2)	50	Sí	[91, 41, 16]	0	0.5861	0.1186	0.1972
No	Frec.	(1, 2)	500	No	[500]	0.2	0.6301	0.2715	0.3795
No	Frec.	(1, 2)	500	No	[500]	0	0.6720	0.2358	0.3491
No	Frec.	(1, 2)	500	No	[500, 250]	0.2	0.6842	0.2340	0.3487
No	Frec.	(1, 2)	500	No	[500, 250]	0	0.7659	0.1534	0.2556
No	Frec.	(1, 2)	500	No	[500, 250, 166]	0.2	0.6793	0.2421	0.3570
No	Frec.	(1, 2)	500	No	[500, 250, 166]	0	0.7030	0.2122	0.3260
No	Frec.	(1, 2)	500	No	[750, 250]	0.2	0.6955	0.2308	0.3466
No	Frec.	(1, 2)	500	No	[750, 250]	0	0.6632	0.2611	0.3746
No	Frec.	(1, 2)	500	No	[916, 416, 166]	0.2	0.6754	0.2375	0.3514
No	Frec.	(1, 2)	500	No	[916, 416, 166]	0	0.6814	0.2422	0.3574
No	Frec.	(1, 2)	500	Sí	[500]	0.2	0.7335	0.2272	0.3469
No	Frec.	(1, 2)	500	Sí	[500]	0	0.7645	0.2064	0.3251
No	Frec.	(1, 2)	500	Sí	[500, 250]	0.2	0.7306	0.2190	0.3369
No	Frec.	(1, 2)	500	Sí	[500, 250]	0	0.7240	0.2564	0.3787
No	Frec.	(1, 2)	500	Sí	[500, 250, 166]	0.2	0.7175	0.2449	0.3651
No	Frec.	(1, 2)	500	Sí	[500, 250, 166]	0	0.7939	0.1876	0.3035
No	Frec.	(1, 2)	500	Sí	[750, 250]	0.2	0.7731	0.2132	0.3342
No	Frec.	(1, 2)	500	Sí	[750, 250]	0	0.7743	0.1972	0.3143
No	Frec.	(1, 2)	500	Sí	[916, 416, 166]	0.2	0.7749	0.2155	0.3372
No	Frec.	(1, 2)	500	Sí	[916, 416, 166]	0	0.6941	0.2896	0.4087
No	Frec.	(1, 2)	2000	No	[2000]	0.2	0.7032	0.3620	0.4779
No	Frec.	(1, 2)	2000	No	[2000]	0	0.6272	0.4353	0.5139
No	Frec.	(1, 2)	2000	No	[2000, 1000]	0.2	0.7496	0.3469	0.4743
No	Frec.	(1, 2)	2000	No	[2000, 1000]	0	0.7151	0.3966	0.5102
No	Frec.	(1, 2)	2000	No	[2000, 1000, 666]	0.2	0.7499	0.3709	0.4963
No	Frec.	(1, 2)	2000	No	[2000, 1000, 666]	0	0.7823	0.3395	0.4735
No	Frec.	(1, 2)	2000	No	[3000, 1000]	0.2	0.8189	0.2881	0.4263
No	Frec.	(1, 2)	2000	No	[3000, 1000]	0	0.7498	0.3780	0.5026
No	Frec.	(1, 2)	2000	No	[3666, 1666, 666]	0.2	0.7215	0.3846	0.5017
No	Frec.	(1, 2)	2000	No	[3666, 1666, 666]	0	0.7870	0.3367	0.4716
No	Frec.	(1, 2)	2000	Sí	[2000]	0.2	0.6883	0.3818	0.4911
No	Frec.	(1, 2)	2000	Sí	[2000]	0	0.7160	0.3596	0.4788
No	Frec.	(1, 2)	2000	Sí	[2000, 1000]	0.2	0.7283	0.3801	0.4995
No	Frec.	(1, 2)	2000	Sí	[2000, 1000]	0	0.7823	0.3347	0.4688
No	Frec.	(1, 2)	2000	Sí	[2000, 1000, 666]	0.2	0.7470	0.3710	0.4958
No	Frec.	(1, 2)	2000	Sí	[2000, 1000, 666]	0	0.7887	0.3557	0.4903
No	Frec.	(1, 2)	2000	Sí	[3000, 1000]	0.2	0.8046	0.3012	0.4383
No	Frec.	(1, 2)	2000	Sí	[3000, 1000]	0	0.7400	0.3788	0.5011
No	Frec.	(1, 2)	2000	Sí	[3666, 1666, 666]	0.2	0.7023	0.3915	0.5028
No	Frec.	(1, 2)	2000	Sí	[3666, 1666, 666]	0	0.7607	0.3654	0.4937

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Frec.	(1, 2)	3000	No	[3000]	0.2	0.6697	0.3951	0.4970
No	Frec.	(1, 2)	3000	No	[3000]	0	0.5958	0.4746	0.5283
No	Frec.	(1, 2)	3000	No	[3000, 1500]	0.2	0.7770	0.3842	0.5142
No	Frec.	(1, 2)	3000	No	[3000, 1500]	0	0.7593	0.3953	0.5199
No	Frec.	(1, 2)	3000	No	[3000, 1500, 1000]	0.2	0.8103	0.3435	0.4824
No	Frec.	(1, 2)	3000	No	[3000, 1500, 1000]	0	0.7708	0.3649	0.4953
No	Frec.	(1, 2)	3000	No	[4500, 1500]	0.2	0.7776	0.3557	0.4881
No	Frec.	(1, 2)	3000	No	[4500, 1500]	0	0.6940	0.4419	0.5400
No	Frec.	(1, 2)	3000	No	[5500, 2500, 1000]	0.2	0.8506	0.2680	0.4076
No	Frec.	(1, 2)	3000	No	[5500, 2500, 1000]	0	0.7797	0.3687	0.5007
No	Frec.	(1, 2)	3000	Sí	[3000]	0.2	0.6734	0.4161	0.5144
No	Frec.	(1, 2)	3000	Sí	[3000]	0	0.5629	0.4881	0.5229
No	Frec.	(1, 2)	3000	Sí	[3000, 1500]	0.2	0.7478	0.4231	0.5404
No	Frec.	(1, 2)	3000	Sí	[3000, 1500]	0	0.8394	0.3340	0.4779
No	Frec.	(1, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.7960	0.3570	0.4929
No	Frec.	(1, 2)	3000	Sí	[3000, 1500, 1000]	0	0.8160	0.3435	0.4834
No	Frec.	(1, 2)	3000	Sí	[4500, 1500]	0.2	0.8106	0.3506	0.4895
No	Frec.	(1, 2)	3000	Sí	[4500, 1500]	0	0.8246	0.3377	0.4791
No	Frec.	(1, 2)	3000	Sí	[5500, 2500, 1000]	0.2	0.7944	0.3778	0.5121
No	Frec.	(1, 2)	3000	Sí	[5500, 2500, 1000]	0	0.7342	0.4356	0.5468
No	Frec.	(2, 2)	50	No	[50]	0.2	0.5385	0.0069	0.0137
No	Frec.	(2, 2)	50	No	[50]	0	0.4872	0.0188	0.0362
No	Frec.	(2, 2)	50	No	[50, 25]	0.2	0.5846	0.0063	0.0124
No	Frec.	(2, 2)	50	No	[50, 25]	0	0.5915	0.0069	0.0137
No	Frec.	(2, 2)	50	No	[50, 25, 16]	0.2	0.5417	0.0043	0.0085
No	Frec.	(2, 2)	50	No	[50, 25, 16]	0	0.5000	0.0109	0.0213
No	Frec.	(2, 2)	50	No	[75, 25]	0.2	0.5690	0.0054	0.0108
No	Frec.	(2, 2)	50	No	[75, 25]	0	0.6277	0.0097	0.0192
No	Frec.	(2, 2)	50	No	[91, 41, 16]	0.2	0.5806	0.0089	0.0176
No	Frec.	(2, 2)	50	No	[91, 41, 16]	0	0.5130	0.0228	0.0436
No	Frec.	(2, 2)	50	Sí	[50]	0.2	0.5799	0.0353	0.0666
No	Frec.	(2, 2)	50	Sí	[50]	0	0.5730	0.0350	0.0660
No	Frec.	(2, 2)	50	Sí	[50, 25]	0.2	0.6636	0.0121	0.0237
No	Frec.	(2, 2)	50	Sí	[50, 25]	0	0.5735	0.0329	0.0622
No	Frec.	(2, 2)	50	Sí	[50, 25, 16]	0.2	0.6727	0.0122	0.0240
No	Frec.	(2, 2)	50	Sí	[50, 25, 16]	0	0.7041	0.0114	0.0224
No	Frec.	(2, 2)	50	Sí	[75, 25]	0.2	0.6433	0.0182	0.0353
No	Frec.	(2, 2)	50	Sí	[75, 25]	0	0.5051	0.0330	0.0620
No	Frec.	(2, 2)	50	Sí	[91, 41, 16]	0.2	0.6727	0.0122	0.0240
No	Frec.	(2, 2)	50	Sí	[91, 41, 16]	0	0.6842	0.0129	0.0253
No	Frec.	(2, 2)	500	No	[500]	0.2	0.5679	0.1319	0.2141
No	Frec.	(2, 2)	500	No	[500]	0	0.5768	0.1233	0.2032
No	Frec.	(2, 2)	500	No	[500, 250]	0.2	0.6267	0.1450	0.2355
No	Frec.	(2, 2)	500	No	[500, 250]	0	0.6808	0.1138	0.1950
No	Frec.	(2, 2)	500	No	[500, 250, 166]	0.2	0.6469	0.1189	0.2009
No	Frec.	(2, 2)	500	No	[500, 250, 166]	0	0.5912	0.1584	0.2498
No	Frec.	(2, 2)	500	No	[750, 250]	0.2	0.6901	0.1055	0.1830
No	Frec.	(2, 2)	500	No	[750, 250]	0	0.7158	0.0890	0.1583
No	Frec.	(2, 2)	500	No	[916, 416, 166]	0.2	0.7098	0.0933	0.1649
No	Frec.	(2, 2)	500	No	[916, 416, 166]	0	0.6639	0.1044	0.1804

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
No	Frec.	(2, 2)	500	Sí	[500]	0.2	0.6405	0.1186	0.2001
No	Frec.	(2, 2)	500	Sí	[500]	0	0.6915	0.1225	0.2082
No	Frec.	(2, 2)	500	Sí	[500, 250]	0.2	0.7811	0.0913	0.1635
No	Frec.	(2, 2)	500	Sí	[500, 250]	0	0.7063	0.1120	0.1933
No	Frec.	(2, 2)	500	Sí	[500, 250, 166]	0.2	0.6836	0.1270	0.2142
No	Frec.	(2, 2)	500	Sí	[500, 250, 166]	0	0.6785	0.1230	0.2083
No	Frec.	(2, 2)	500	Sí	[750, 250]	0.2	0.7491	0.1030	0.1812
No	Frec.	(2, 2)	500	Sí	[750, 250]	0	0.7519	0.0961	0.1704
No	Frec.	(2, 2)	500	Sí	[916, 416, 166]	0.2	0.7128	0.1106	0.1915
No	Frec.	(2, 2)	500	Sí	[916, 416, 166]	0	0.6859	0.1078	0.1864
No	Frec.	(2, 2)	2000	No	[2000]	0.2	0.5625	0.2543	0.3502
No	Frec.	(2, 2)	2000	No	[2000]	0	0.6031	0.2545	0.3579
No	Frec.	(2, 2)	2000	No	[2000, 1000]	0.2	0.6638	0.2589	0.3725
No	Frec.	(2, 2)	2000	No	[2000, 1000]	0	0.7313	0.2185	0.3364
No	Frec.	(2, 2)	2000	No	[2000, 1000, 666]	0.2	0.7426	0.2024	0.3182
No	Frec.	(2, 2)	2000	No	[2000, 1000, 666]	0	0.7116	0.2294	0.3469
No	Frec.	(2, 2)	2000	No	[3000, 1000]	0.2	0.7177	0.2191	0.3357
No	Frec.	(2, 2)	2000	No	[3000, 1000]	0	0.7343	0.2031	0.3182
No	Frec.	(2, 2)	2000	No	[3666, 1666, 666]	0.2	0.7545	0.2029	0.3198
No	Frec.	(2, 2)	2000	No	[3666, 1666, 666]	0	0.7504	0.1633	0.2682
No	Frec.	(2, 2)	2000	Sí	[2000]	0.2	0.6206	0.2023	0.3051
No	Frec.	(2, 2)	2000	Sí	[2000]	0	0.6304	0.1744	0.2732
No	Frec.	(2, 2)	2000	Sí	[2000, 1000]	0.2	0.7970	0.1640	0.2720
No	Frec.	(2, 2)	2000	Sí	[2000, 1000]	0	0.7324	0.1993	0.3133
No	Frec.	(2, 2)	2000	Sí	[2000, 1000, 666]	0.2	0.8369	0.1602	0.2689
No	Frec.	(2, 2)	2000	Sí	[2000, 1000, 666]	0	0.8100	0.1711	0.2825
No	Frec.	(2, 2)	2000	Sí	[3000, 1000]	0.2	0.7609	0.1876	0.3010
No	Frec.	(2, 2)	2000	Sí	[3000, 1000]	0	0.7350	0.1805	0.2898
No	Frec.	(2, 2)	2000	Sí	[3666, 1666, 666]	0.2	0.8456	0.1420	0.2432
No	Frec.	(2, 2)	2000	Sí	[3666, 1666, 666]	0	0.8094	0.1641	0.2729
No	Frec.	(2, 2)	3000	No	[3000]	0.2	0.5542	0.3180	0.4042
No	Frec.	(2, 2)	3000	No	[3000]	0	0.6116	0.2163	0.3196
No	Frec.	(2, 2)	3000	No	[3000, 1500]	0.2	0.6951	0.2597	0.3782
No	Frec.	(2, 2)	3000	No	[3000, 1500]	0	0.7497	0.2345	0.3572
No	Frec.	(2, 2)	3000	No	[3000, 1500, 1000]	0.2	0.8507	0.1628	0.2733
No	Frec.	(2, 2)	3000	No	[3000, 1500, 1000]	0	0.6685	0.2863	0.4009
No	Frec.	(2, 2)	3000	No	[4500, 1500]	0.2	0.7222	0.2469	0.3680
No	Frec.	(2, 2)	3000	No	[4500, 1500]	0	0.7663	0.2193	0.3410
No	Frec.	(2, 2)	3000	No	[5500, 2500, 1000]	0.2	0.7382	0.2188	0.3375
No	Frec.	(2, 2)	3000	No	[5500, 2500, 1000]	0	0.7343	0.2474	0.3701
No	Frec.	(2, 2)	3000	Sí	[3000]	0.2	0.5745	0.2465	0.3450
No	Frec.	(2, 2)	3000	Sí	[3000]	0	0.5256	0.2592	0.3472
No	Frec.	(2, 2)	3000	Sí	[3000, 1500]	0.2	0.7353	0.2059	0.3217
No	Frec.	(2, 2)	3000	Sí	[3000, 1500]	0	0.7444	0.2155	0.3342
No	Frec.	(2, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.8537	0.1590	0.2681
No	Frec.	(2, 2)	3000	Sí	[3000, 1500, 1000]	0	0.7065	0.2285	0.3454
No	Frec.	(2, 2)	3000	Sí	[4500, 1500]	0.2	0.7561	0.1950	0.3101
No	Frec.	(2, 2)	3000	Sí	[4500, 1500]	0	0.7605	0.1977	0.3138
No	Frec.	(2, 2)	3000	Sí	[5500, 2500, 1000]	0.2	0.7429	0.2076	0.3245
No	Frec.	(2, 2)	3000	Sí	[5500, 2500, 1000]	0	0.7565	0.1924	0.3067

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Tf-Idf	(1, 1)	50	No	[50]	0.2	0.6142	0.5918	0.6028
Down	Tf-Idf	(1, 1)	50	No	[50]	0	0.6135	0.5824	0.5976
Down	Tf-Idf	(1, 1)	50	No	[50, 25]	0.2	0.6276	0.5639	0.5940
Down	Tf-Idf	(1, 1)	50	No	[50, 25]	0	0.6147	0.5991	0.6068
Down	Tf-Idf	(1, 1)	50	No	[50, 25, 16]	0.2	0.6284	0.5420	0.5820
Down	Tf-Idf	(1, 1)	50	No	[50, 25, 16]	0	0.5994	0.6401	0.6191
Down	Tf-Idf	(1, 1)	50	No	[75, 25]	0.2	0.6212	0.5534	0.5853
Down	Tf-Idf	(1, 1)	50	No	[75, 25]	0	0.6043	0.6156	0.6099
Down	Tf-Idf	(1, 1)	50	No	[91, 41, 16]	0.2	0.6259	0.5684	0.5957
Down	Tf-Idf	(1, 1)	50	No	[91, 41, 16]	0	0.6226	0.5771	0.5990
Down	Tf-Idf	(1, 1)	50	Sí	[50]	0.2	0.6316	0.5684	0.5983
Down	Tf-Idf	(1, 1)	50	Sí	[50]	0	0.6612	0.4893	0.5624
Down	Tf-Idf	(1, 1)	50	Sí	[50, 25]	0.2	0.6455	0.5334	0.5841
Down	Tf-Idf	(1, 1)	50	Sí	[50, 25]	0	0.6165	0.5956	0.6059
Down	Tf-Idf	(1, 1)	50	Sí	[50, 25, 16]	0.2	0.6320	0.5748	0.6021
Down	Tf-Idf	(1, 1)	50	Sí	[50, 25, 16]	0	0.6337	0.5434	0.5851
Down	Tf-Idf	(1, 1)	50	Sí	[75, 25]	0.2	0.6719	0.4694	0.5527
Down	Tf-Idf	(1, 1)	50	Sí	[75, 25]	0	0.6548	0.4754	0.5509
Down	Tf-Idf	(1, 1)	50	Sí	[91, 41, 16]	0.2	0.6290	0.5481	0.5858
Down	Tf-Idf	(1, 1)	50	Sí	[91, 41, 16]	0	0.6737	0.4718	0.5549
Down	Tf-Idf	(1, 1)	500	No	[500]	0.2	0.7050	0.6586	0.6810
Down	Tf-Idf	(1, 1)	500	No	[500]	0	0.7404	0.5918	0.6579
Down	Tf-Idf	(1, 1)	500	No	[500, 250]	0.2	0.6842	0.7179	0.7006
Down	Tf-Idf	(1, 1)	500	No	[500, 250]	0	0.7007	0.6802	0.6903
Down	Tf-Idf	(1, 1)	500	No	[500, 250, 166]	0.2	0.7070	0.6723	0.6892
Down	Tf-Idf	(1, 1)	500	No	[500, 250, 166]	0	0.6963	0.6891	0.6927
Down	Tf-Idf	(1, 1)	500	No	[750, 250]	0.2	0.6917	0.7000	0.6958
Down	Tf-Idf	(1, 1)	500	No	[750, 250]	0	0.6882	0.7063	0.6972
Down	Tf-Idf	(1, 1)	500	No	[916, 416, 166]	0.2	0.7043	0.6736	0.6886
Down	Tf-Idf	(1, 1)	500	No	[916, 416, 166]	0	0.7648	0.5477	0.6383
Down	Tf-Idf	(1, 1)	500	Sí	[500]	0.2	0.7205	0.5961	0.6524
Down	Tf-Idf	(1, 1)	500	Sí	[500]	0	0.7126	0.6356	0.6719
Down	Tf-Idf	(1, 1)	500	Sí	[500, 250]	0.2	0.7574	0.5646	0.6469
Down	Tf-Idf	(1, 1)	500	Sí	[500, 250]	0	0.7273	0.6014	0.6584
Down	Tf-Idf	(1, 1)	500	Sí	[500, 250, 166]	0.2	0.7485	0.5644	0.6436
Down	Tf-Idf	(1, 1)	500	Sí	[500, 250, 166]	0	0.7001	0.6753	0.6875
Down	Tf-Idf	(1, 1)	500	Sí	[750, 250]	0.2	0.7350	0.5856	0.6518
Down	Tf-Idf	(1, 1)	500	Sí	[750, 250]	0	0.7295	0.5980	0.6572
Down	Tf-Idf	(1, 1)	500	Sí	[916, 416, 166]	0.2	0.7423	0.5966	0.6615
Down	Tf-Idf	(1, 1)	500	Sí	[916, 416, 166]	0	0.7113	0.6402	0.6739
Down	Tf-Idf	(1, 1)	2000	No	[2000]	0.2	0.7556	0.7007	0.7271
Down	Tf-Idf	(1, 1)	2000	No	[2000]	0	0.7646	0.6711	0.7148
Down	Tf-Idf	(1, 1)	2000	No	[2000, 1000]	0.2	0.7273	0.7539	0.7404
Down	Tf-Idf	(1, 1)	2000	No	[2000, 1000]	0	0.7766	0.6769	0.7233
Down	Tf-Idf	(1, 1)	2000	No	[2000, 1000, 666]	0.2	0.7729	0.6891	0.7286
Down	Tf-Idf	(1, 1)	2000	No	[2000, 1000, 666]	0	0.8054	0.6336	0.7093
Down	Tf-Idf	(1, 1)	2000	No	[3000, 1000]	0.2	0.7745	0.6756	0.7217
Down	Tf-Idf	(1, 1)	2000	No	[3000, 1000]	0	0.7980	0.6498	0.7163
Down	Tf-Idf	(1, 1)	2000	No	[3666, 1666, 666]	0.2	0.7468	0.7436	0.7452
Down	Tf-Idf	(1, 1)	2000	No	[3666, 1666, 666]	0	0.7499	0.7235	0.7364

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Tf-Idf	(1, 1)	2000	Sí	[2000]	0.2	0.7893	0.6255	0.6979
Down	Tf-Idf	(1, 1)	2000	Sí	[2000]	0	0.7595	0.6835	0.7195
Down	Tf-Idf	(1, 1)	2000	Sí	[2000, 1000]	0.2	0.7842	0.6680	0.7214
Down	Tf-Idf	(1, 1)	2000	Sí	[2000, 1000]	0	0.8156	0.6051	0.6947
Down	Tf-Idf	(1, 1)	2000	Sí	[2000, 1000, 666]	0.2	0.8029	0.6340	0.7085
Down	Tf-Idf	(1, 1)	2000	Sí	[2000, 1000, 666]	0	0.7702	0.6776	0.7209
Down	Tf-Idf	(1, 1)	2000	Sí	[3000, 1000]	0.2	0.7472	0.7200	0.7333
Down	Tf-Idf	(1, 1)	2000	Sí	[3000, 1000]	0	0.7338	0.7418	0.7378
Down	Tf-Idf	(1, 1)	2000	Sí	[3666, 1666, 666]	0.2	0.7247	0.7521	0.7381
Down	Tf-Idf	(1, 1)	2000	Sí	[3666, 1666, 666]	0	0.7374	0.7392	0.7383
Down	Tf-Idf	(1, 1)	3000	No	[3000]	0.2	0.7665	0.7002	0.7319
Down	Tf-Idf	(1, 1)	3000	No	[3000]	0	0.7850	0.6581	0.7160
Down	Tf-Idf	(1, 1)	3000	No	[3000, 1500]	0.2	0.8046	0.6827	0.7386
Down	Tf-Idf	(1, 1)	3000	No	[3000, 1500]	0	0.8120	0.6748	0.7370
Down	Tf-Idf	(1, 1)	3000	No	[3000, 1500, 1000]	0.2	0.8306	0.6358	0.7202
Down	Tf-Idf	(1, 1)	3000	No	[3000, 1500, 1000]	0	0.7688	0.7426	0.7555
Down	Tf-Idf	(1, 1)	3000	No	[4500, 1500]	0.2	0.7245	0.8104	0.7650
Down	Tf-Idf	(1, 1)	3000	No	[4500, 1500]	0	0.7776	0.7220	0.7488
Down	Tf-Idf	(1, 1)	3000	No	[5500, 2500, 1000]	0.2	0.7772	0.7266	0.7511
Down	Tf-Idf	(1, 1)	3000	No	[5500, 2500, 1000]	0	0.8035	0.6625	0.7262
Down	Tf-Idf	(1, 1)	3000	Sí	[3000]	0.2	0.6768	0.8282	0.7449
Down	Tf-Idf	(1, 1)	3000	Sí	[3000]	0	0.7877	0.6397	0.7060
Down	Tf-Idf	(1, 1)	3000	Sí	[3000, 1500]	0.2	0.7758	0.7151	0.7442
Down	Tf-Idf	(1, 1)	3000	Sí	[3000, 1500]	0	0.7924	0.6885	0.7368
Down	Tf-Idf	(1, 1)	3000	Sí	[3000, 1500, 1000]	0.2	0.7486	0.7448	0.7467
Down	Tf-Idf	(1, 1)	3000	Sí	[3000, 1500, 1000]	0	0.7612	0.7339	0.7473
Down	Tf-Idf	(1, 1)	3000	Sí	[4500, 1500]	0.2	0.8691	0.5383	0.6648
Down	Tf-Idf	(1, 1)	3000	Sí	[4500, 1500]	0	0.7806	0.7056	0.7412
Down	Tf-Idf	(1, 1)	3000	Sí	[5500, 2500, 1000]	0.2	0.7941	0.6878	0.7371
Down	Tf-Idf	(1, 1)	3000	Sí	[5500, 2500, 1000]	0	0.8701	0.5254	0.6552
Down	Tf-Idf	(1, 2)	50	No	[50]	0.2	0.6095	0.5847	0.5969
Down	Tf-Idf	(1, 2)	50	No	[50]	0	0.5702	0.7123	0.6334
Down	Tf-Idf	(1, 2)	50	No	[50, 25]	0.2	0.6188	0.5391	0.5762
Down	Tf-Idf	(1, 2)	50	No	[50, 25]	0	0.6020	0.5649	0.5829
Down	Tf-Idf	(1, 2)	50	No	[50, 25, 16]	0.2	0.6368	0.4932	0.5559
Down	Tf-Idf	(1, 2)	50	No	[50, 25, 16]	0	0.6141	0.5543	0.5827
Down	Tf-Idf	(1, 2)	50	No	[75, 25]	0.2	0.6548	0.4394	0.5259
Down	Tf-Idf	(1, 2)	50	No	[75, 25]	0	0.6176	0.5282	0.5694
Down	Tf-Idf	(1, 2)	50	No	[91, 41, 16]	0.2	0.6200	0.5236	0.5677
Down	Tf-Idf	(1, 2)	50	No	[91, 41, 16]	0	0.5846	0.6356	0.6091
Down	Tf-Idf	(1, 2)	50	Sí	[50]	0.2	0.6603	0.4954	0.5661
Down	Tf-Idf	(1, 2)	50	Sí	[50]	0	0.6685	0.4703	0.5521
Down	Tf-Idf	(1, 2)	50	Sí	[50, 25]	0.2	0.6667	0.4926	0.5665
Down	Tf-Idf	(1, 2)	50	Sí	[50, 25]	0	0.6280	0.5750	0.6003
Down	Tf-Idf	(1, 2)	50	Sí	[50, 25, 16]	0.2	0.6676	0.4708	0.5522
Down	Tf-Idf	(1, 2)	50	Sí	[50, 25, 16]	0	0.6615	0.4807	0.5568
Down	Tf-Idf	(1, 2)	50	Sí	[75, 25]	0.2	0.6766	0.4348	0.5294
Down	Tf-Idf	(1, 2)	50	Sí	[75, 25]	0	0.6325	0.5489	0.5877
Down	Tf-Idf	(1, 2)	50	Sí	[91, 41, 16]	0.2	0.6904	0.4240	0.5254
Down	Tf-Idf	(1, 2)	50	Sí	[91, 41, 16]	0	0.6596	0.4964	0.5664

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Tf-Idf	(1, 2)	500	No	[500]	0.2	0.6788	0.6921	0.6854
Down	Tf-Idf	(1, 2)	500	No	[500]	0	0.7292	0.5915	0.6532
Down	Tf-Idf	(1, 2)	500	No	[500, 250]	0.2	0.6913	0.6833	0.6873
Down	Tf-Idf	(1, 2)	500	No	[500, 250]	0	0.7129	0.6229	0.6648
Down	Tf-Idf	(1, 2)	500	No	[500, 250, 166]	0.2	0.7008	0.6667	0.6833
Down	Tf-Idf	(1, 2)	500	No	[500, 250, 166]	0	0.6968	0.6658	0.6810
Down	Tf-Idf	(1, 2)	500	No	[750, 250]	0.2	0.7168	0.6209	0.6654
Down	Tf-Idf	(1, 2)	500	No	[750, 250]	0	0.7241	0.6065	0.6601
Down	Tf-Idf	(1, 2)	500	No	[916, 416, 166]	0.2	0.6916	0.6733	0.6823
Down	Tf-Idf	(1, 2)	500	No	[916, 416, 166]	0	0.7302	0.6036	0.6609
Down	Tf-Idf	(1, 2)	500	Sí	[500]	0.2	0.6779	0.6829	0.6804
Down	Tf-Idf	(1, 2)	500	Sí	[500]	0	0.6996	0.6440	0.6707
Down	Tf-Idf	(1, 2)	500	Sí	[500, 250]	0.2	0.7247	0.5943	0.6531
Down	Tf-Idf	(1, 2)	500	Sí	[500, 250]	0	0.7129	0.6095	0.6572
Down	Tf-Idf	(1, 2)	500	Sí	[500, 250, 166]	0.2	0.7078	0.6298	0.6666
Down	Tf-Idf	(1, 2)	500	Sí	[500, 250, 166]	0	0.7032	0.6434	0.6720
Down	Tf-Idf	(1, 2)	500	Sí	[750, 250]	0.2	0.6553	0.7270	0.6893
Down	Tf-Idf	(1, 2)	500	Sí	[750, 250]	0	0.6917	0.6454	0.6677
Down	Tf-Idf	(1, 2)	500	Sí	[916, 416, 166]	0.2	0.6976	0.6535	0.6748
Down	Tf-Idf	(1, 2)	500	Sí	[916, 416, 166]	0	0.7390	0.5907	0.6566
Down	Tf-Idf	(1, 2)	2000	No	[2000]	0.2	0.7219	0.7215	0.7217
Down	Tf-Idf	(1, 2)	2000	No	[2000]	0	0.7034	0.7597	0.7305
Down	Tf-Idf	(1, 2)	2000	No	[2000, 1000]	0.2	0.7487	0.6767	0.7109
Down	Tf-Idf	(1, 2)	2000	No	[2000, 1000]	0	0.7241	0.7279	0.7260
Down	Tf-Idf	(1, 2)	2000	No	[2000, 1000, 666]	0.2	0.8000	0.5747	0.6688
Down	Tf-Idf	(1, 2)	2000	No	[2000, 1000, 666]	0	0.7635	0.6619	0.7091
Down	Tf-Idf	(1, 2)	2000	No	[3000, 1000]	0.2	0.7697	0.6485	0.7039
Down	Tf-Idf	(1, 2)	2000	No	[3000, 1000]	0	0.7693	0.6330	0.6945
Down	Tf-Idf	(1, 2)	2000	No	[3666, 1666, 666]	0.2	0.7991	0.5839	0.6747
Down	Tf-Idf	(1, 2)	2000	No	[3666, 1666, 666]	0	0.7224	0.7308	0.7266
Down	Tf-Idf	(1, 2)	2000	Sí	[2000]	0.2	0.7174	0.7223	0.7198
Down	Tf-Idf	(1, 2)	2000	Sí	[2000]	0	0.7496	0.6700	0.7075
Down	Tf-Idf	(1, 2)	2000	Sí	[2000, 1000]	0.2	0.7646	0.6739	0.7164
Down	Tf-Idf	(1, 2)	2000	Sí	[2000, 1000]	0	0.7453	0.7078	0.7261
Down	Tf-Idf	(1, 2)	2000	Sí	[2000, 1000, 666]	0.2	0.7359	0.7260	0.7309
Down	Tf-Idf	(1, 2)	2000	Sí	[2000, 1000, 666]	0	0.7328	0.7301	0.7314
Down	Tf-Idf	(1, 2)	2000	Sí	[3000, 1000]	0.2	0.8184	0.5823	0.6804
Down	Tf-Idf	(1, 2)	2000	Sí	[3000, 1000]	0	0.7551	0.6886	0.7203
Down	Tf-Idf	(1, 2)	2000	Sí	[3666, 1666, 666]	0.2	0.7752	0.6573	0.7114
Down	Tf-Idf	(1, 2)	2000	Sí	[3666, 1666, 666]	0	0.7640	0.6705	0.7142
Down	Tf-Idf	(1, 2)	3000	No	[3000]	0.2	0.7310	0.7162	0.7235
Down	Tf-Idf	(1, 2)	3000	No	[3000]	0	0.6600	0.8264	0.7339
Down	Tf-Idf	(1, 2)	3000	No	[3000, 1500]	0.2	0.7526	0.7053	0.7282
Down	Tf-Idf	(1, 2)	3000	No	[3000, 1500]	0	0.7894	0.6513	0.7137
Down	Tf-Idf	(1, 2)	3000	No	[3000, 1500, 1000]	0.2	0.7705	0.6776	0.7210
Down	Tf-Idf	(1, 2)	3000	No	[3000, 1500, 1000]	0	0.7395	0.7344	0.7369
Down	Tf-Idf	(1, 2)	3000	No	[4500, 1500]	0.2	0.7923	0.6378	0.7067
Down	Tf-Idf	(1, 2)	3000	No	[4500, 1500]	0	0.7695	0.6838	0.7242
Down	Tf-Idf	(1, 2)	3000	No	[5500, 2500, 1000]	0.2	0.7251	0.7468	0.7358
Down	Tf-Idf	(1, 2)	3000	No	[5500, 2500, 1000]	0	0.7560	0.6976	0.7256

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Tf-Idf	(1, 2)	3000	Sí	[3000]	0.2	0.7513	0.7169	0.7337
Down	Tf-Idf	(1, 2)	3000	Sí	[3000]	0	0.7417	0.7185	0.7299
Down	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500]	0.2	0.7016	0.8208	0.7565
Down	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500]	0	0.7758	0.7035	0.7379
Down	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.8060	0.6554	0.7230
Down	Tf-Idf	(1, 2)	3000	Sí	[3000, 1500, 1000]	0	0.7990	0.6535	0.7189
Down	Tf-Idf	(1, 2)	3000	Sí	[4500, 1500]	0.2	0.7312	0.7739	0.7519
Down	Tf-Idf	(1, 2)	3000	Sí	[4500, 1500]	0	0.7819	0.6891	0.7326
Down	Tf-Idf	(1, 2)	3000	Sí	[5500, 2500, 1000]	0.2	0.8130	0.6427	0.7179
Down	Tf-Idf	(1, 2)	3000	Sí	[5500, 2500, 1000]	0	0.7638	0.7116	0.7368
Down	Tf-Idf	(2, 2)	50	No	[50]	0.2	0.5909	0.5284	0.5579
Down	Tf-Idf	(2, 2)	50	No	[50]	0	0.6013	0.4945	0.5427
Down	Tf-Idf	(2, 2)	50	No	[50, 25]	0.2	0.5892	0.5482	0.5680
Down	Tf-Idf	(2, 2)	50	No	[50, 25]	0	0.6012	0.4655	0.5247
Down	Tf-Idf	(2, 2)	50	No	[50, 25, 16]	0.2	0.5974	0.4993	0.5440
Down	Tf-Idf	(2, 2)	50	No	[50, 25, 16]	0	0.6030	0.4775	0.5330
Down	Tf-Idf	(2, 2)	50	No	[75, 25]	0.2	0.5965	0.5238	0.5578
Down	Tf-Idf	(2, 2)	50	No	[75, 25]	0	0.6026	0.4818	0.5355
Down	Tf-Idf	(2, 2)	50	No	[91, 41, 16]	0.2	0.5958	0.5271	0.5593
Down	Tf-Idf	(2, 2)	50	No	[91, 41, 16]	0	0.6155	0.4744	0.5358
Down	Tf-Idf	(2, 2)	50	Sí	[50]	0.2	0.6203	0.4382	0.5136
Down	Tf-Idf	(2, 2)	50	Sí	[50]	0	0.6242	0.4225	0.5039
Down	Tf-Idf	(2, 2)	50	Sí	[50, 25]	0.2	0.6248	0.4295	0.5091
Down	Tf-Idf	(2, 2)	50	Sí	[50, 25]	0	0.6227	0.4144	0.4977
Down	Tf-Idf	(2, 2)	50	Sí	[50, 25, 16]	0.2	0.6239	0.4334	0.5115
Down	Tf-Idf	(2, 2)	50	Sí	[50, 25, 16]	0	0.6235	0.4329	0.5110
Down	Tf-Idf	(2, 2)	50	Sí	[75, 25]	0.2	0.6259	0.4148	0.4989
Down	Tf-Idf	(2, 2)	50	Sí	[75, 25]	0	0.6191	0.4404	0.5147
Down	Tf-Idf	(2, 2)	50	Sí	[91, 41, 16]	0.2	0.6224	0.4343	0.5116
Down	Tf-Idf	(2, 2)	50	Sí	[91, 41, 16]	0	0.6131	0.4419	0.5136
Down	Tf-Idf	(2, 2)	500	No	[500]	0.2	0.6584	0.5202	0.5812
Down	Tf-Idf	(2, 2)	500	No	[500]	0	0.6463	0.5562	0.5978
Down	Tf-Idf	(2, 2)	500	No	[500, 250]	0.2	0.6572	0.5532	0.6007
Down	Tf-Idf	(2, 2)	500	No	[500, 250]	0	0.6319	0.6229	0.6273
Down	Tf-Idf	(2, 2)	500	No	[500, 250, 166]	0.2	0.6743	0.5122	0.5822
Down	Tf-Idf	(2, 2)	500	No	[500, 250, 166]	0	0.6224	0.6143	0.6183
Down	Tf-Idf	(2, 2)	500	No	[750, 250]	0.2	0.6258	0.6191	0.6224
Down	Tf-Idf	(2, 2)	500	No	[750, 250]	0	0.6362	0.6214	0.6287
Down	Tf-Idf	(2, 2)	500	No	[916, 416, 166]	0.2	0.6446	0.5745	0.6075
Down	Tf-Idf	(2, 2)	500	No	[916, 416, 166]	0	0.6458	0.5674	0.6041
Down	Tf-Idf	(2, 2)	500	Sí	[500]	0.2	0.6875	0.4440	0.5395
Down	Tf-Idf	(2, 2)	500	Sí	[500]	0	0.6814	0.4542	0.5451
Down	Tf-Idf	(2, 2)	500	Sí	[500, 250]	0.2	0.6691	0.5033	0.5745
Down	Tf-Idf	(2, 2)	500	Sí	[500, 250]	0	0.6913	0.4473	0.5432
Down	Tf-Idf	(2, 2)	500	Sí	[500, 250, 166]	0.2	0.6873	0.4428	0.5386
Down	Tf-Idf	(2, 2)	500	Sí	[500, 250, 166]	0	0.6697	0.4974	0.5708
Down	Tf-Idf	(2, 2)	500	Sí	[750, 250]	0.2	0.6859	0.4506	0.5439
Down	Tf-Idf	(2, 2)	500	Sí	[750, 250]	0	0.6810	0.4792	0.5625
Down	Tf-Idf	(2, 2)	500	Sí	[916, 416, 166]	0.2	0.6908	0.4694	0.5590
Down	Tf-Idf	(2, 2)	500	Sí	[916, 416, 166]	0	0.6752	0.4848	0.5644

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Tf-Idf	(2, 2)	2000	No	[2000]	0.2	0.6513	0.6515	0.6514
Down	Tf-Idf	(2, 2)	2000	No	[2000]	0	0.6475	0.6596	0.6535
Down	Tf-Idf	(2, 2)	2000	No	[2000, 1000]	0.2	0.7007	0.5842	0.6372
Down	Tf-Idf	(2, 2)	2000	No	[2000, 1000]	0	0.6944	0.5864	0.6359
Down	Tf-Idf	(2, 2)	2000	No	[2000, 1000, 666]	0.2	0.6961	0.5849	0.6357
Down	Tf-Idf	(2, 2)	2000	No	[2000, 1000, 666]	0	0.6957	0.5890	0.6379
Down	Tf-Idf	(2, 2)	2000	No	[3000, 1000]	0.2	0.6963	0.5920	0.6399
Down	Tf-Idf	(2, 2)	2000	No	[3000, 1000]	0	0.6880	0.5958	0.6386
Down	Tf-Idf	(2, 2)	2000	No	[3666, 1666, 666]	0.2	0.6892	0.6098	0.6471
Down	Tf-Idf	(2, 2)	2000	No	[3666, 1666, 666]	0	0.7040	0.5600	0.6238
Down	Tf-Idf	(2, 2)	2000	Sí	[2000]	0.2	0.6700	0.5362	0.5957
Down	Tf-Idf	(2, 2)	2000	Sí	[2000]	0	0.6735	0.5431	0.6013
Down	Tf-Idf	(2, 2)	2000	Sí	[2000, 1000]	0.2	0.6897	0.5332	0.6015
Down	Tf-Idf	(2, 2)	2000	Sí	[2000, 1000]	0	0.6977	0.5243	0.5987
Down	Tf-Idf	(2, 2)	2000	Sí	[2000, 1000, 666]	0.2	0.7533	0.4237	0.5423
Down	Tf-Idf	(2, 2)	2000	Sí	[2000, 1000, 666]	0	0.7242	0.4949	0.5880
Down	Tf-Idf	(2, 2)	2000	Sí	[3000, 1000]	0.2	0.7370	0.4574	0.5645
Down	Tf-Idf	(2, 2)	2000	Sí	[3000, 1000]	0	0.7303	0.4818	0.5806
Down	Tf-Idf	(2, 2)	2000	Sí	[3666, 1666, 666]	0.2	0.7809	0.3680	0.5003
Down	Tf-Idf	(2, 2)	2000	Sí	[3666, 1666, 666]	0	0.7060	0.5152	0.5957
Down	Tf-Idf	(2, 2)	3000	No	[3000]	0.2	0.6845	0.5737	0.6242
Down	Tf-Idf	(2, 2)	3000	No	[3000]	0	0.6399	0.7288	0.6814
Down	Tf-Idf	(2, 2)	3000	No	[3000, 1500]	0.2	0.7368	0.5636	0.6387
Down	Tf-Idf	(2, 2)	3000	No	[3000, 1500]	0	0.6801	0.6510	0.6652
Down	Tf-Idf	(2, 2)	3000	No	[3000, 1500, 1000]	0.2	0.7239	0.5629	0.6333
Down	Tf-Idf	(2, 2)	3000	No	[3000, 1500, 1000]	0	0.7305	0.5557	0.6312
Down	Tf-Idf	(2, 2)	3000	No	[4500, 1500]	0.2	0.7098	0.5966	0.6483
Down	Tf-Idf	(2, 2)	3000	No	[4500, 1500]	0	0.7563	0.5043	0.6051
Down	Tf-Idf	(2, 2)	3000	No	[5500, 2500, 1000]	0.2	0.6871	0.6359	0.6605
Down	Tf-Idf	(2, 2)	3000	No	[5500, 2500, 1000]	0	0.6849	0.6356	0.6594
Down	Tf-Idf	(2, 2)	3000	Sí	[3000]	0.2	0.6616	0.5588	0.6059
Down	Tf-Idf	(2, 2)	3000	Sí	[3000]	0	0.6653	0.5776	0.6184
Down	Tf-Idf	(2, 2)	3000	Sí	[3000, 1500]	0.2	0.6780	0.5804	0.6254
Down	Tf-Idf	(2, 2)	3000	Sí	[3000, 1500]	0	0.7773	0.4116	0.5382
Down	Tf-Idf	(2, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.7176	0.5289	0.6090
Down	Tf-Idf	(2, 2)	3000	Sí	[3000, 1500, 1000]	0	0.6973	0.5535	0.6171
Down	Tf-Idf	(2, 2)	3000	Sí	[4500, 1500]	0.2	0.7187	0.5135	0.5990
Down	Tf-Idf	(2, 2)	3000	Sí	[4500, 1500]	0	0.7256	0.5066	0.5966
Down	Tf-Idf	(2, 2)	3000	Sí	[5500, 2500, 1000]	0.2	0.7379	0.4903	0.5891
Down	Tf-Idf	(2, 2)	3000	Sí	[5500, 2500, 1000]	0	0.7225	0.5119	0.5992
Down	Frec.	(1, 1)	50	No	[50]	0.2	0.6226	0.5801	0.6006
Down	Frec.	(1, 1)	50	No	[50]	0	0.6443	0.4863	0.5543
Down	Frec.	(1, 1)	50	No	[50, 25]	0.2	0.6329	0.5294	0.5765
Down	Frec.	(1, 1)	50	No	[50, 25]	0	0.6384	0.5045	0.5636
Down	Frec.	(1, 1)	50	No	[50, 25, 16]	0.2	0.6167	0.5842	0.6001
Down	Frec.	(1, 1)	50	No	[50, 25, 16]	0	0.6225	0.5208	0.5671
Down	Frec.	(1, 1)	50	No	[75, 25]	0.2	0.6129	0.6075	0.6102
Down	Frec.	(1, 1)	50	No	[75, 25]	0	0.6168	0.5638	0.5891
Down	Frec.	(1, 1)	50	No	[91, 41, 16]	0.2	0.6358	0.5170	0.5703
Down	Frec.	(1, 1)	50	No	[91, 41, 16]	0	0.6404	0.4972	0.5598

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Frec.	(1, 1)	50	Sí	[50]	0.2	0.6548	0.4947	0.5636
Down	Frec.	(1, 1)	50	Sí	[50]	0	0.6326	0.5697	0.5995
Down	Frec.	(1, 1)	50	Sí	[50, 25]	0.2	0.6385	0.5510	0.5915
Down	Frec.	(1, 1)	50	Sí	[50, 25]	0	0.6323	0.5692	0.5991
Down	Frec.	(1, 1)	50	Sí	[50, 25, 16]	0.2	0.6748	0.4483	0.5387
Down	Frec.	(1, 1)	50	Sí	[50, 25, 16]	0	0.6616	0.4647	0.5459
Down	Frec.	(1, 1)	50	Sí	[75, 25]	0.2	0.6382	0.5671	0.6005
Down	Frec.	(1, 1)	50	Sí	[75, 25]	0	0.6492	0.5248	0.5804
Down	Frec.	(1, 1)	50	Sí	[91, 41, 16]	0.2	0.6500	0.4982	0.5641
Down	Frec.	(1, 1)	50	Sí	[91, 41, 16]	0	0.6460	0.5102	0.5701
Down	Frec.	(1, 1)	500	No	[500]	0.2	0.7172	0.6459	0.6796
Down	Frec.	(1, 1)	500	No	[500]	0	0.7233	0.6389	0.6785
Down	Frec.	(1, 1)	500	No	[500, 250]	0.2	0.7044	0.6819	0.6930
Down	Frec.	(1, 1)	500	No	[500, 250]	0	0.7236	0.6260	0.6713
Down	Frec.	(1, 1)	500	No	[500, 250, 166]	0.2	0.7387	0.6308	0.6805
Down	Frec.	(1, 1)	500	No	[500, 250, 166]	0	0.7062	0.6639	0.6844
Down	Frec.	(1, 1)	500	No	[750, 250]	0.2	0.7231	0.6478	0.6834
Down	Frec.	(1, 1)	500	No	[750, 250]	0	0.7083	0.6662	0.6866
Down	Frec.	(1, 1)	500	No	[916, 416, 166]	0.2	0.7502	0.5946	0.6634
Down	Frec.	(1, 1)	500	No	[916, 416, 166]	0	0.7067	0.6794	0.6928
Down	Frec.	(1, 1)	500	Sí	[500]	0.2	0.7132	0.6242	0.6657
Down	Frec.	(1, 1)	500	Sí	[500]	0	0.7075	0.6274	0.6650
Down	Frec.	(1, 1)	500	Sí	[500, 250]	0.2	0.7291	0.6211	0.6708
Down	Frec.	(1, 1)	500	Sí	[500, 250]	0	0.7309	0.5917	0.6539
Down	Frec.	(1, 1)	500	Sí	[500, 250, 166]	0.2	0.7405	0.5836	0.6527
Down	Frec.	(1, 1)	500	Sí	[500, 250, 166]	0	0.6919	0.6655	0.6785
Down	Frec.	(1, 1)	500	Sí	[750, 250]	0.2	0.7108	0.6544	0.6815
Down	Frec.	(1, 1)	500	Sí	[750, 250]	0	0.7443	0.5913	0.6591
Down	Frec.	(1, 1)	500	Sí	[916, 416, 166]	0.2	0.7469	0.5651	0.6434
Down	Frec.	(1, 1)	500	Sí	[916, 416, 166]	0	0.7531	0.5765	0.6531
Down	Frec.	(1, 1)	2000	No	[2000]	0.2	0.7224	0.7630	0.7421
Down	Frec.	(1, 1)	2000	No	[2000]	0	0.7743	0.6617	0.7136
Down	Frec.	(1, 1)	2000	No	[2000, 1000]	0.2	0.7421	0.7417	0.7419
Down	Frec.	(1, 1)	2000	No	[2000, 1000]	0	0.7323	0.7635	0.7475
Down	Frec.	(1, 1)	2000	No	[2000, 1000, 666]	0.2	0.7333	0.7531	0.7431
Down	Frec.	(1, 1)	2000	No	[2000, 1000, 666]	0	0.7205	0.7843	0.7510
Down	Frec.	(1, 1)	2000	No	[3000, 1000]	0.2	0.8058	0.6346	0.7100
Down	Frec.	(1, 1)	2000	No	[3000, 1000]	0	0.7704	0.6933	0.7298
Down	Frec.	(1, 1)	2000	No	[3666, 1666, 666]	0.2	0.7521	0.7243	0.7380
Down	Frec.	(1, 1)	2000	No	[3666, 1666, 666]	0	0.8074	0.6384	0.7130
Down	Frec.	(1, 1)	2000	Sí	[2000]	0.2	0.7312	0.7157	0.7234
Down	Frec.	(1, 1)	2000	Sí	[2000]	0	0.7456	0.7123	0.7286
Down	Frec.	(1, 1)	2000	Sí	[2000, 1000]	0.2	0.7586	0.7091	0.7330
Down	Frec.	(1, 1)	2000	Sí	[2000, 1000]	0	0.7212	0.7686	0.7441
Down	Frec.	(1, 1)	2000	Sí	[2000, 1000, 666]	0.2	0.7453	0.7344	0.7398
Down	Frec.	(1, 1)	2000	Sí	[2000, 1000, 666]	0	0.7506	0.7253	0.7377
Down	Frec.	(1, 1)	2000	Sí	[3000, 1000]	0.2	0.7756	0.6655	0.7163
Down	Frec.	(1, 1)	2000	Sí	[3000, 1000]	0	0.7423	0.7342	0.7382
Down	Frec.	(1, 1)	2000	Sí	[3666, 1666, 666]	0.2	0.7838	0.6581	0.7155
Down	Frec.	(1, 1)	2000	Sí	[3666, 1666, 666]	0	0.7783	0.6761	0.7236

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Frec.	(1, 1)	3000	No	[3000]	0.2	0.7897	0.6556	0.7164
Down	Frec.	(1, 1)	3000	No	[3000]	0	0.7993	0.6416	0.7118
Down	Frec.	(1, 1)	3000	No	[3000, 1500]	0.2	0.7968	0.6756	0.7312
Down	Frec.	(1, 1)	3000	No	[3000, 1500]	0	0.7815	0.7238	0.7516
Down	Frec.	(1, 1)	3000	No	[3000, 1500, 1000]	0.2	0.7323	0.7843	0.7574
Down	Frec.	(1, 1)	3000	No	[3000, 1500, 1000]	0	0.7905	0.7048	0.7452
Down	Frec.	(1, 1)	3000	No	[4500, 1500]	0.2	0.8515	0.5928	0.6990
Down	Frec.	(1, 1)	3000	No	[4500, 1500]	0	0.8046	0.6796	0.7368
Down	Frec.	(1, 1)	3000	No	[5500, 2500, 1000]	0.2	0.8334	0.6198	0.7109
Down	Frec.	(1, 1)	3000	No	[5500, 2500, 1000]	0	0.7631	0.7408	0.7518
Down	Frec.	(1, 1)	3000	Sí	[3000]	0.2	0.8140	0.5963	0.6883
Down	Frec.	(1, 1)	3000	Sí	[3000]	0	0.7583	0.6871	0.7210
Down	Frec.	(1, 1)	3000	Sí	[3000, 1500]	0.2	0.8737	0.5395	0.6671
Down	Frec.	(1, 1)	3000	Sí	[3000, 1500]	0	0.8413	0.5930	0.6957
Down	Frec.	(1, 1)	3000	Sí	[3000, 1500, 1000]	0.2	0.7466	0.7592	0.7528
Down	Frec.	(1, 1)	3000	Sí	[3000, 1500, 1000]	0	0.8036	0.6611	0.7254
Down	Frec.	(1, 1)	3000	Sí	[4500, 1500]	0.2	0.8008	0.6734	0.7316
Down	Frec.	(1, 1)	3000	Sí	[4500, 1500]	0	0.8245	0.6155	0.7048
Down	Frec.	(1, 1)	3000	Sí	[5500, 2500, 1000]	0.2	0.7630	0.7398	0.7513
Down	Frec.	(1, 1)	3000	Sí	[5500, 2500, 1000]	0	0.7400	0.7691	0.7543
Down	Frec.	(1, 2)	50	No	[50]	0.2	0.6276	0.5097	0.5626
Down	Frec.	(1, 2)	50	No	[50]	0	0.6158	0.5780	0.5963
Down	Frec.	(1, 2)	50	No	[50, 25]	0.2	0.6314	0.4974	0.5564
Down	Frec.	(1, 2)	50	No	[50, 25]	0	0.6039	0.5981	0.6010
Down	Frec.	(1, 2)	50	No	[50, 25, 16]	0.2	0.6261	0.5040	0.5584
Down	Frec.	(1, 2)	50	No	[50, 25, 16]	0	0.6089	0.5575	0.5820
Down	Frec.	(1, 2)	50	No	[75, 25]	0.2	0.6296	0.5059	0.5610
Down	Frec.	(1, 2)	50	No	[75, 25]	0	0.5921	0.6092	0.6005
Down	Frec.	(1, 2)	50	No	[91, 41, 16]	0.2	0.6238	0.5411	0.5795
Down	Frec.	(1, 2)	50	No	[91, 41, 16]	0	0.6421	0.4490	0.5284
Down	Frec.	(1, 2)	50	Sí	[50]	0.2	0.6573	0.5059	0.5718
Down	Frec.	(1, 2)	50	Sí	[50]	0	0.6612	0.4830	0.5582
Down	Frec.	(1, 2)	50	Sí	[50, 25]	0.2	0.6745	0.4638	0.5497
Down	Frec.	(1, 2)	50	Sí	[50, 25]	0	0.6581	0.4998	0.5682
Down	Frec.	(1, 2)	50	Sí	[50, 25, 16]	0.2	0.6591	0.4944	0.5650
Down	Frec.	(1, 2)	50	Sí	[50, 25, 16]	0	0.6339	0.5372	0.5815
Down	Frec.	(1, 2)	50	Sí	[75, 25]	0.2	0.6521	0.5056	0.5696
Down	Frec.	(1, 2)	50	Sí	[75, 25]	0	0.6338	0.5697	0.6000
Down	Frec.	(1, 2)	50	Sí	[91, 41, 16]	0.2	0.6493	0.5223	0.5789
Down	Frec.	(1, 2)	50	Sí	[91, 41, 16]	0	0.6612	0.4685	0.5484
Down	Frec.	(1, 2)	500	No	[500]	0.2	0.6948	0.6589	0.6764
Down	Frec.	(1, 2)	500	No	[500]	0	0.6532	0.7445	0.6958
Down	Frec.	(1, 2)	500	No	[500, 250]	0.2	0.7208	0.6176	0.6652
Down	Frec.	(1, 2)	500	No	[500, 250]	0	0.6826	0.6888	0.6857
Down	Frec.	(1, 2)	500	No	[500, 250, 166]	0.2	0.7320	0.6031	0.6613
Down	Frec.	(1, 2)	500	No	[500, 250, 166]	0	0.6914	0.6738	0.6824
Down	Frec.	(1, 2)	500	No	[750, 250]	0.2	0.7267	0.6193	0.6687
Down	Frec.	(1, 2)	500	No	[750, 250]	0	0.7076	0.6409	0.6726
Down	Frec.	(1, 2)	500	No	[916, 416, 166]	0.2	0.7411	0.5897	0.6568
Down	Frec.	(1, 2)	500	No	[916, 416, 166]	0	0.7106	0.6340	0.6701

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Frec.	(1, 2)	500	Sí	[500]	0.2	0.6990	0.6455	0.6712
Down	Frec.	(1, 2)	500	Sí	[500]	0	0.6988	0.6399	0.6680
Down	Frec.	(1, 2)	500	Sí	[500, 250]	0.2	0.7041	0.6376	0.6692
Down	Frec.	(1, 2)	500	Sí	[500, 250]	0	0.7177	0.5981	0.6525
Down	Frec.	(1, 2)	500	Sí	[500, 250, 166]	0.2	0.7247	0.6057	0.6599
Down	Frec.	(1, 2)	500	Sí	[500, 250, 166]	0	0.7255	0.6082	0.6617
Down	Frec.	(1, 2)	500	Sí	[750, 250]	0.2	0.7099	0.6287	0.6668
Down	Frec.	(1, 2)	500	Sí	[750, 250]	0	0.7132	0.6158	0.6609
Down	Frec.	(1, 2)	500	Sí	[916, 416, 166]	0.2	0.7295	0.6054	0.6617
Down	Frec.	(1, 2)	500	Sí	[916, 416, 166]	0	0.7113	0.6350	0.6710
Down	Frec.	(1, 2)	2000	No	[2000]	0.2	0.7324	0.6875	0.7092
Down	Frec.	(1, 2)	2000	No	[2000]	0	0.7398	0.6820	0.7098
Down	Frec.	(1, 2)	2000	No	[2000, 1000]	0.2	0.7769	0.6333	0.6978
Down	Frec.	(1, 2)	2000	No	[2000, 1000]	0	0.7497	0.6863	0.7166
Down	Frec.	(1, 2)	2000	No	[2000, 1000, 666]	0.2	0.7561	0.6761	0.7139
Down	Frec.	(1, 2)	2000	No	[2000, 1000, 666]	0	0.7429	0.6999	0.7208
Down	Frec.	(1, 2)	2000	No	[3000, 1000]	0.2	0.7698	0.6483	0.7038
Down	Frec.	(1, 2)	2000	No	[3000, 1000]	0	0.7390	0.7101	0.7243
Down	Frec.	(1, 2)	2000	No	[3666, 1666, 666]	0.2	0.7323	0.7050	0.7184
Down	Frec.	(1, 2)	2000	No	[3666, 1666, 666]	0	0.7691	0.6488	0.7039
Down	Frec.	(1, 2)	2000	Sí	[2000]	0.2	0.6698	0.8160	0.7357
Down	Frec.	(1, 2)	2000	Sí	[2000]	0	0.7470	0.6680	0.7053
Down	Frec.	(1, 2)	2000	Sí	[2000, 1000]	0.2	0.7657	0.6629	0.7106
Down	Frec.	(1, 2)	2000	Sí	[2000, 1000]	0	0.7606	0.6764	0.7160
Down	Frec.	(1, 2)	2000	Sí	[2000, 1000, 666]	0.2	0.8329	0.5738	0.6795
Down	Frec.	(1, 2)	2000	Sí	[2000, 1000, 666]	0	0.7686	0.6662	0.7137
Down	Frec.	(1, 2)	2000	Sí	[3000, 1000]	0.2	0.7274	0.7389	0.7331
Down	Frec.	(1, 2)	2000	Sí	[3000, 1000]	0	0.7693	0.6840	0.7241
Down	Frec.	(1, 2)	2000	Sí	[3666, 1666, 666]	0.2	0.7936	0.6445	0.7113
Down	Frec.	(1, 2)	2000	Sí	[3666, 1666, 666]	0	0.7658	0.6777	0.7191
Down	Frec.	(1, 2)	3000	No	[3000]	0.2	0.7090	0.7471	0.7276
Down	Frec.	(1, 2)	3000	No	[3000]	0	0.7888	0.5915	0.6760
Down	Frec.	(1, 2)	3000	No	[3000, 1500]	0.2	0.7400	0.7365	0.7382
Down	Frec.	(1, 2)	3000	No	[3000, 1500]	0	0.7870	0.6617	0.7190
Down	Frec.	(1, 2)	3000	No	[3000, 1500, 1000]	0.2	0.7565	0.6999	0.7271
Down	Frec.	(1, 2)	3000	No	[3000, 1500, 1000]	0	0.7794	0.6698	0.7204
Down	Frec.	(1, 2)	3000	No	[4500, 1500]	0.2	0.7338	0.7293	0.7315
Down	Frec.	(1, 2)	3000	No	[4500, 1500]	0	0.8214	0.6008	0.6940
Down	Frec.	(1, 2)	3000	No	[5500, 2500, 1000]	0.2	0.7421	0.7387	0.7404
Down	Frec.	(1, 2)	3000	No	[5500, 2500, 1000]	0	0.7292	0.7473	0.7381
Down	Frec.	(1, 2)	3000	Sí	[3000]	0.2	0.7627	0.6885	0.7237
Down	Frec.	(1, 2)	3000	Sí	[3000]	0	0.7840	0.6577	0.7154
Down	Frec.	(1, 2)	3000	Sí	[3000, 1500]	0.2	0.8036	0.6609	0.7253
Down	Frec.	(1, 2)	3000	Sí	[3000, 1500]	0	0.7957	0.6632	0.7234
Down	Frec.	(1, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.7355	0.7699	0.7523
Down	Frec.	(1, 2)	3000	Sí	[3000, 1500, 1000]	0	0.8108	0.6426	0.7169
Down	Frec.	(1, 2)	3000	Sí	[4500, 1500]	0.2	0.6998	0.8170	0.7538
Down	Frec.	(1, 2)	3000	Sí	[4500, 1500]	0	0.8061	0.6639	0.7281
Down	Frec.	(1, 2)	3000	Sí	[5500, 2500, 1000]	0.2	0.7603	0.7228	0.7411
Down	Frec.	(1, 2)	3000	Sí	[5500, 2500, 1000]	0	0.8159	0.6231	0.7066

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Frec.	(2, 2)	50	No	[50]	0.2	0.5978	0.5109	0.5509
Down	Frec.	(2, 2)	50	No	[50]	0	0.6110	0.4747	0.5343
Down	Frec.	(2, 2)	50	No	[50, 25]	0.2	0.6150	0.4567	0.5242
Down	Frec.	(2, 2)	50	No	[50, 25]	0	0.5893	0.5509	0.5695
Down	Frec.	(2, 2)	50	No	[50, 25, 16]	0.2	0.5982	0.5038	0.5469
Down	Frec.	(2, 2)	50	No	[50, 25, 16]	0	0.6175	0.4485	0.5196
Down	Frec.	(2, 2)	50	No	[75, 25]	0.2	0.5966	0.5339	0.5635
Down	Frec.	(2, 2)	50	No	[75, 25]	0	0.6021	0.4907	0.5408
Down	Frec.	(2, 2)	50	No	[91, 41, 16]	0.2	0.6033	0.5058	0.5503
Down	Frec.	(2, 2)	50	No	[91, 41, 16]	0	0.5998	0.5159	0.5547
Down	Frec.	(2, 2)	50	Sí	[50]	0.2	0.6214	0.4381	0.5139
Down	Frec.	(2, 2)	50	Sí	[50]	0	0.6212	0.4308	0.5088
Down	Frec.	(2, 2)	50	Sí	[50, 25]	0.2	0.6193	0.4387	0.5136
Down	Frec.	(2, 2)	50	Sí	[50, 25]	0	0.6201	0.4298	0.5077
Down	Frec.	(2, 2)	50	Sí	[50, 25, 16]	0.2	0.6229	0.4316	0.5099
Down	Frec.	(2, 2)	50	Sí	[50, 25, 16]	0	0.6209	0.4343	0.5111
Down	Frec.	(2, 2)	50	Sí	[75, 25]	0.2	0.6195	0.4386	0.5135
Down	Frec.	(2, 2)	50	Sí	[75, 25]	0	0.6250	0.4192	0.5018
Down	Frec.	(2, 2)	50	Sí	[91, 41, 16]	0.2	0.6248	0.4172	0.5003
Down	Frec.	(2, 2)	50	Sí	[91, 41, 16]	0	0.6243	0.4336	0.5117
Down	Frec.	(2, 2)	500	No	[500]	0.2	0.6529	0.5439	0.5934
Down	Frec.	(2, 2)	500	No	[500]	0	0.6872	0.4648	0.5545
Down	Frec.	(2, 2)	500	No	[500, 250]	0.2	0.6759	0.4901	0.5682
Down	Frec.	(2, 2)	500	No	[500, 250]	0	0.6560	0.5576	0.6029
Down	Frec.	(2, 2)	500	No	[500, 250, 166]	0.2	0.6782	0.5094	0.5818
Down	Frec.	(2, 2)	500	No	[500, 250, 166]	0	0.6394	0.5907	0.6141
Down	Frec.	(2, 2)	500	No	[750, 250]	0.2	0.6747	0.5218	0.5885
Down	Frec.	(2, 2)	500	No	[750, 250]	0	0.6694	0.5317	0.5927
Down	Frec.	(2, 2)	500	No	[916, 416, 166]	0.2	0.6647	0.5656	0.6112
Down	Frec.	(2, 2)	500	No	[916, 416, 166]	0	0.6495	0.5783	0.6118
Down	Frec.	(2, 2)	500	Sí	[500]	0.2	0.6888	0.4637	0.5543
Down	Frec.	(2, 2)	500	Sí	[500]	0	0.6644	0.4934	0.5663
Down	Frec.	(2, 2)	500	Sí	[500, 250]	0.2	0.6788	0.4656	0.5524
Down	Frec.	(2, 2)	500	Sí	[500, 250]	0	0.6712	0.4866	0.5642
Down	Frec.	(2, 2)	500	Sí	[500, 250, 166]	0.2	0.6662	0.4922	0.5662
Down	Frec.	(2, 2)	500	Sí	[500, 250, 166]	0	0.6744	0.4851	0.5643
Down	Frec.	(2, 2)	500	Sí	[750, 250]	0.2	0.6727	0.4879	0.5656
Down	Frec.	(2, 2)	500	Sí	[750, 250]	0	0.6661	0.5048	0.5743
Down	Frec.	(2, 2)	500	Sí	[916, 416, 166]	0.2	0.6769	0.4762	0.5591
Down	Frec.	(2, 2)	500	Sí	[916, 416, 166]	0	0.6719	0.4838	0.5626
Down	Frec.	(2, 2)	2000	No	[2000]	0.2	0.7321	0.5122	0.6027
Down	Frec.	(2, 2)	2000	No	[2000]	0	0.7167	0.5311	0.6101
Down	Frec.	(2, 2)	2000	No	[2000, 1000]	0.2	0.6924	0.5814	0.6321
Down	Frec.	(2, 2)	2000	No	[2000, 1000]	0	0.7328	0.5132	0.6037
Down	Frec.	(2, 2)	2000	No	[2000, 1000, 666]	0.2	0.6933	0.6069	0.6472
Down	Frec.	(2, 2)	2000	No	[2000, 1000, 666]	0	0.6958	0.5874	0.6370
Down	Frec.	(2, 2)	2000	No	[3000, 1000]	0.2	0.6955	0.5851	0.6355
Down	Frec.	(2, 2)	2000	No	[3000, 1000]	0	0.6543	0.6680	0.6611
Down	Frec.	(2, 2)	2000	No	[3666, 1666, 666]	0.2	0.7032	0.5844	0.6383
Down	Frec.	(2, 2)	2000	No	[3666, 1666, 666]	0	0.7273	0.5391	0.6192

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	H.L.	Drop	Preci.	Recall	F-score
Down	Frec.	(2, 2)	2000	Sí	[2000]	0.2	0.7203	0.4726	0.5707
Down	Frec.	(2, 2)	2000	Sí	[2000]	0	0.7023	0.4995	0.5838
Down	Frec.	(2, 2)	2000	Sí	[2000, 1000]	0.2	0.7247	0.4609	0.5634
Down	Frec.	(2, 2)	2000	Sí	[2000, 1000]	0	0.6984	0.5312	0.6034
Down	Frec.	(2, 2)	2000	Sí	[2000, 1000, 666]	0.2	0.7322	0.4729	0.5747
Down	Frec.	(2, 2)	2000	Sí	[2000, 1000, 666]	0	0.7264	0.4683	0.5694
Down	Frec.	(2, 2)	2000	Sí	[3000, 1000]	0.2	0.6729	0.5558	0.6088
Down	Frec.	(2, 2)	2000	Sí	[3000, 1000]	0	0.6518	0.5920	0.6204
Down	Frec.	(2, 2)	2000	Sí	[3666, 1666, 666]	0.2	0.6908	0.5413	0.6070
Down	Frec.	(2, 2)	2000	Sí	[3666, 1666, 666]	0	0.7029	0.5178	0.5963
Down	Frec.	(2, 2)	3000	No	[3000]	0.2	0.6461	0.6734	0.6595
Down	Frec.	(2, 2)	3000	No	[3000]	0	0.7098	0.5586	0.6252
Down	Frec.	(2, 2)	3000	No	[3000, 1500]	0.2	0.7095	0.6003	0.6503
Down	Frec.	(2, 2)	3000	No	[3000, 1500]	0	0.6680	0.6900	0.6788
Down	Frec.	(2, 2)	3000	No	[3000, 1500, 1000]	0.2	0.7436	0.5400	0.6256
Down	Frec.	(2, 2)	3000	No	[3000, 1500, 1000]	0	0.7605	0.5003	0.6036
Down	Frec.	(2, 2)	3000	No	[4500, 1500]	0.2	0.6972	0.6184	0.6555
Down	Frec.	(2, 2)	3000	No	[4500, 1500]	0	0.6966	0.6193	0.6556
Down	Frec.	(2, 2)	3000	No	[5500, 2500, 1000]	0.2	0.6846	0.6518	0.6678
Down	Frec.	(2, 2)	3000	No	[5500, 2500, 1000]	0	0.7467	0.5225	0.6148
Down	Frec.	(2, 2)	3000	Sí	[3000]	0.2	0.6804	0.5535	0.6104
Down	Frec.	(2, 2)	3000	Sí	[3000]	0	0.8036	0.3421	0.4799
Down	Frec.	(2, 2)	3000	Sí	[3000, 1500]	0.2	0.7513	0.4671	0.5761
Down	Frec.	(2, 2)	3000	Sí	[3000, 1500]	0	0.6825	0.5851	0.6300
Down	Frec.	(2, 2)	3000	Sí	[3000, 1500, 1000]	0.2	0.7554	0.4643	0.5751
Down	Frec.	(2, 2)	3000	Sí	[3000, 1500, 1000]	0	0.7198	0.5233	0.6060
Down	Frec.	(2, 2)	3000	Sí	[4500, 1500]	0.2	0.7305	0.4987	0.5927
Down	Frec.	(2, 2)	3000	Sí	[4500, 1500]	0	0.7464	0.4756	0.5810
Down	Frec.	(2, 2)	3000	Sí	[5500, 2500, 1000]	0.2	0.7122	0.5372	0.6124
Down	Frec.	(2, 2)	3000	Sí	[5500, 2500, 1000]	0	0.7680	0.4062	0.5313

Fin de la tabla

APÉNDICE B

Tabla comparativa de configuraciones de localización: máquina de vectores soporte

En esta búsqueda exhaustiva se han entrenado y evaluado 480 configuraciones.

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
No	Tf-Idf	(1, 1)	50	No	0.125	0.4836	0.0193	0.0371
No	Tf-Idf	(1, 1)	50	No	0.5	0.4816	0.0193	0.0371
No	Tf-Idf	(1, 1)	50	No	2	0.4816	0.0193	0.0371
No	Tf-Idf	(1, 1)	50	No	8	0.4816	0.0193	0.0371
No	Tf-Idf	(1, 1)	50	No	16	0.4816	0.0193	0.0371
No	Tf-Idf	(1, 1)	50	Sí	0.125	0.6353	0.0741	0.1327
No	Tf-Idf	(1, 1)	50	Sí	0.5	0.6336	0.0741	0.1327
No	Tf-Idf	(1, 1)	50	Sí	2	0.6336	0.0741	0.1327
No	Tf-Idf	(1, 1)	50	Sí	8	0.6336	0.0741	0.1327
No	Tf-Idf	(1, 1)	50	Sí	16	0.6336	0.0741	0.1327
No	Tf-Idf	(1, 1)	500	No	0.125	0.7306	0.2174	0.3351
No	Tf-Idf	(1, 1)	500	No	0.5	0.7295	0.2179	0.3356
No	Tf-Idf	(1, 1)	500	No	2	0.7302	0.2201	0.3382
No	Tf-Idf	(1, 1)	500	No	8	0.7302	0.2201	0.3382
No	Tf-Idf	(1, 1)	500	No	16	0.7302	0.2201	0.3382
No	Tf-Idf	(1, 1)	500	Sí	0.125	0.7339	0.2071	0.3231
No	Tf-Idf	(1, 1)	500	Sí	0.5	0.7331	0.2076	0.3236
No	Tf-Idf	(1, 1)	500	Sí	2	0.7331	0.2076	0.3236
No	Tf-Idf	(1, 1)	500	Sí	8	0.7331	0.2076	0.3236
No	Tf-Idf	(1, 1)	500	Sí	16	0.7331	0.2076	0.3236
No	Tf-Idf	(1, 1)	2000	No	0.125	0.7785	0.3830	0.5134
No	Tf-Idf	(1, 1)	2000	No	0.5	0.7779	0.3845	0.5146
No	Tf-Idf	(1, 1)	2000	No	2	0.7778	0.3848	0.5149
No	Tf-Idf	(1, 1)	2000	No	8	0.7776	0.3850	0.5150
No	Tf-Idf	(1, 1)	2000	No	16	0.7776	0.3850	0.5150
No	Tf-Idf	(1, 1)	2000	Sí	0.125	0.7752	0.3627	0.4942
No	Tf-Idf	(1, 1)	2000	Sí	0.5	0.7736	0.3657	0.4966
No	Tf-Idf	(1, 1)	2000	Sí	2	0.7739	0.3662	0.4971
No	Tf-Idf	(1, 1)	2000	Sí	8	0.7740	0.3665	0.4974
No	Tf-Idf	(1, 1)	2000	Sí	16	0.7740	0.3665	0.4974

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
No	Tf-Idf	(1, 1)	3000	No	0.125	0.7679	0.4342	0.5548
No	Tf-Idf	(1, 1)	3000	No	0.5	0.7650	0.4368	0.5561
No	Tf-Idf	(1, 1)	3000	No	2	0.7642	0.4373	0.5563
No	Tf-Idf	(1, 1)	3000	No	8	0.7642	0.4373	0.5563
No	Tf-Idf	(1, 1)	3000	No	16	0.7642	0.4373	0.5563
No	Tf-Idf	(1, 1)	3000	Sí	0.125	0.7655	0.4210	0.5432
No	Tf-Idf	(1, 1)	3000	Sí	0.5	0.7612	0.4236	0.5443
No	Tf-Idf	(1, 1)	3000	Sí	2	0.7606	0.4241	0.5445
No	Tf-Idf	(1, 1)	3000	Sí	8	0.7604	0.4242	0.5446
No	Tf-Idf	(1, 1)	3000	Sí	16	0.7604	0.4242	0.5446
No	Tf-Idf	(1, 2)	50	No	0.125	0.0000	0.0000	0.0000
No	Tf-Idf	(1, 2)	50	No	0.5	0.0000	0.0000	0.0000
No	Tf-Idf	(1, 2)	50	No	2	0.0000	0.0000	0.0000
No	Tf-Idf	(1, 2)	50	No	8	0.0000	0.0000	0.0000
No	Tf-Idf	(1, 2)	50	No	16	0.0000	0.0000	0.0000
No	Tf-Idf	(1, 2)	50	Sí	0.125	0.6342	0.0735	0.1317
No	Tf-Idf	(1, 2)	50	Sí	0.5	0.6324	0.0735	0.1316
No	Tf-Idf	(1, 2)	50	Sí	2	0.6324	0.0735	0.1316
No	Tf-Idf	(1, 2)	50	Sí	8	0.6324	0.0735	0.1316
No	Tf-Idf	(1, 2)	50	Sí	16	0.6324	0.0735	0.1316
No	Tf-Idf	(1, 2)	500	No	0.125	0.6966	0.1713	0.2750
No	Tf-Idf	(1, 2)	500	No	0.5	0.6958	0.1721	0.2760
No	Tf-Idf	(1, 2)	500	No	2	0.6955	0.1726	0.2766
No	Tf-Idf	(1, 2)	500	No	8	0.6955	0.1726	0.2766
No	Tf-Idf	(1, 2)	500	No	16	0.6955	0.1726	0.2766
No	Tf-Idf	(1, 2)	500	Sí	0.125	0.7253	0.2039	0.3183
No	Tf-Idf	(1, 2)	500	Sí	0.5	0.7252	0.2042	0.3187
No	Tf-Idf	(1, 2)	500	Sí	2	0.7256	0.2047	0.3193
No	Tf-Idf	(1, 2)	500	Sí	8	0.7252	0.2047	0.3193
No	Tf-Idf	(1, 2)	500	Sí	16	0.7252	0.2047	0.3193
No	Tf-Idf	(1, 2)	2000	No	0.125	0.7513	0.3534	0.4807
No	Tf-Idf	(1, 2)	2000	No	0.5	0.7500	0.3549	0.4818
No	Tf-Idf	(1, 2)	2000	No	2	0.7495	0.3554	0.4821
No	Tf-Idf	(1, 2)	2000	No	8	0.7492	0.3554	0.4821
No	Tf-Idf	(1, 2)	2000	No	16	0.7492	0.3554	0.4821
No	Tf-Idf	(1, 2)	2000	Sí	0.125	0.7639	0.3541	0.4838
No	Tf-Idf	(1, 2)	2000	Sí	0.5	0.7632	0.3554	0.4849
No	Tf-Idf	(1, 2)	2000	Sí	2	0.7632	0.3559	0.4854
No	Tf-Idf	(1, 2)	2000	Sí	8	0.7625	0.3562	0.4856
No	Tf-Idf	(1, 2)	2000	Sí	16	0.7625	0.3562	0.4856
No	Tf-Idf	(1, 2)	3000	No	0.125	0.7523	0.4005	0.5227
No	Tf-Idf	(1, 2)	3000	No	0.5	0.7475	0.4020	0.5228
No	Tf-Idf	(1, 2)	3000	No	2	0.7472	0.4023	0.5230
No	Tf-Idf	(1, 2)	3000	No	8	0.7473	0.4025	0.5232
No	Tf-Idf	(1, 2)	3000	No	16	0.7473	0.4027	0.5233
No	Tf-Idf	(1, 2)	3000	Sí	0.125	0.7642	0.4015	0.5264
No	Tf-Idf	(1, 2)	3000	Sí	0.5	0.7627	0.4043	0.5284
No	Tf-Idf	(1, 2)	3000	Sí	2	0.7622	0.4048	0.5287
No	Tf-Idf	(1, 2)	3000	Sí	8	0.7624	0.4053	0.5292
No	Tf-Idf	(1, 2)	3000	Sí	16	0.7625	0.4054	0.5294

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
No	Tf-Idf	(2, 2)	50	No	0.125	0.5000	0.0002	0.0003
No	Tf-Idf	(2, 2)	50	No	0.5	0.5000	0.0002	0.0003
No	Tf-Idf	(2, 2)	50	No	2	0.5000	0.0002	0.0003
No	Tf-Idf	(2, 2)	50	No	8	0.5000	0.0002	0.0003
No	Tf-Idf	(2, 2)	50	No	16	0.5000	0.0002	0.0003
No	Tf-Idf	(2, 2)	50	Sí	0.125	0.6027	0.0221	0.0426
No	Tf-Idf	(2, 2)	50	Sí	0.5	0.6027	0.0221	0.0426
No	Tf-Idf	(2, 2)	50	Sí	2	0.6027	0.0221	0.0426
No	Tf-Idf	(2, 2)	50	Sí	8	0.6027	0.0221	0.0426
No	Tf-Idf	(2, 2)	50	Sí	16	0.6027	0.0221	0.0426
No	Tf-Idf	(2, 2)	500	No	0.125	0.6646	0.0869	0.1537
No	Tf-Idf	(2, 2)	500	No	0.5	0.6634	0.0874	0.1544
No	Tf-Idf	(2, 2)	500	No	2	0.6634	0.0874	0.1544
No	Tf-Idf	(2, 2)	500	No	8	0.6634	0.0874	0.1544
No	Tf-Idf	(2, 2)	500	No	16	0.6634	0.0874	0.1544
No	Tf-Idf	(2, 2)	500	Sí	0.125	0.7239	0.1111	0.1926
No	Tf-Idf	(2, 2)	500	Sí	0.5	0.7268	0.1114	0.1932
No	Tf-Idf	(2, 2)	500	Sí	2	0.7265	0.1113	0.1930
No	Tf-Idf	(2, 2)	500	Sí	8	0.7257	0.1113	0.1929
No	Tf-Idf	(2, 2)	500	Sí	16	0.7257	0.1113	0.1929
No	Tf-Idf	(2, 2)	2000	No	0.125	0.7356	0.2235	0.3428
No	Tf-Idf	(2, 2)	2000	No	0.5	0.7348	0.2253	0.3449
No	Tf-Idf	(2, 2)	2000	No	2	0.7338	0.2255	0.3449
No	Tf-Idf	(2, 2)	2000	No	8	0.7330	0.2255	0.3448
No	Tf-Idf	(2, 2)	2000	No	16	0.7326	0.2255	0.3448
No	Tf-Idf	(2, 2)	2000	Sí	0.125	0.7436	0.1993	0.3143
No	Tf-Idf	(2, 2)	2000	Sí	0.5	0.7411	0.1986	0.3133
No	Tf-Idf	(2, 2)	2000	Sí	2	0.7396	0.1985	0.3130
No	Tf-Idf	(2, 2)	2000	Sí	8	0.7384	0.1986	0.3130
No	Tf-Idf	(2, 2)	2000	Sí	16	0.7384	0.1986	0.3130
No	Tf-Idf	(2, 2)	3000	No	0.125	0.7218	0.2726	0.3957
No	Tf-Idf	(2, 2)	3000	No	0.5	0.7201	0.2736	0.3965
No	Tf-Idf	(2, 2)	3000	No	2	0.7186	0.2737	0.3964
No	Tf-Idf	(2, 2)	3000	No	8	0.7186	0.2737	0.3964
No	Tf-Idf	(2, 2)	3000	No	16	0.7186	0.2737	0.3964
No	Tf-Idf	(2, 2)	3000	Sí	0.125	0.7356	0.2253	0.3449
No	Tf-Idf	(2, 2)	3000	Sí	0.5	0.7297	0.2274	0.3468
No	Tf-Idf	(2, 2)	3000	Sí	2	0.7286	0.2279	0.3472
No	Tf-Idf	(2, 2)	3000	Sí	8	0.7280	0.2286	0.3479
No	Tf-Idf	(2, 2)	3000	Sí	16	0.7276	0.2286	0.3479
No	Frec.	(1, 1)	50	No	0.125	0.5837	0.0211	0.0407
No	Frec.	(1, 1)	50	No	0.5	0.5837	0.0211	0.0407
No	Frec.	(1, 1)	50	No	2	0.5837	0.0211	0.0407
No	Frec.	(1, 1)	50	No	8	0.5837	0.0211	0.0407
No	Frec.	(1, 1)	50	No	16	0.5837	0.0211	0.0407
No	Frec.	(1, 1)	50	Sí	0.125	0.6199	0.0766	0.1363
No	Frec.	(1, 1)	50	Sí	0.5	0.6179	0.0767	0.1365
No	Frec.	(1, 1)	50	Sí	2	0.6179	0.0767	0.1365
No	Frec.	(1, 1)	50	Sí	8	0.6179	0.0767	0.1365
No	Frec.	(1, 1)	50	Sí	16	0.6179	0.0767	0.1365

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
No	Frec.	(1, 1)	500	No	0.125	0.7408	0.2184	0.3374
No	Frec.	(1, 1)	500	No	0.5	0.7388	0.2189	0.3378
No	Frec.	(1, 1)	500	No	2	0.7387	0.2192	0.3381
No	Frec.	(1, 1)	500	No	8	0.7388	0.2194	0.3383
No	Frec.	(1, 1)	500	No	16	0.7388	0.2194	0.3383
No	Frec.	(1, 1)	500	Sí	0.125	0.7397	0.2083	0.3250
No	Frec.	(1, 1)	500	Sí	0.5	0.7387	0.2086	0.3253
No	Frec.	(1, 1)	500	Sí	2	0.7380	0.2088	0.3255
No	Frec.	(1, 1)	500	Sí	8	0.7380	0.2088	0.3255
No	Frec.	(1, 1)	500	Sí	16	0.7380	0.2088	0.3255
No	Frec.	(1, 1)	2000	No	0.125	0.7808	0.3776	0.5090
No	Frec.	(1, 1)	2000	No	0.5	0.7776	0.3786	0.5092
No	Frec.	(1, 1)	2000	No	2	0.7767	0.3791	0.5095
No	Frec.	(1, 1)	2000	No	8	0.7765	0.3793	0.5096
No	Frec.	(1, 1)	2000	No	16	0.7763	0.3793	0.5096
No	Frec.	(1, 1)	2000	Sí	0.125	0.7828	0.3609	0.4941
No	Frec.	(1, 1)	2000	Sí	0.5	0.7795	0.3621	0.4945
No	Frec.	(1, 1)	2000	Sí	2	0.7793	0.3622	0.4946
No	Frec.	(1, 1)	2000	Sí	8	0.7791	0.3624	0.4947
No	Frec.	(1, 1)	2000	Sí	16	0.7791	0.3624	0.4947
No	Frec.	(1, 1)	3000	No	0.125	0.7771	0.4256	0.5500
No	Frec.	(1, 1)	3000	No	0.5	0.7725	0.4267	0.5497
No	Frec.	(1, 1)	3000	No	2	0.7713	0.4272	0.5499
No	Frec.	(1, 1)	3000	No	8	0.7713	0.4272	0.5499
No	Frec.	(1, 1)	3000	No	16	0.7713	0.4272	0.5499
No	Frec.	(1, 1)	3000	Sí	0.125	0.7692	0.4067	0.5321
No	Frec.	(1, 1)	3000	Sí	0.5	0.7656	0.4072	0.5317
No	Frec.	(1, 1)	3000	Sí	2	0.7642	0.4072	0.5313
No	Frec.	(1, 1)	3000	Sí	8	0.7643	0.4076	0.5316
No	Frec.	(1, 1)	3000	Sí	16	0.7644	0.4077	0.5318
No	Frec.	(1, 2)	50	No	0.125	0.3000	0.0005	0.0010
No	Frec.	(1, 2)	50	No	0.5	0.3000	0.0005	0.0010
No	Frec.	(1, 2)	50	No	2	0.3000	0.0005	0.0010
No	Frec.	(1, 2)	50	No	8	0.3000	0.0005	0.0010
No	Frec.	(1, 2)	50	No	16	0.3000	0.0005	0.0010
No	Frec.	(1, 2)	50	Sí	0.125	0.6190	0.0744	0.1329
No	Frec.	(1, 2)	50	Sí	0.5	0.6171	0.0746	0.1331
No	Frec.	(1, 2)	50	Sí	2	0.6171	0.0746	0.1331
No	Frec.	(1, 2)	50	Sí	8	0.6171	0.0746	0.1331
No	Frec.	(1, 2)	50	Sí	16	0.6171	0.0746	0.1331
No	Frec.	(1, 2)	500	No	0.125	0.6945	0.1744	0.2788
No	Frec.	(1, 2)	500	No	0.5	0.6933	0.1746	0.2789
No	Frec.	(1, 2)	500	No	2	0.6937	0.1749	0.2794
No	Frec.	(1, 2)	500	No	8	0.6937	0.1749	0.2794
No	Frec.	(1, 2)	500	No	16	0.6939	0.1751	0.2796
No	Frec.	(1, 2)	500	Sí	0.125	0.7359	0.2052	0.3209
No	Frec.	(1, 2)	500	Sí	0.5	0.7356	0.2062	0.3220
No	Frec.	(1, 2)	500	Sí	2	0.7363	0.2065	0.3225
No	Frec.	(1, 2)	500	Sí	8	0.7356	0.2066	0.3226
No	Frec.	(1, 2)	500	Sí	16	0.7352	0.2066	0.3226

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
No	Frec.	(1, 2)	2000	No	0.125	0.7623	0.3457	0.4757
No	Frec.	(1, 2)	2000	No	0.5	0.7601	0.3483	0.4777
No	Frec.	(1, 2)	2000	No	2	0.7598	0.3488	0.4781
No	Frec.	(1, 2)	2000	No	8	0.7593	0.3488	0.4780
No	Frec.	(1, 2)	2000	No	16	0.7593	0.3488	0.4780
No	Frec.	(1, 2)	2000	Sí	0.125	0.7758	0.3521	0.4844
No	Frec.	(1, 2)	2000	Sí	0.5	0.7731	0.3534	0.4851
No	Frec.	(1, 2)	2000	Sí	2	0.7727	0.3544	0.4859
No	Frec.	(1, 2)	2000	Sí	8	0.7727	0.3544	0.4859
No	Frec.	(1, 2)	2000	Sí	16	0.7725	0.3544	0.4859
No	Frec.	(1, 2)	3000	No	0.125	0.7579	0.4010	0.5245
No	Frec.	(1, 2)	3000	No	0.5	0.7515	0.4022	0.5239
No	Frec.	(1, 2)	3000	No	2	0.7506	0.4023	0.5239
No	Frec.	(1, 2)	3000	No	8	0.7506	0.4028	0.5243
No	Frec.	(1, 2)	3000	No	16	0.7506	0.4028	0.5243
No	Frec.	(1, 2)	3000	Sí	0.125	0.7731	0.3953	0.5231
No	Frec.	(1, 2)	3000	Sí	0.5	0.7692	0.3964	0.5232
No	Frec.	(1, 2)	3000	Sí	2	0.7676	0.3966	0.5230
No	Frec.	(1, 2)	3000	Sí	8	0.7674	0.3968	0.5231
No	Frec.	(1, 2)	3000	Sí	16	0.7675	0.3969	0.5232
No	Frec.	(2, 2)	50	No	0.125	0.5000	0.0023	0.0046
No	Frec.	(2, 2)	50	No	0.5	0.5172	0.0025	0.0049
No	Frec.	(2, 2)	50	No	2	0.5312	0.0028	0.0055
No	Frec.	(2, 2)	50	No	8	0.5312	0.0028	0.0055
No	Frec.	(2, 2)	50	No	16	0.5312	0.0028	0.0055
No	Frec.	(2, 2)	50	Sí	0.125	0.5778	0.0298	0.0566
No	Frec.	(2, 2)	50	Sí	0.5	0.5778	0.0298	0.0566
No	Frec.	(2, 2)	50	Sí	2	0.5778	0.0298	0.0566
No	Frec.	(2, 2)	50	Sí	8	0.5778	0.0298	0.0566
No	Frec.	(2, 2)	50	Sí	16	0.5778	0.0298	0.0566
No	Frec.	(2, 2)	500	No	0.125	0.6534	0.1024	0.1771
No	Frec.	(2, 2)	500	No	0.5	0.6538	0.1026	0.1773
No	Frec.	(2, 2)	500	No	2	0.6535	0.1027	0.1776
No	Frec.	(2, 2)	500	No	8	0.6538	0.1029	0.1778
No	Frec.	(2, 2)	500	No	16	0.6538	0.1029	0.1778
No	Frec.	(2, 2)	500	Sí	0.125	0.7106	0.1113	0.1924
No	Frec.	(2, 2)	500	Sí	0.5	0.7091	0.1113	0.1923
No	Frec.	(2, 2)	500	Sí	2	0.7091	0.1113	0.1923
No	Frec.	(2, 2)	500	Sí	8	0.7091	0.1113	0.1923
No	Frec.	(2, 2)	500	Sí	16	0.7091	0.1113	0.1923
No	Frec.	(2, 2)	2000	No	0.125	0.7138	0.2223	0.3391
No	Frec.	(2, 2)	2000	No	0.5	0.7118	0.2238	0.3406
No	Frec.	(2, 2)	2000	No	2	0.7113	0.2241	0.3409
No	Frec.	(2, 2)	2000	No	8	0.7109	0.2241	0.3408
No	Frec.	(2, 2)	2000	No	16	0.7106	0.2241	0.3408
No	Frec.	(2, 2)	2000	Sí	0.125	0.7443	0.1924	0.3058
No	Frec.	(2, 2)	2000	Sí	0.5	0.7324	0.1944	0.3072
No	Frec.	(2, 2)	2000	Sí	2	0.7301	0.1952	0.3080
No	Frec.	(2, 2)	2000	Sí	8	0.7297	0.1952	0.3080
No	Frec.	(2, 2)	2000	Sí	16	0.7291	0.1955	0.3083

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
No	Frec.	(2, 2)	3000	No	0.125	0.7227	0.2737	0.3971
No	Frec.	(2, 2)	3000	No	0.5	0.7179	0.2749	0.3975
No	Frec.	(2, 2)	3000	No	2	0.7168	0.2750	0.3975
No	Frec.	(2, 2)	3000	No	8	0.7164	0.2752	0.3976
No	Frec.	(2, 2)	3000	No	16	0.7164	0.2752	0.3976
No	Frec.	(2, 2)	3000	Sí	0.125	0.7339	0.2215	0.3403
No	Frec.	(2, 2)	3000	Sí	0.5	0.7267	0.2237	0.3420
No	Frec.	(2, 2)	3000	Sí	2	0.7248	0.2232	0.3413
No	Frec.	(2, 2)	3000	Sí	8	0.7251	0.2232	0.3413
No	Frec.	(2, 2)	3000	Sí	16	0.7251	0.2232	0.3413
Down	Tf-Idf	(1, 1)	50	No	0.125	0.6262	0.5472	0.5840
Down	Tf-Idf	(1, 1)	50	No	0.5	0.6260	0.5478	0.5843
Down	Tf-Idf	(1, 1)	50	No	2	0.6260	0.5478	0.5843
Down	Tf-Idf	(1, 1)	50	No	8	0.6258	0.5476	0.5841
Down	Tf-Idf	(1, 1)	50	No	16	0.6258	0.5476	0.5841
Down	Tf-Idf	(1, 1)	50	Sí	0.125	0.6467	0.5379	0.5873
Down	Tf-Idf	(1, 1)	50	Sí	0.5	0.6467	0.5377	0.5872
Down	Tf-Idf	(1, 1)	50	Sí	2	0.6467	0.5377	0.5872
Down	Tf-Idf	(1, 1)	50	Sí	8	0.6467	0.5377	0.5872
Down	Tf-Idf	(1, 1)	50	Sí	16	0.6467	0.5377	0.5872
Down	Tf-Idf	(1, 1)	500	No	0.125	0.7229	0.6535	0.6864
Down	Tf-Idf	(1, 1)	500	No	0.5	0.7229	0.6535	0.6864
Down	Tf-Idf	(1, 1)	500	No	2	0.7227	0.6535	0.6864
Down	Tf-Idf	(1, 1)	500	No	8	0.7227	0.6533	0.6863
Down	Tf-Idf	(1, 1)	500	No	16	0.7227	0.6533	0.6863
Down	Tf-Idf	(1, 1)	500	Sí	0.125	0.7188	0.6446	0.6797
Down	Tf-Idf	(1, 1)	500	Sí	0.5	0.7188	0.6451	0.6800
Down	Tf-Idf	(1, 1)	500	Sí	2	0.7188	0.6449	0.6798
Down	Tf-Idf	(1, 1)	500	Sí	8	0.7188	0.6449	0.6798
Down	Tf-Idf	(1, 1)	500	Sí	16	0.7188	0.6449	0.6798
Down	Tf-Idf	(1, 1)	2000	No	0.125	0.7595	0.7113	0.7346
Down	Tf-Idf	(1, 1)	2000	No	0.5	0.7589	0.7111	0.7342
Down	Tf-Idf	(1, 1)	2000	No	2	0.7587	0.7118	0.7345
Down	Tf-Idf	(1, 1)	2000	No	8	0.7585	0.7118	0.7344
Down	Tf-Idf	(1, 1)	2000	No	16	0.7584	0.7118	0.7344
Down	Tf-Idf	(1, 1)	2000	Sí	0.125	0.7493	0.6994	0.7235
Down	Tf-Idf	(1, 1)	2000	Sí	0.5	0.7481	0.6986	0.7225
Down	Tf-Idf	(1, 1)	2000	Sí	2	0.7481	0.6986	0.7225
Down	Tf-Idf	(1, 1)	2000	Sí	8	0.7482	0.6988	0.7226
Down	Tf-Idf	(1, 1)	2000	Sí	16	0.7482	0.6988	0.7226
Down	Tf-Idf	(1, 1)	3000	No	0.125	0.7628	0.7283	0.7452
Down	Tf-Idf	(1, 1)	3000	No	0.5	0.7607	0.7278	0.7439
Down	Tf-Idf	(1, 1)	3000	No	2	0.7614	0.7280	0.7443
Down	Tf-Idf	(1, 1)	3000	No	8	0.7613	0.7278	0.7442
Down	Tf-Idf	(1, 1)	3000	No	16	0.7614	0.7278	0.7442
Down	Tf-Idf	(1, 1)	3000	Sí	0.125	0.7566	0.7214	0.7386
Down	Tf-Idf	(1, 1)	3000	Sí	0.5	0.7560	0.7220	0.7386
Down	Tf-Idf	(1, 1)	3000	Sí	2	0.7554	0.7222	0.7384
Down	Tf-Idf	(1, 1)	3000	Sí	8	0.7555	0.7222	0.7385
Down	Tf-Idf	(1, 1)	3000	Sí	16	0.7554	0.7222	0.7384

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
Down	Tf-Idf	(1, 2)	50	No	0.125	0.6127	0.5656	0.5882
Down	Tf-Idf	(1, 2)	50	No	0.5	0.6126	0.5656	0.5882
Down	Tf-Idf	(1, 2)	50	No	2	0.6122	0.5655	0.5879
Down	Tf-Idf	(1, 2)	50	No	8	0.6119	0.5653	0.5877
Down	Tf-Idf	(1, 2)	50	No	16	0.6119	0.5653	0.5877
Down	Tf-Idf	(1, 2)	50	Sí	0.125	0.6382	0.5434	0.5870
Down	Tf-Idf	(1, 2)	50	Sí	0.5	0.6383	0.5434	0.5870
Down	Tf-Idf	(1, 2)	50	Sí	2	0.6383	0.5435	0.5871
Down	Tf-Idf	(1, 2)	50	Sí	8	0.6383	0.5435	0.5871
Down	Tf-Idf	(1, 2)	50	Sí	16	0.6383	0.5435	0.5871
Down	Tf-Idf	(1, 2)	500	No	0.125	0.7095	0.6408	0.6734
Down	Tf-Idf	(1, 2)	500	No	0.5	0.7096	0.6408	0.6734
Down	Tf-Idf	(1, 2)	500	No	2	0.7093	0.6403	0.6730
Down	Tf-Idf	(1, 2)	500	No	8	0.7093	0.6403	0.6730
Down	Tf-Idf	(1, 2)	500	No	16	0.7092	0.6403	0.6730
Down	Tf-Idf	(1, 2)	500	Sí	0.125	0.7209	0.6276	0.6710
Down	Tf-Idf	(1, 2)	500	Sí	0.5	0.7202	0.6276	0.6707
Down	Tf-Idf	(1, 2)	500	Sí	2	0.7199	0.6274	0.6705
Down	Tf-Idf	(1, 2)	500	Sí	8	0.7201	0.6271	0.6704
Down	Tf-Idf	(1, 2)	500	Sí	16	0.7199	0.6271	0.6703
Down	Tf-Idf	(1, 2)	2000	No	0.125	0.7470	0.6887	0.7167
Down	Tf-Idf	(1, 2)	2000	No	0.5	0.7467	0.6900	0.7173
Down	Tf-Idf	(1, 2)	2000	No	2	0.7463	0.6903	0.7172
Down	Tf-Idf	(1, 2)	2000	No	8	0.7461	0.6900	0.7169
Down	Tf-Idf	(1, 2)	2000	No	16	0.7462	0.6900	0.7170
Down	Tf-Idf	(1, 2)	2000	Sí	0.125	0.7487	0.6849	0.7154
Down	Tf-Idf	(1, 2)	2000	Sí	0.5	0.7470	0.6836	0.7139
Down	Tf-Idf	(1, 2)	2000	Sí	2	0.7465	0.6839	0.7138
Down	Tf-Idf	(1, 2)	2000	Sí	8	0.7467	0.6844	0.7142
Down	Tf-Idf	(1, 2)	2000	Sí	16	0.7467	0.6846	0.7143
Down	Tf-Idf	(1, 2)	3000	No	0.125	0.7470	0.7052	0.7255
Down	Tf-Idf	(1, 2)	3000	No	0.5	0.7471	0.7049	0.7254
Down	Tf-Idf	(1, 2)	3000	No	2	0.7464	0.7049	0.7250
Down	Tf-Idf	(1, 2)	3000	No	8	0.7464	0.7054	0.7253
Down	Tf-Idf	(1, 2)	3000	No	16	0.7464	0.7054	0.7253
Down	Tf-Idf	(1, 2)	3000	Sí	0.125	0.7565	0.7077	0.7313
Down	Tf-Idf	(1, 2)	3000	Sí	0.5	0.7549	0.7065	0.7299
Down	Tf-Idf	(1, 2)	3000	Sí	2	0.7542	0.7064	0.7295
Down	Tf-Idf	(1, 2)	3000	Sí	8	0.7541	0.7060	0.7293
Down	Tf-Idf	(1, 2)	3000	Sí	16	0.7540	0.7062	0.7293
Down	Tf-Idf	(2, 2)	50	No	0.125	0.5938	0.5039	0.5452
Down	Tf-Idf	(2, 2)	50	No	0.5	0.5937	0.5040	0.5452
Down	Tf-Idf	(2, 2)	50	No	2	0.5937	0.5040	0.5452
Down	Tf-Idf	(2, 2)	50	No	8	0.5937	0.5040	0.5452
Down	Tf-Idf	(2, 2)	50	No	16	0.5937	0.5040	0.5452
Down	Tf-Idf	(2, 2)	50	Sí	0.125	0.6212	0.4263	0.5056
Down	Tf-Idf	(2, 2)	50	Sí	0.5	0.6212	0.4263	0.5056
Down	Tf-Idf	(2, 2)	50	Sí	2	0.6212	0.4263	0.5056
Down	Tf-Idf	(2, 2)	50	Sí	8	0.6212	0.4263	0.5056
Down	Tf-Idf	(2, 2)	50	Sí	16	0.6212	0.4263	0.5056

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
Down	Tf-Idf	(2, 2)	500	No	0.125	0.6608	0.5417	0.5953
Down	Tf-Idf	(2, 2)	500	No	0.5	0.6600	0.5422	0.5953
Down	Tf-Idf	(2, 2)	500	No	2	0.6601	0.5424	0.5955
Down	Tf-Idf	(2, 2)	500	No	8	0.6601	0.5424	0.5955
Down	Tf-Idf	(2, 2)	500	No	16	0.6601	0.5424	0.5955
Down	Tf-Idf	(2, 2)	500	Sí	0.125	0.6772	0.4699	0.5548
Down	Tf-Idf	(2, 2)	500	Sí	0.5	0.6774	0.4707	0.5554
Down	Tf-Idf	(2, 2)	500	Sí	2	0.6775	0.4712	0.5558
Down	Tf-Idf	(2, 2)	500	Sí	8	0.6775	0.4709	0.5556
Down	Tf-Idf	(2, 2)	500	Sí	16	0.6775	0.4709	0.5556
Down	Tf-Idf	(2, 2)	2000	No	0.125	0.7001	0.6012	0.6469
Down	Tf-Idf	(2, 2)	2000	No	0.5	0.6994	0.6030	0.6476
Down	Tf-Idf	(2, 2)	2000	No	2	0.6986	0.6026	0.6471
Down	Tf-Idf	(2, 2)	2000	No	8	0.6986	0.6025	0.6470
Down	Tf-Idf	(2, 2)	2000	No	16	0.6984	0.6025	0.6469
Down	Tf-Idf	(2, 2)	2000	Sí	0.125	0.7193	0.4862	0.5802
Down	Tf-Idf	(2, 2)	2000	Sí	0.5	0.7172	0.4867	0.5799
Down	Tf-Idf	(2, 2)	2000	Sí	2	0.7172	0.4870	0.5801
Down	Tf-Idf	(2, 2)	2000	Sí	8	0.7172	0.4870	0.5801
Down	Tf-Idf	(2, 2)	2000	Sí	16	0.7172	0.4870	0.5801
Down	Tf-Idf	(2, 2)	3000	No	0.125	0.6997	0.6152	0.6547
Down	Tf-Idf	(2, 2)	3000	No	0.5	0.6995	0.6170	0.6557
Down	Tf-Idf	(2, 2)	3000	No	2	0.6996	0.6173	0.6559
Down	Tf-Idf	(2, 2)	3000	No	8	0.6993	0.6173	0.6558
Down	Tf-Idf	(2, 2)	3000	No	16	0.6992	0.6170	0.6556
Down	Tf-Idf	(2, 2)	3000	Sí	0.125	0.7219	0.4981	0.5895
Down	Tf-Idf	(2, 2)	3000	Sí	0.5	0.7192	0.4993	0.5894
Down	Tf-Idf	(2, 2)	3000	Sí	2	0.7188	0.4999	0.5897
Down	Tf-Idf	(2, 2)	3000	Sí	8	0.7188	0.5002	0.5899
Down	Tf-Idf	(2, 2)	3000	Sí	16	0.7188	0.5002	0.5899
Down	Frec.	(1, 1)	50	No	0.125	0.6390	0.5029	0.5628
Down	Frec.	(1, 1)	50	No	0.5	0.6386	0.5027	0.5626
Down	Frec.	(1, 1)	50	No	2	0.6386	0.5027	0.5626
Down	Frec.	(1, 1)	50	No	8	0.6386	0.5027	0.5626
Down	Frec.	(1, 1)	50	No	16	0.6386	0.5027	0.5626
Down	Frec.	(1, 1)	50	Sí	0.125	0.6535	0.5282	0.5842
Down	Frec.	(1, 1)	50	Sí	0.5	0.6538	0.5280	0.5842
Down	Frec.	(1, 1)	50	Sí	2	0.6539	0.5280	0.5842
Down	Frec.	(1, 1)	50	Sí	8	0.6539	0.5280	0.5842
Down	Frec.	(1, 1)	50	Sí	16	0.6539	0.5280	0.5842
Down	Frec.	(1, 1)	500	No	0.125	0.7367	0.6263	0.6770
Down	Frec.	(1, 1)	500	No	0.5	0.7363	0.6258	0.6765
Down	Frec.	(1, 1)	500	No	2	0.7362	0.6259	0.6766
Down	Frec.	(1, 1)	500	No	8	0.7362	0.6258	0.6765
Down	Frec.	(1, 1)	500	No	16	0.7362	0.6258	0.6765
Down	Frec.	(1, 1)	500	Sí	0.125	0.7419	0.6149	0.6724
Down	Frec.	(1, 1)	500	Sí	0.5	0.7409	0.6150	0.6721
Down	Frec.	(1, 1)	500	Sí	2	0.7405	0.6150	0.6720
Down	Frec.	(1, 1)	500	Sí	8	0.7406	0.6152	0.6721
Down	Frec.	(1, 1)	500	Sí	16	0.7406	0.6152	0.6721

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
Down	Frec.	(1, 1)	2000	No	0.125	0.7708	0.6943	0.7306
Down	Frec.	(1, 1)	2000	No	0.5	0.7694	0.6958	0.7307
Down	Frec.	(1, 1)	2000	No	2	0.7691	0.6963	0.7309
Down	Frec.	(1, 1)	2000	No	8	0.7689	0.6963	0.7308
Down	Frec.	(1, 1)	2000	No	16	0.7689	0.6963	0.7308
Down	Frec.	(1, 1)	2000	Sí	0.125	0.7622	0.6811	0.7193
Down	Frec.	(1, 1)	2000	Sí	0.5	0.7617	0.6819	0.7196
Down	Frec.	(1, 1)	2000	Sí	2	0.7613	0.6818	0.7194
Down	Frec.	(1, 1)	2000	Sí	8	0.7612	0.6819	0.7194
Down	Frec.	(1, 1)	2000	Sí	16	0.7612	0.6819	0.7194
Down	Frec.	(1, 1)	3000	No	0.125	0.7671	0.7181	0.7418
Down	Frec.	(1, 1)	3000	No	0.5	0.7657	0.7184	0.7413
Down	Frec.	(1, 1)	3000	No	2	0.7652	0.7184	0.7411
Down	Frec.	(1, 1)	3000	No	8	0.7655	0.7181	0.7410
Down	Frec.	(1, 1)	3000	No	16	0.7655	0.7181	0.7410
Down	Frec.	(1, 1)	3000	Sí	0.125	0.7618	0.7121	0.7362
Down	Frec.	(1, 1)	3000	Sí	0.5	0.7602	0.7120	0.7353
Down	Frec.	(1, 1)	3000	Sí	2	0.7592	0.7116	0.7346
Down	Frec.	(1, 1)	3000	Sí	8	0.7593	0.7116	0.7347
Down	Frec.	(1, 1)	3000	Sí	16	0.7593	0.7116	0.7347
Down	Frec.	(1, 2)	50	No	0.125	0.6252	0.4966	0.5535
Down	Frec.	(1, 2)	50	No	0.5	0.6259	0.4974	0.5543
Down	Frec.	(1, 2)	50	No	2	0.6260	0.4981	0.5548
Down	Frec.	(1, 2)	50	No	8	0.6260	0.4981	0.5548
Down	Frec.	(1, 2)	50	No	16	0.6260	0.4981	0.5548
Down	Frec.	(1, 2)	50	Sí	0.125	0.6449	0.5245	0.5785
Down	Frec.	(1, 2)	50	Sí	0.5	0.6449	0.5245	0.5785
Down	Frec.	(1, 2)	50	Sí	2	0.6449	0.5245	0.5785
Down	Frec.	(1, 2)	50	Sí	8	0.6449	0.5245	0.5785
Down	Frec.	(1, 2)	50	Sí	16	0.6449	0.5245	0.5785
Down	Frec.	(1, 2)	500	No	0.125	0.7238	0.6114	0.6628
Down	Frec.	(1, 2)	500	No	0.5	0.7231	0.6116	0.6627
Down	Frec.	(1, 2)	500	No	2	0.7235	0.6121	0.6631
Down	Frec.	(1, 2)	500	No	8	0.7236	0.6122	0.6633
Down	Frec.	(1, 2)	500	No	16	0.7236	0.6122	0.6633
Down	Frec.	(1, 2)	500	Sí	0.125	0.7388	0.6041	0.6647
Down	Frec.	(1, 2)	500	Sí	0.5	0.7384	0.6038	0.6644
Down	Frec.	(1, 2)	500	Sí	2	0.7385	0.6036	0.6643
Down	Frec.	(1, 2)	500	Sí	8	0.7383	0.6035	0.6641
Down	Frec.	(1, 2)	500	Sí	16	0.7382	0.6035	0.6641
Down	Frec.	(1, 2)	2000	No	0.125	0.7589	0.6690	0.7111
Down	Frec.	(1, 2)	2000	No	0.5	0.7577	0.6718	0.7122
Down	Frec.	(1, 2)	2000	No	2	0.7570	0.6709	0.7113
Down	Frec.	(1, 2)	2000	No	8	0.7569	0.6710	0.7114
Down	Frec.	(1, 2)	2000	No	16	0.7568	0.6712	0.7114
Down	Frec.	(1, 2)	2000	Sí	0.125	0.7615	0.6677	0.7115
Down	Frec.	(1, 2)	2000	Sí	0.5	0.7603	0.6675	0.7109
Down	Frec.	(1, 2)	2000	Sí	2	0.7606	0.6680	0.7113
Down	Frec.	(1, 2)	2000	Sí	8	0.7605	0.6680	0.7113
Down	Frec.	(1, 2)	2000	Sí	16	0.7605	0.6680	0.7113

Continúa en la siguiente página

Eq.	Vec.	n-gs	Max d	S-W	C	Preci.	Recall	F-score
Down	Frec.	(1, 2)	3000	No	0.125	0.7557	0.6865	0.7195
Down	Frec.	(1, 2)	3000	No	0.5	0.7551	0.6864	0.7191
Down	Frec.	(1, 2)	3000	No	2	0.7544	0.6870	0.7192
Down	Frec.	(1, 2)	3000	No	8	0.7546	0.6875	0.7195
Down	Frec.	(1, 2)	3000	No	16	0.7545	0.6872	0.7193
Down	Frec.	(1, 2)	3000	Sí	0.125	0.7645	0.6931	0.7271
Down	Frec.	(1, 2)	3000	Sí	0.5	0.7623	0.6936	0.7263
Down	Frec.	(1, 2)	3000	Sí	2	0.7621	0.6935	0.7262
Down	Frec.	(1, 2)	3000	Sí	8	0.7623	0.6945	0.7268
Down	Frec.	(1, 2)	3000	Sí	16	0.7621	0.6945	0.7267
Down	Frec.	(2, 2)	50	No	0.125	0.6039	0.4956	0.5444
Down	Frec.	(2, 2)	50	No	0.5	0.6041	0.4956	0.5445
Down	Frec.	(2, 2)	50	No	2	0.6041	0.4956	0.5445
Down	Frec.	(2, 2)	50	No	8	0.6041	0.4956	0.5445
Down	Frec.	(2, 2)	50	No	16	0.6041	0.4956	0.5445
Down	Frec.	(2, 2)	50	Sí	0.125	0.6191	0.4246	0.5037
Down	Frec.	(2, 2)	50	Sí	0.5	0.6191	0.4246	0.5037
Down	Frec.	(2, 2)	50	Sí	2	0.6185	0.4249	0.5038
Down	Frec.	(2, 2)	50	Sí	8	0.6185	0.4249	0.5038
Down	Frec.	(2, 2)	50	Sí	16	0.6185	0.4249	0.5038
Down	Frec.	(2, 2)	500	No	0.125	0.6689	0.5387	0.5968
Down	Frec.	(2, 2)	500	No	0.5	0.6688	0.5376	0.5960
Down	Frec.	(2, 2)	500	No	2	0.6687	0.5372	0.5958
Down	Frec.	(2, 2)	500	No	8	0.6687	0.5374	0.5959
Down	Frec.	(2, 2)	500	No	16	0.6687	0.5374	0.5959
Down	Frec.	(2, 2)	500	Sí	0.125	0.6759	0.4684	0.5533
Down	Frec.	(2, 2)	500	Sí	0.5	0.6761	0.4677	0.5529
Down	Frec.	(2, 2)	500	Sí	2	0.6763	0.4685	0.5536
Down	Frec.	(2, 2)	500	Sí	8	0.6763	0.4685	0.5536
Down	Frec.	(2, 2)	500	Sí	16	0.6763	0.4685	0.5536
Down	Frec.	(2, 2)	2000	No	0.125	0.7084	0.5911	0.6445
Down	Frec.	(2, 2)	2000	No	0.5	0.7076	0.5908	0.6439
Down	Frec.	(2, 2)	2000	No	2	0.7074	0.5909	0.6439
Down	Frec.	(2, 2)	2000	No	8	0.7076	0.5914	0.6443
Down	Frec.	(2, 2)	2000	No	16	0.7075	0.5911	0.6441
Down	Frec.	(2, 2)	2000	Sí	0.125	0.7179	0.4855	0.5793
Down	Frec.	(2, 2)	2000	Sí	0.5	0.7174	0.4859	0.5794
Down	Frec.	(2, 2)	2000	Sí	2	0.7168	0.4852	0.5787
Down	Frec.	(2, 2)	2000	Sí	8	0.7170	0.4859	0.5792
Down	Frec.	(2, 2)	2000	Sí	16	0.7172	0.4859	0.5793
Down	Frec.	(2, 2)	3000	No	0.125	0.7125	0.6045	0.6540
Down	Frec.	(2, 2)	3000	No	0.5	0.7105	0.6055	0.6538
Down	Frec.	(2, 2)	3000	No	2	0.7099	0.6058	0.6537
Down	Frec.	(2, 2)	3000	No	8	0.7099	0.6059	0.6538
Down	Frec.	(2, 2)	3000	No	16	0.7100	0.6061	0.6540
Down	Frec.	(2, 2)	3000	Sí	0.125	0.7179	0.5002	0.5896
Down	Frec.	(2, 2)	3000	Sí	0.5	0.7172	0.5021	0.5906
Down	Frec.	(2, 2)	3000	Sí	2	0.7172	0.5017	0.5904
Down	Frec.	(2, 2)	3000	Sí	8	0.7174	0.5019	0.5906
Down	Frec.	(2, 2)	3000	Sí	16	0.7173	0.5019	0.5906

Fin de la tabla

APÉNDICE C

Tabla comparativa de configuraciones de estimador: regresión lineal

En esta búsqueda exhaustiva se han entrenado y evaluado 84 configuraciones.

Sum.	Lags	Prev.	Log	MSE	RMSE	MAE	R2
Sí	1	1	Sí	0.1870	0.4324	0.3421	-1.0481
Sí	1	1	No	0.0386	0.1966	0.1628	-1.8612
Sí	1	2	Sí	0.2044	0.4521	0.3574	-1.0295
Sí	1	2	No	0.0524	0.2288	0.1906	-2.0473
Sí	1	3	Sí	0.1907	0.4366	0.3498	-0.8736
Sí	1	3	No	0.0511	0.2261	0.1882	-1.9033
Sí	2	1	Sí	0.1836	0.4285	0.3018	-0.8235
Sí	2	1	No	0.0491	0.2215	0.1792	-1.8553
Sí	2	2	Sí	0.1406	0.3750	0.2796	-0.3817
Sí	2	2	No	0.0426	0.2064	0.1721	-1.4189
Sí	2	3	Sí	0.1291	0.3593	0.2795	-0.2687
Sí	2	3	No	0.0374	0.1933	0.1578	-1.1215
Sí	3	1	Sí	0.1486	0.3855	0.2915	-0.4607
Sí	3	1	No	0.0455	0.2134	0.1768	-1.5848
Sí	3	2	Sí	0.1280	0.3578	0.2902	-0.2578
Sí	3	2	No	0.0382	0.1956	0.1642	-1.1713
Sí	3	3	Sí	0.1166	0.3414	0.2704	-0.1456
Sí	3	3	No	0.0295	0.1718	0.1441	-0.6759
Sí	4	1	Sí	0.1487	0.3856	0.3042	-0.4612
Sí	4	1	No	0.0424	0.2059	0.1692	-1.4061
Sí	4	2	Sí	0.1246	0.3529	0.2764	-0.2241
Sí	4	2	No	0.0330	0.1816	0.1526	-0.8725
Sí	4	3	Sí	0.1102	0.3319	0.2761	-0.0089
Sí	4	3	No	0.0344	0.1855	0.1559	-0.6520
Sí	5	1	Sí	0.1546	0.3932	0.2800	-0.5197
Sí	5	1	No	0.0375	0.1937	0.1618	-1.1302
Sí	5	2	Sí	0.1208	0.3476	0.2718	-0.1064
Sí	5	2	No	0.0370	0.1923	0.1604	-0.7756
Sí	5	3	Sí	0.1265	0.3556	0.2769	-0.1580
Sí	5	3	No	0.0376	0.1938	0.1665	-0.8027

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	MSE	RMSE	MAE	R2
Sí	6	1	Sí	0.1329	0.3645	0.2803	-0.2166
Sí	6	1	No	0.0399	0.1997	0.1668	-0.9142
Sí	6	2	Sí	0.1303	0.3609	0.2835	-0.1929
Sí	6	2	No	0.0386	0.1965	0.1706	-0.8535
Sí	6	3	Sí	0.1313	0.3623	0.2882	-0.1565
Sí	6	3	No	0.0402	0.2006	0.1750	-0.7660
Sí	7	1	Sí	0.1665	0.4080	0.3167	-0.5244
Sí	7	1	No	0.0406	0.2016	0.1750	-0.9512
Sí	7	2	Sí	0.1574	0.3967	0.3092	-0.3865
Sí	7	2	No	0.0411	0.2028	0.1770	-0.8050
Sí	7	3	Sí	0.1782	0.4221	0.3291	-0.4391
Sí	7	3	No	0.0550	0.2346	0.2047	-0.9809
No	1	1	Sí	0.2427	0.4926	0.3849	-1.6581
No	1	1	No	0.1168	0.3417	0.2590	-7.6464
No	1	2	Sí	0.4017	0.6338	0.4737	-2.9890
No	1	2	No	0.1462	0.3824	0.2984	-7.5128
No	1	3	Sí	0.3341	0.5780	0.4520	-2.2830
No	1	3	No	0.1158	0.3403	0.2389	-5.5755
No	2	1	Sí	0.1775	0.4213	0.2963	-0.7624
No	2	1	No	0.0622	0.2493	0.1890	-2.6178
No	2	2	Sí	0.4242	0.6513	0.5475	-3.1690
No	2	2	No	0.3552	0.5960	0.4488	-19.1655
No	2	3	Sí	0.1772	0.4210	0.3527	-0.7418
No	2	3	No	0.1187	0.3446	0.2691	-5.7407
No	3	1	Sí	0.1303	0.3610	0.2843	-0.2810
No	3	1	No	0.0412	0.2030	0.1707	-1.3391
No	3	2	Sí	0.6657	0.8159	0.6812	-5.5419
No	3	2	No	0.4867	0.6976	0.5574	-26.6305
No	3	3	Sí	0.1570	0.3962	0.3099	-0.5426
No	3	3	No	0.0548	0.2341	0.1694	-2.1119
No	4	1	Sí	0.1284	0.3584	0.2837	-0.2622
No	4	1	No	0.0453	0.2129	0.1796	-1.5727
No	4	2	Sí	0.4245	0.6516	0.5427	-3.1722
No	4	2	No	0.0916	0.3026	0.2533	-4.1980
No	4	3	Sí	0.1440	0.3795	0.2791	-0.3186
No	4	3	No	0.0525	0.2291	0.1974	-1.5194
No	5	1	Sí	0.1260	0.3549	0.2431	-0.2378
No	5	1	No	0.0357	0.1888	0.1487	-1.0247
No	5	2	Sí	0.2040	0.4517	0.3420	-0.8684
No	5	2	No	0.1571	0.3964	0.3400	-6.5417
No	5	3	Sí	0.0579	0.2407	0.1960	0.4697
No	5	3	No	0.0329	0.1814	0.1556	-0.5793
No	6	1	Sí	0.1359	0.3687	0.3242	-0.2448
No	6	1	No	0.0540	0.2323	0.2009	-1.5907
No	6	2	Sí	0.5598	0.7482	0.5946	-4.1262
No	6	2	No	0.2830	0.5320	0.4743	-12.5864
No	6	3	Sí	0.1487	0.3857	0.3255	-0.3104
No	6	3	No	0.1039	0.3223	0.2363	-3.5601
No	7	1	Sí	0.1527	0.3907	0.3242	-0.3980
No	7	1	No	0.0632	0.2513	0.2261	-2.0323

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	MSE	RMSE	MAE	R2
No	7	2	Sí	0.9283	0.9635	0.8092	-7.1791
No	7	2	No	0.4113	0.6413	0.5277	-17.0500
No	7	3	Sí	0.1896	0.4354	0.3526	-0.5312
No	7	3	No	0.0637	0.2524	0.1995	-1.2935

Fin de la tabla

APÉNDICE D

Tabla comparativa de configuraciones de estimador: red neuronal artificial

En esta búsqueda exhaustiva se han entrenado y evaluado 1008 configuraciones.

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	1	1	Sí	[]	0.2	0.1350	0.3674	0.3042	-0.4787
Sí	1	1	Sí	[]	0	0.1128	0.3358	0.2611	-0.2351
Sí	1	1	Sí	[1]	0.2	0.1112	0.3335	0.2668	-0.2182
Sí	1	1	Sí	[1]	0	0.1121	0.3349	0.2609	-0.2284
Sí	1	1	Sí	[1, 1]	0.2	0.2102	0.4585	0.3527	-1.3023
Sí	1	1	Sí	[1, 1]	0	0.2911	0.5396	0.4444	-2.1891
Sí	1	1	Sí	[1, 1, 1]	0.2	0.1114	0.3337	0.2625	-0.2201
Sí	1	1	Sí	[1, 1, 1]	0	0.1118	0.3344	0.2628	-0.2251
Sí	1	1	Sí	[2, 1]	0.2	0.2316	0.4813	0.3771	-1.5372
Sí	1	1	Sí	[2, 1]	0	0.3416	0.5845	0.4999	-2.7422
Sí	1	1	Sí	[3, 2, 1]	0.2	0.3019	0.5494	0.4585	-2.3064
Sí	1	1	Sí	[3, 2, 1]	0	0.1114	0.3338	0.2622	-0.2207
Sí	1	1	No	[]	0.2	0.0154	0.1240	0.1110	-0.1384
Sí	1	1	No	[]	0	0.0168	0.1298	0.1148	-0.2475
Sí	1	1	No	[1]	0.2	0.0167	0.1293	0.1147	-0.2387
Sí	1	1	No	[1]	0	0.0153	0.1237	0.1103	-0.1340
Sí	1	1	No	[1, 1]	0.2	0.1438	0.3793	0.3610	-9.6519
Sí	1	1	No	[1, 1]	0	0.1890	0.4347	0.4190	-12.9961
Sí	1	1	No	[1, 1, 1]	0.2	0.1403	0.3746	0.3561	-9.3896
Sí	1	1	No	[1, 1, 1]	0	0.0154	0.1241	0.1095	-0.1401
Sí	1	1	No	[2, 1]	0.2	0.0154	0.1243	0.1080	-0.1439
Sí	1	1	No	[2, 1]	0	0.0153	0.1238	0.1103	-0.1349
Sí	1	1	No	[3, 2, 1]	0.2	0.0154	0.1241	0.1095	-0.1407
Sí	1	1	No	[3, 2, 1]	0	0.0154	0.1240	0.1094	-0.1378
Sí	1	2	Sí	[]	0.2	0.1297	0.3601	0.2860	-0.2875
Sí	1	2	Sí	[]	0	0.1558	0.3947	0.3115	-0.5471
Sí	1	2	Sí	[2]	0.2	0.1034	0.3215	0.2366	-0.0267
Sí	1	2	Sí	[2]	0	0.1078	0.3284	0.2544	-0.0707
Sí	1	2	Sí	[2, 1]	0.2	0.1109	0.3330	0.2633	-0.1012
Sí	1	2	Sí	[2, 1]	0	0.1114	0.3337	0.2641	-0.1060

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	1	2	Sí	[2, 1, 1]	0.2	0.1127	0.3357	0.2670	-0.1188
Sí	1	2	Sí	[2, 1, 1]	0	0.4138	0.6432	0.5597	-3.1086
Sí	1	2	Sí	[3, 1]	0.2	0.1103	0.3321	0.2610	-0.0950
Sí	1	2	Sí	[3, 1]	0	0.1122	0.3349	0.2659	-0.1139
Sí	1	2	Sí	[4, 2, 1]	0.2	0.1123	0.3351	0.2662	-0.1148
Sí	1	2	Sí	[4, 2, 1]	0	0.2308	0.4804	0.3697	-1.2915
Sí	1	2	No	[]	0.2	0.0182	0.1349	0.1104	-0.0591
Sí	1	2	No	[]	0	0.0236	0.1535	0.1304	-0.3714
Sí	1	2	No	[2]	0.2	0.0166	0.1290	0.1077	0.0316
Sí	1	2	No	[2]	0	0.0168	0.1298	0.1089	0.0200
Sí	1	2	No	[2, 1]	0.2	0.1432	0.3785	0.3550	-7.3371
Sí	1	2	No	[2, 1]	0	0.0483	0.2197	0.1842	-1.8093
Sí	1	2	No	[2, 1, 1]	0.2	0.0178	0.1335	0.1157	-0.0371
Sí	1	2	No	[2, 1, 1]	0	0.0179	0.1338	0.1162	-0.0426
Sí	1	2	No	[3, 1]	0.2	0.0178	0.1334	0.1155	-0.0366
Sí	1	2	No	[3, 1]	0	0.0178	0.1334	0.1157	-0.0355
Sí	1	2	No	[4, 2, 1]	0.2	0.0236	0.1536	0.1349	-0.3729
Sí	1	2	No	[4, 2, 1]	0	0.0303	0.1742	0.1511	-0.7663
Sí	1	3	Sí	[]	0.2	0.3761	0.6133	0.4316	-2.6961
Sí	1	3	Sí	[]	0	0.1219	0.3491	0.2713	-0.1980
Sí	1	3	Sí	[3]	0.2	0.1711	0.4137	0.3263	-0.6816
Sí	1	3	Sí	[3]	0	0.1240	0.3521	0.2848	-0.2183
Sí	1	3	Sí	[3, 1]	0.2	0.1092	0.3304	0.2629	-0.0729
Sí	1	3	Sí	[3, 1]	0	0.1079	0.3285	0.2620	-0.0608
Sí	1	3	Sí	[3, 1, 1]	0.2	0.3364	0.5800	0.4839	-2.3062
Sí	1	3	Sí	[3, 1, 1]	0	0.1136	0.3370	0.2679	-0.1161
Sí	1	3	Sí	[4, 1]	0.2	0.2255	0.4749	0.3654	-1.2161
Sí	1	3	Sí	[4, 1]	0	0.1137	0.3373	0.2674	-0.1179
Sí	1	3	Sí	[5, 2, 1]	0.2	0.1133	0.3365	0.2676	-0.1131
Sí	1	3	Sí	[5, 2, 1]	0	0.1132	0.3364	0.2674	-0.1122
Sí	1	3	No	[]	0.2	0.0152	0.1233	0.0990	0.1375
Sí	1	3	No	[]	0	0.0229	0.1513	0.1259	-0.2994
Sí	1	3	No	[3]	0.2	0.0183	0.1353	0.1184	-0.0400
Sí	1	3	No	[3]	0	0.0630	0.2510	0.2135	-2.5756
Sí	1	3	No	[3, 1]	0.2	0.0184	0.1355	0.1177	-0.0419
Sí	1	3	No	[3, 1]	0	0.1745	0.4177	0.3964	-8.9063
Sí	1	3	No	[3, 1, 1]	0.2	0.0184	0.1355	0.1177	-0.0419
Sí	1	3	No	[3, 1, 1]	0	0.0478	0.2187	0.1833	-1.7144
Sí	1	3	No	[4, 1]	0.2	0.0180	0.1342	0.1162	-0.0227
Sí	1	3	No	[4, 1]	0	0.0178	0.1333	0.1152	-0.0092
Sí	1	3	No	[5, 2, 1]	0.2	0.1571	0.3964	0.3733	-7.9199
Sí	1	3	No	[5, 2, 1]	0	0.1996	0.4468	0.4266	-10.3346
Sí	2	1	Sí	[]	0.2	0.1044	0.3230	0.2526	-0.0362
Sí	2	1	Sí	[]	0	0.1414	0.3760	0.3141	-0.4042
Sí	2	1	Sí	[1]	0.2	0.1081	0.3288	0.2548	-0.0735
Sí	2	1	Sí	[1]	0	0.1102	0.3320	0.2609	-0.0944
Sí	2	1	Sí	[1, 1]	0.2	0.1124	0.3353	0.2669	-0.1166
Sí	2	1	Sí	[1, 1]	0	0.1118	0.3343	0.2648	-0.1097
Sí	2	1	Sí	[1, 1, 1]	0.2	0.1121	0.3349	0.2661	-0.1134
Sí	2	1	Sí	[1, 1, 1]	0	0.1717	0.4144	0.3207	-0.7053

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	2	1	Sí	[2, 1]	0.2	0.1130	0.3362	0.2680	-0.1226
Sí	2	1	Sí	[2, 1]	0	0.1101	0.3319	0.2617	-0.0936
Sí	2	1	Sí	[3, 2, 1]	0.2	0.1123	0.3351	0.2665	-0.1152
Sí	2	1	Sí	[3, 2, 1]	0	0.1124	0.3352	0.2662	-0.1157
Sí	2	1	No	[]	0.2	0.0225	0.1501	0.1164	-0.3118
Sí	2	1	No	[]	0	0.0216	0.1471	0.1307	-0.2591
Sí	2	1	No	[1]	0.2	0.1347	0.3671	0.3437	-6.8431
Sí	2	1	No	[1]	0	0.3451	0.5874	0.5675	-19.0866
Sí	2	1	No	[1, 1]	0.2	0.1306	0.3613	0.3359	-6.5994
Sí	2	1	No	[1, 1]	0	0.0179	0.1338	0.1161	-0.0423
Sí	2	1	No	[1, 1, 1]	0.2	0.0178	0.1335	0.1156	-0.0377
Sí	2	1	No	[1, 1, 1]	0	0.0290	0.1704	0.1483	-0.6897
Sí	2	1	No	[2, 1]	0.2	0.1752	0.4186	0.3969	-9.1988
Sí	2	1	No	[2, 1]	0	0.0179	0.1336	0.1158	-0.0392
Sí	2	1	No	[3, 2, 1]	0.2	0.0180	0.1340	0.1165	-0.0459
Sí	2	1	No	[3, 2, 1]	0	0.2017	0.4492	0.4295	-10.7432
Sí	2	2	Sí	[]	0.2	0.1271	0.3565	0.2971	-0.2489
Sí	2	2	Sí	[]	0	0.2516	0.5015	0.3597	-1.4721
Sí	2	2	Sí	[2]	0.2	0.1221	0.3495	0.2475	-0.2002
Sí	2	2	Sí	[2]	0	0.1086	0.3296	0.2578	-0.0676
Sí	2	2	Sí	[2, 1]	0.2	0.1137	0.3372	0.2681	-0.1176
Sí	2	2	Sí	[2, 1]	0	0.1139	0.3375	0.2658	-0.1193
Sí	2	2	Sí	[2, 1, 1]	0.2	0.1872	0.4327	0.3337	-0.8398
Sí	2	2	Sí	[2, 1, 1]	0	0.1136	0.3370	0.2678	-0.1159
Sí	2	2	Sí	[3, 1]	0.2	0.1134	0.3367	0.2678	-0.1140
Sí	2	2	Sí	[3, 1]	0	0.1137	0.3372	0.2662	-0.1173
Sí	2	2	Sí	[4, 2, 1]	0.2	0.1130	0.3362	0.2674	-0.1110
Sí	2	2	Sí	[4, 2, 1]	0	0.1120	0.3347	0.2676	-0.1008
Sí	2	2	No	[]	0.2	0.0145	0.1206	0.0978	0.1744
Sí	2	2	No	[]	0	0.0404	0.2011	0.1666	-1.2954
Sí	2	2	No	[2]	0.2	0.0150	0.1225	0.1019	0.1476
Sí	2	2	No	[2]	0	0.0172	0.1313	0.1161	0.0212
Sí	2	2	No	[2, 1]	0.2	0.0182	0.1351	0.1171	-0.0361
Sí	2	2	No	[2, 1]	0	0.0183	0.1353	0.1171	-0.0400
Sí	2	2	No	[2, 1, 1]	0.2	0.0180	0.1342	0.1164	-0.0226
Sí	2	2	No	[2, 1, 1]	0	0.0182	0.1349	0.1166	-0.0327
Sí	2	2	No	[3, 1]	0.2	0.0182	0.1350	0.1170	-0.0353
Sí	2	2	No	[3, 1]	0	0.1818	0.4264	0.4056	-9.3212
Sí	2	2	No	[4, 2, 1]	0.2	0.0184	0.1358	0.1180	-0.0469
Sí	2	2	No	[4, 2, 1]	0	0.1215	0.3486	0.3223	-5.8975
Sí	2	3	Sí	[]	0.2	0.1966	0.4434	0.3544	-0.9323
Sí	2	3	Sí	[]	0	0.2872	0.5359	0.4461	-1.8227
Sí	2	3	Sí	[3]	0.2	0.0953	0.3087	0.2514	0.0637
Sí	2	3	Sí	[3]	0	0.1279	0.3577	0.2705	-0.2572
Sí	2	3	Sí	[3, 1]	0.2	0.0979	0.3129	0.2493	0.0376
Sí	2	3	Sí	[3, 1]	0	0.4345	0.6592	0.5767	-3.2699
Sí	2	3	Sí	[3, 1, 1]	0.2	0.1150	0.3391	0.2708	-0.1299
Sí	2	3	Sí	[3, 1, 1]	0	0.1122	0.3349	0.2670	-0.1023
Sí	2	3	Sí	[4, 1]	0.2	0.1136	0.3370	0.2680	-0.1164
Sí	2	3	Sí	[4, 1]	0	0.1062	0.3259	0.2655	-0.0441

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	2	3	Sí	[5, 2, 1]	0.2	0.1136	0.3371	0.2681	-0.1167
Sí	2	3	Sí	[5, 2, 1]	0	0.1115	0.3339	0.2665	-0.0954
Sí	2	3	No	[]	0.2	0.0403	0.2006	0.1542	-1.2855
Sí	2	3	No	[]	0	0.0327	0.1809	0.1510	-0.8579
Sí	2	3	No	[3]	0.2	0.0168	0.1298	0.1129	0.0439
Sí	2	3	No	[3]	0	0.1976	0.4445	0.4230	-10.2185
Sí	2	3	No	[3, 1]	0.2	0.0183	0.1353	0.1181	-0.0400
Sí	2	3	No	[3, 1]	0	0.0175	0.1323	0.1164	0.0060
Sí	2	3	No	[3, 1, 1]	0.2	0.0183	0.1352	0.1171	-0.0377
Sí	2	3	No	[3, 1, 1]	0	0.1907	0.4366	0.4160	-9.8246
Sí	2	3	No	[4, 1]	0.2	0.0183	0.1353	0.1178	-0.0393
Sí	2	3	No	[4, 1]	0	0.1705	0.4129	0.3915	-8.6775
Sí	2	3	No	[5, 2, 1]	0.2	0.0183	0.1354	0.1175	-0.0402
Sí	2	3	No	[5, 2, 1]	0	0.0182	0.1348	0.1172	-0.0324
Sí	3	1	Sí	[]	0.2	0.2600	0.5099	0.3547	-1.5554
Sí	3	1	Sí	[]	0	0.0853	0.2921	0.2438	0.1616
Sí	3	1	Sí	[1]	0.2	0.1191	0.3451	0.2707	-0.1701
Sí	3	1	Sí	[1]	0	0.4498	0.6707	0.5787	-3.4207
Sí	3	1	Sí	[1, 1]	0.2	0.1161	0.3407	0.2692	-0.1410
Sí	3	1	Sí	[1, 1]	0	0.1168	0.3418	0.2696	-0.1480
Sí	3	1	Sí	[1, 1, 1]	0.2	0.1136	0.3371	0.2680	-0.1167
Sí	3	1	Sí	[1, 1, 1]	0	0.1132	0.3364	0.2677	-0.1123
Sí	3	1	Sí	[2, 1]	0.2	0.1138	0.3373	0.2681	-0.1183
Sí	3	1	Sí	[2, 1]	0	0.1127	0.3358	0.2674	-0.1079
Sí	3	1	Sí	[3, 2, 1]	0.2	0.1133	0.3366	0.2678	-0.1135
Sí	3	1	Sí	[3, 2, 1]	0	0.1137	0.3372	0.2680	-0.1175
Sí	3	1	No	[]	0.2	0.0165	0.1286	0.1100	0.0612
Sí	3	1	No	[]	0	0.0202	0.1422	0.1240	-0.1486
Sí	3	1	No	[1]	0.2	0.0186	0.1365	0.1185	-0.0574
Sí	3	1	No	[1]	0	0.0194	0.1394	0.1209	-0.1029
Sí	3	1	No	[1, 1]	0.2	0.0183	0.1354	0.1174	-0.0408
Sí	3	1	No	[1, 1]	0	0.0183	0.1355	0.1175	-0.0418
Sí	3	1	No	[1, 1, 1]	0.2	0.0183	0.1354	0.1175	-0.0414
Sí	3	1	No	[1, 1, 1]	0	0.0184	0.1356	0.1177	-0.0435
Sí	3	1	No	[2, 1]	0.2	0.1519	0.3897	0.3660	-7.6214
Sí	3	1	No	[2, 1]	0	0.0172	0.1313	0.1155	0.0213
Sí	3	1	No	[3, 2, 1]	0.2	0.0184	0.1357	0.1178	-0.0447
Sí	3	1	No	[3, 2, 1]	0	0.1952	0.4418	0.4214	-10.0808
Sí	3	2	Sí	[]	0.2	0.1257	0.3545	0.2988	-0.2352
Sí	3	2	Sí	[]	0	0.2566	0.5065	0.3271	-1.5216
Sí	3	2	Sí	[2]	0.2	0.1205	0.3471	0.2715	-0.1843
Sí	3	2	Sí	[2]	0	0.7959	0.8921	0.8044	-6.8218
Sí	3	2	Sí	[2, 1]	0.2	0.3369	0.5804	0.4839	-2.3109
Sí	3	2	Sí	[2, 1]	0	0.1142	0.3380	0.2684	-0.1225
Sí	3	2	Sí	[2, 1, 1]	0.2	0.1126	0.3356	0.2675	-0.1070
Sí	3	2	Sí	[2, 1, 1]	0	0.1137	0.3373	0.2681	-0.1179
Sí	3	2	Sí	[3, 1]	0.2	0.1120	0.3346	0.2673	-0.1005
Sí	3	2	Sí	[3, 1]	0	0.1135	0.3370	0.2679	-0.1158
Sí	3	2	Sí	[4, 2, 1]	0.2	0.1134	0.3367	0.2678	-0.1143
Sí	3	2	Sí	[4, 2, 1]	0	0.1142	0.3380	0.2685	-0.1227

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	3	2	No	[]	0.2	0.0292	0.1709	0.1320	-0.6583
Sí	3	2	No	[]	0	0.0302	0.1738	0.1440	-0.7144
Sí	3	2	No	[2]	0.2	0.1101	0.3319	0.3055	-5.2524
Sí	3	2	No	[2]	0	0.0201	0.1419	0.1231	-0.1434
Sí	3	2	No	[2, 1]	0.2	0.0182	0.1350	0.1171	-0.0341
Sí	3	2	No	[2, 1]	0	0.0183	0.1354	0.1178	-0.0414
Sí	3	2	No	[2, 1, 1]	0.2	0.1003	0.3167	0.2877	-4.6960
Sí	3	2	No	[2, 1, 1]	0	0.0536	0.2316	0.1951	-2.0454
Sí	3	2	No	[3, 1]	0.2	0.0232	0.1523	0.1336	-0.3175
Sí	3	2	No	[3, 1]	0	0.0182	0.1348	0.1172	-0.0323
Sí	3	2	No	[4, 2, 1]	0.2	0.0190	0.1379	0.1210	-0.0800
Sí	3	2	No	[4, 2, 1]	0	0.1337	0.3657	0.3408	-6.5929
Sí	3	3	Sí	[]	0.2	0.3270	0.5718	0.3772	-2.2135
Sí	3	3	Sí	[]	0	0.0873	0.2954	0.2325	0.1423
Sí	3	3	Sí	[3]	0.2	0.0987	0.3142	0.2585	0.0299
Sí	3	3	Sí	[3]	0	0.3123	0.5588	0.4606	-2.0691
Sí	3	3	Sí	[3, 1]	0.2	0.1134	0.3367	0.2680	-0.1142
Sí	3	3	Sí	[3, 1]	0	0.1008	0.3175	0.2600	0.0094
Sí	3	3	Sí	[3, 1, 1]	0.2	0.1106	0.3325	0.2656	-0.0865
Sí	3	3	Sí	[3, 1, 1]	0	0.1136	0.3370	0.2680	-0.1164
Sí	3	3	Sí	[4, 1]	0.2	0.1958	0.4425	0.3401	-0.9240
Sí	3	3	Sí	[4, 1]	0	0.4677	0.6839	0.5997	-3.5966
Sí	3	3	Sí	[5, 2, 1]	0.2	0.1134	0.3368	0.2679	-0.1147
Sí	3	3	Sí	[5, 2, 1]	0	0.1126	0.3356	0.2675	-0.1068
Sí	3	3	No	[]	0.2	0.0541	0.2326	0.1881	-2.0724
Sí	3	3	No	[]	0	0.0209	0.1446	0.1159	-0.1865
Sí	3	3	No	[3]	0.2	0.0170	0.1304	0.1147	0.0349
Sí	3	3	No	[3]	0	0.0175	0.1322	0.1159	0.0075
Sí	3	3	No	[3, 1]	0.2	0.0210	0.1450	0.1267	-0.1940
Sí	3	3	No	[3, 1]	0	0.0181	0.1345	0.1167	-0.0269
Sí	3	3	No	[3, 1, 1]	0.2	0.0183	0.1352	0.1171	-0.0371
Sí	3	3	No	[3, 1, 1]	0	0.0183	0.1353	0.1173	-0.0400
Sí	3	3	No	[4, 1]	0.2	0.0183	0.1352	0.1172	-0.0380
Sí	3	3	No	[4, 1]	0	0.0183	0.1351	0.1171	-0.0363
Sí	3	3	No	[5, 2, 1]	0.2	0.1714	0.4140	0.3920	-8.7296
Sí	3	3	No	[5, 2, 1]	0	0.0182	0.1350	0.1171	-0.0346
Sí	4	1	Sí	[]	0.2	0.2568	0.5067	0.3499	-1.5233
Sí	4	1	Sí	[]	0	0.2237	0.4729	0.3733	-1.1981
Sí	4	1	Sí	[1]	0.2	0.1135	0.3370	0.2679	-0.1158
Sí	4	1	Sí	[1]	0	0.1111	0.3333	0.2669	-0.0915
Sí	4	1	Sí	[1, 1]	0.2	0.1116	0.3341	0.2671	-0.0969
Sí	4	1	Sí	[1, 1]	0	0.1451	0.3809	0.2997	-0.4259
Sí	4	1	Sí	[1, 1, 1]	0.2	0.3445	0.5870	0.4927	-2.3860
Sí	4	1	Sí	[1, 1, 1]	0	0.1132	0.3364	0.2678	-0.1121
Sí	4	1	Sí	[2, 1]	0.2	0.1093	0.3307	0.2660	-0.0746
Sí	4	1	Sí	[2, 1]	0	0.4567	0.6758	0.5927	-3.4887
Sí	4	1	Sí	[3, 2, 1]	0.2	0.1850	0.4301	0.3318	-0.8177
Sí	4	1	Sí	[3, 2, 1]	0	0.1137	0.3372	0.2681	-0.1176
Sí	4	1	No	[]	0.2	0.0449	0.2120	0.1639	-1.5518
Sí	4	1	No	[]	0	0.0200	0.1415	0.1145	-0.1368

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	4	1	No	[1]	0.2	0.2075	0.4555	0.4353	-10.7798
Sí	4	1	No	[1]	0	0.1908	0.4368	0.4162	-9.8336
Sí	4	1	No	[1, 1]	0.2	0.1599	0.3999	0.3771	-8.0805
Sí	4	1	No	[1, 1]	0	0.1739	0.4170	0.3954	-8.8748
Sí	4	1	No	[1, 1, 1]	0.2	0.0996	0.3156	0.2863	-4.6554
Sí	4	1	No	[1, 1, 1]	0	0.0183	0.1351	0.1173	-0.0370
Sí	4	1	No	[2, 1]	0.2	0.0184	0.1356	0.1175	-0.0445
Sí	4	1	No	[2, 1]	0	0.2139	0.4625	0.4429	-11.1444
Sí	4	1	No	[3, 2, 1]	0.2	0.0182	0.1351	0.1171	-0.0359
Sí	4	1	No	[3, 2, 1]	0	0.1814	0.4259	0.4047	-9.2975
Sí	4	2	Sí	[]	0.2	0.2202	0.4692	0.3352	-1.1639
Sí	4	2	Sí	[]	0	0.2242	0.4735	0.3774	-1.2032
Sí	4	2	Sí	[2]	0.2	0.1123	0.3351	0.2703	-0.1036
Sí	4	2	Sí	[2]	0	0.1356	0.3683	0.2806	-0.3330
Sí	4	2	Sí	[2, 1]	0.2	0.2661	0.5158	0.4088	-1.6149
Sí	4	2	Sí	[2, 1]	0	0.1110	0.3332	0.2654	-0.0913
Sí	4	2	Sí	[2, 1, 1]	0.2	0.1132	0.3364	0.2679	-0.1121
Sí	4	2	Sí	[2, 1, 1]	0	0.1125	0.3354	0.2671	-0.1057
Sí	4	2	Sí	[3, 1]	0.2	0.1137	0.3371	0.2678	-0.1169
Sí	4	2	Sí	[3, 1]	0	0.1051	0.3241	0.2633	-0.0325
Sí	4	2	Sí	[4, 2, 1]	0.2	0.1133	0.3366	0.2676	-0.1133
Sí	4	2	Sí	[4, 2, 1]	0	0.1138	0.3374	0.2681	-0.1187
Sí	4	2	No	[]	0.2	0.0177	0.1330	0.1124	-0.0050
Sí	4	2	No	[]	0	0.0174	0.1319	0.1079	0.0129
Sí	4	2	No	[2]	0.2	0.0190	0.1380	0.1175	-0.0814
Sí	4	2	No	[2]	0	0.0190	0.1377	0.1195	-0.0767
Sí	4	2	No	[2, 1]	0.2	0.0239	0.1547	0.1358	-0.3580
Sí	4	2	No	[2, 1]	0	0.0178	0.1334	0.1164	-0.0101
Sí	4	2	No	[2, 1, 1]	0.2	0.0184	0.1357	0.1179	-0.0452
Sí	4	2	No	[2, 1, 1]	0	0.2059	0.4537	0.4339	-10.6884
Sí	4	2	No	[3, 1]	0.2	0.0183	0.1353	0.1173	-0.0398
Sí	4	2	No	[3, 1]	0	0.1973	0.4441	0.4237	-10.1994
Sí	4	2	No	[4, 2, 1]	0.2	0.1706	0.4131	0.3911	-8.6866
Sí	4	2	No	[4, 2, 1]	0	0.0193	0.1390	0.1222	-0.0966
Sí	4	3	Sí	[]	0.2	0.1747	0.4179	0.3042	-0.5992
Sí	4	3	Sí	[]	0	0.1312	0.3622	0.2996	-0.2012
Sí	4	3	Sí	[3]	0.2	0.9674	0.9836	0.8863	-7.8583
Sí	4	3	Sí	[3]	0	0.0939	0.3064	0.2518	0.1403
Sí	4	3	Sí	[3, 1]	0.2	0.1158	0.3403	0.2729	-0.0603
Sí	4	3	Sí	[3, 1]	0	0.2014	0.4488	0.3448	-0.8444
Sí	4	3	Sí	[3, 1, 1]	0.2	0.1224	0.3498	0.2780	-0.1205
Sí	4	3	Sí	[3, 1, 1]	0	0.1579	0.3974	0.3072	-0.4459
Sí	4	3	Sí	[4, 1]	0.2	0.1162	0.3408	0.2728	-0.0637
Sí	4	3	Sí	[4, 1]	0	0.2908	0.5392	0.4354	-1.6624
Sí	4	3	Sí	[5, 2, 1]	0.2	0.1558	0.3947	0.3049	-0.4267
Sí	4	3	Sí	[5, 2, 1]	0	0.2367	0.4865	0.3732	-1.1670
Sí	4	3	No	[]	0.2	0.0398	0.1995	0.1666	-0.9104
Sí	4	3	No	[]	0	0.0283	0.1683	0.1211	-0.3602
Sí	4	3	No	[3]	0.2	0.0191	0.1383	0.1203	0.0813
Sí	4	3	No	[3]	0	0.0302	0.1737	0.1510	-0.4490

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	4	3	No	[3, 1]	0.2	0.0211	0.1454	0.1266	-0.0146
Sí	4	3	No	[3, 1]	0	0.1792	0.4234	0.3983	-7.6044
Sí	4	3	No	[3, 1, 1]	0.2	0.0217	0.1474	0.1279	-0.0428
Sí	4	3	No	[3, 1, 1]	0	0.0217	0.1472	0.1276	-0.0399
Sí	4	3	No	[4, 1]	0.2	0.0209	0.1446	0.1257	-0.0031
Sí	4	3	No	[4, 1]	0	0.1549	0.3936	0.3660	-6.4354
Sí	4	3	No	[5, 2, 1]	0.2	0.0216	0.1471	0.1277	-0.0382
Sí	4	3	No	[5, 2, 1]	0	0.2027	0.4502	0.4263	-8.7285
Sí	5	1	Sí	[]	0.2	0.1050	0.3240	0.2528	-0.0316
Sí	5	1	Sí	[]	0	0.1152	0.3394	0.2758	-0.1321
Sí	5	1	Sí	[1]	0.2	0.1505	0.3879	0.3002	-0.4786
Sí	5	1	Sí	[1]	0	0.4120	0.6419	0.5562	-3.0491
Sí	5	1	Sí	[1, 1]	0.2	0.1135	0.3368	0.2679	-0.1149
Sí	5	1	Sí	[1, 1]	0	0.3435	0.5861	0.4961	-2.3755
Sí	5	1	Sí	[1, 1, 1]	0.2	0.1148	0.3388	0.2691	-0.1280
Sí	5	1	Sí	[1, 1, 1]	0	0.4038	0.6355	0.5494	-2.9685
Sí	5	1	Sí	[2, 1]	0.2	0.1150	0.3390	0.2693	-0.1297
Sí	5	1	Sí	[2, 1]	0	0.3041	0.5515	0.4468	-1.9887
Sí	5	1	Sí	[3, 2, 1]	0.2	0.1131	0.3362	0.2674	-0.1111
Sí	5	1	Sí	[3, 2, 1]	0	0.1135	0.3369	0.2679	-0.1156
Sí	5	1	No	[]	0.2	0.0179	0.1337	0.1161	-0.0152
Sí	5	1	No	[]	0	0.0171	0.1310	0.1098	0.0264
Sí	5	1	No	[1]	0.2	0.0183	0.1354	0.1175	-0.0411
Sí	5	1	No	[1]	0	0.0170	0.1304	0.1107	0.0339
Sí	5	1	No	[1, 1]	0.2	0.0182	0.1349	0.1169	-0.0333
Sí	5	1	No	[1, 1]	0	0.0962	0.3101	0.2800	-4.4610
Sí	5	1	No	[1, 1, 1]	0.2	0.0646	0.2541	0.2185	-2.6649
Sí	5	1	No	[1, 1, 1]	0	0.0184	0.1355	0.1176	-0.0426
Sí	5	1	No	[2, 1]	0.2	0.0183	0.1353	0.1173	-0.0401
Sí	5	1	No	[2, 1]	0	0.0271	0.1647	0.1444	-0.5407
Sí	5	1	No	[3, 2, 1]	0.2	0.1371	0.3702	0.3456	-6.7829
Sí	5	1	No	[3, 2, 1]	0	0.0183	0.1352	0.1172	-0.0385
Sí	5	2	Sí	[]	0.2	0.3508	0.5923	0.4178	-2.2118
Sí	5	2	Sí	[]	0	0.1135	0.3369	0.2730	-0.0390
Sí	5	2	Sí	[2]	0.2	0.6937	0.8329	0.7277	-5.3515
Sí	5	2	Sí	[2]	0	0.1194	0.3455	0.2759	-0.0931
Sí	5	2	Sí	[2, 1]	0.2	0.2308	0.4804	0.3678	-1.1135
Sí	5	2	Sí	[2, 1]	0	0.4930	0.7021	0.6109	-3.5138
Sí	5	2	Sí	[2, 1, 1]	0.2	0.1230	0.3508	0.2786	-0.1265
Sí	5	2	Sí	[2, 1, 1]	0	0.3103	0.5570	0.4498	-1.8412
Sí	5	2	Sí	[3, 1]	0.2	0.3630	0.6025	0.5042	-2.3240
Sí	5	2	Sí	[3, 1]	0	0.4029	0.6347	0.5405	-2.6890
Sí	5	2	Sí	[4, 2, 1]	0.2	0.3590	0.5991	0.4987	-2.2868
Sí	5	2	Sí	[4, 2, 1]	0	0.1220	0.3493	0.2777	-0.1173
Sí	5	2	No	[]	0.2	0.0194	0.1393	0.1207	0.0690
Sí	5	2	No	[]	0	0.0404	0.2011	0.1634	-0.9410
Sí	5	2	No	[2]	0.2	0.0220	0.1483	0.1286	-0.0565
Sí	5	2	No	[2]	0	0.0236	0.1537	0.1361	-0.1335
Sí	5	2	No	[2, 1]	0.2	0.0217	0.1473	0.1279	-0.0421
Sí	5	2	No	[2, 1]	0	0.2018	0.4492	0.4254	-8.6870

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	5	2	No	[2, 1, 1]	0.2	0.0217	0.1472	0.1276	-0.0401
Sí	5	2	No	[2, 1, 1]	0	0.0217	0.1472	0.1277	-0.0401
Sí	5	2	No	[3, 1]	0.2	0.0216	0.1471	0.1277	-0.0390
Sí	5	2	No	[3, 1]	0	0.0216	0.1471	0.1275	-0.0382
Sí	5	2	No	[4, 2, 1]	0.2	0.1501	0.3874	0.3593	-6.2034
Sí	5	2	No	[4, 2, 1]	0	0.0952	0.3085	0.2745	-3.5681
Sí	5	3	Sí	[]	0.2	0.2112	0.4595	0.2968	-0.9337
Sí	5	3	Sí	[]	0	0.2144	0.4630	0.3114	-0.9632
Sí	5	3	Sí	[3]	0.2	0.3352	0.5789	0.4774	-2.0689
Sí	5	3	Sí	[3]	0	0.0903	0.3006	0.2498	0.1728
Sí	5	3	Sí	[3, 1]	0.2	0.1208	0.3475	0.2768	-0.1058
Sí	5	3	Sí	[3, 1]	0	0.1196	0.3458	0.2757	-0.0949
Sí	5	3	Sí	[3, 1, 1]	0.2	0.1209	0.3477	0.2768	-0.1068
Sí	5	3	Sí	[3, 1, 1]	0	0.1218	0.3491	0.2775	-0.1157
Sí	5	3	Sí	[4, 1]	0.2	0.1276	0.3571	0.2832	-0.1679
Sí	5	3	Sí	[4, 1]	0	0.1157	0.3401	0.2714	-0.0593
Sí	5	3	Sí	[5, 2, 1]	0.2	0.1214	0.3484	0.2770	-0.1112
Sí	5	3	Sí	[5, 2, 1]	0	0.1220	0.3493	0.2777	-0.1174
Sí	5	3	No	[]	0.2	0.0341	0.1846	0.1460	-0.6350
Sí	5	3	No	[]	0	0.0152	0.1233	0.1043	0.2697
Sí	5	3	No	[3]	0.2	0.0693	0.2633	0.2245	-2.3270
Sí	5	3	No	[3]	0	0.0523	0.2287	0.1974	-1.5102
Sí	5	3	No	[3, 1]	0.2	0.0548	0.2341	0.1943	-1.6316
Sí	5	3	No	[3, 1]	0	0.0211	0.1452	0.1257	-0.0117
Sí	5	3	No	[3, 1, 1]	0.2	0.1572	0.3965	0.3693	-6.5453
Sí	5	3	No	[3, 1, 1]	0	0.0217	0.1471	0.1276	-0.0394
Sí	5	3	No	[4, 1]	0.2	0.0215	0.1468	0.1273	-0.0343
Sí	5	3	No	[4, 1]	0	0.0214	0.1463	0.1268	-0.0274
Sí	5	3	No	[5, 2, 1]	0.2	0.0217	0.1473	0.1278	-0.0421
Sí	5	3	No	[5, 2, 1]	0	0.0217	0.1473	0.1277	-0.0410
Sí	6	1	Sí	[]	0.2	0.1552	0.3939	0.2971	-0.4210
Sí	6	1	Sí	[]	0	0.1718	0.4145	0.3081	-0.5735
Sí	6	1	Sí	[1]	0.2	0.1217	0.3489	0.2775	-0.1146
Sí	6	1	Sí	[1]	0	0.1300	0.3606	0.2838	-0.1908
Sí	6	1	Sí	[1, 1]	0.2	0.1219	0.3492	0.2776	-0.1163
Sí	6	1	Sí	[1, 1]	0	0.1370	0.3701	0.2934	-0.2541
Sí	6	1	Sí	[1, 1, 1]	0.2	0.1218	0.3489	0.2775	-0.1149
Sí	6	1	Sí	[1, 1, 1]	0	0.1276	0.3572	0.2822	-0.1680
Sí	6	1	Sí	[2, 1]	0.2	0.1207	0.3475	0.2767	-0.1056
Sí	6	1	Sí	[2, 1]	0	0.1074	0.3278	0.2670	0.0162
Sí	6	1	Sí	[3, 2, 1]	0.2	0.1219	0.3491	0.2776	-0.1159
Sí	6	1	Sí	[3, 2, 1]	0	0.1213	0.3482	0.2771	-0.1104
Sí	6	1	No	[]	0.2	0.0246	0.1569	0.1254	-0.1819
Sí	6	1	No	[]	0	0.0245	0.1567	0.1342	-0.1781
Sí	6	1	No	[1]	0.2	0.0217	0.1474	0.1278	-0.0424
Sí	6	1	No	[1]	0	0.0211	0.1453	0.1265	-0.0141
Sí	6	1	No	[1, 1]	0.2	0.0218	0.1478	0.1280	-0.0482
Sí	6	1	No	[1, 1]	0	0.0217	0.1472	0.1277	-0.0397
Sí	6	1	No	[1, 1, 1]	0.2	0.0217	0.1474	0.1278	-0.0431
Sí	6	1	No	[1, 1, 1]	0	0.0648	0.2546	0.2152	-2.1109

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	6	1	No	[2, 1]	0.2	0.0205	0.1433	0.1248	0.0138
Sí	6	1	No	[2, 1]	0	0.0216	0.1471	0.1276	-0.0392
Sí	6	1	No	[3, 2, 1]	0.2	0.1674	0.4091	0.3827	-7.0359
Sí	6	1	No	[3, 2, 1]	0	0.0934	0.3056	0.2693	-3.4821
Sí	6	2	Sí	[]	0.2	0.1385	0.3721	0.2870	-0.2681
Sí	6	2	Sí	[]	0	0.0694	0.2635	0.2134	0.3642
Sí	6	2	Sí	[2]	0.2	0.4719	0.6870	0.5778	-3.3211
Sí	6	2	Sí	[2]	0	0.6268	0.7917	0.7035	-4.7390
Sí	6	2	Sí	[2, 1]	0.2	0.2638	0.5136	0.3978	-1.4156
Sí	6	2	Sí	[2, 1]	0	0.1206	0.3473	0.2766	-0.1041
Sí	6	2	Sí	[2, 1, 1]	0.2	0.3352	0.5790	0.4757	-2.0695
Sí	6	2	Sí	[2, 1, 1]	0	0.1214	0.3484	0.2771	-0.1116
Sí	6	2	Sí	[3, 1]	0.2	0.1175	0.3428	0.2733	-0.0760
Sí	6	2	Sí	[3, 1]	0	0.1223	0.3497	0.2778	-0.1197
Sí	6	2	Sí	[4, 2, 1]	0.2	0.1719	0.4145	0.3210	-0.5736
Sí	6	2	Sí	[4, 2, 1]	0	0.2631	0.5129	0.4096	-1.4090
Sí	6	2	No	[]	0.2	0.0253	0.1591	0.1330	-0.2147
Sí	6	2	No	[]	0	0.0350	0.1871	0.1295	-0.6813
Sí	6	2	No	[2]	0.2	0.0464	0.2154	0.1833	-1.2266
Sí	6	2	No	[2]	0	0.0210	0.1448	0.1216	-0.0064
Sí	6	2	No	[2, 1]	0.2	0.0514	0.2266	0.1913	-1.4658
Sí	6	2	No	[2, 1]	0	0.0218	0.1477	0.1281	-0.0475
Sí	6	2	No	[2, 1, 1]	0.2	0.0217	0.1473	0.1277	-0.0411
Sí	6	2	No	[2, 1, 1]	0	0.0214	0.1465	0.1271	-0.0297
Sí	6	2	No	[3, 1]	0.2	0.1068	0.3268	0.2930	-4.1259
Sí	6	2	No	[3, 1]	0	0.0713	0.2669	0.2298	-2.4208
Sí	6	2	No	[4, 2, 1]	0.2	0.0215	0.1467	0.1273	-0.0336
Sí	6	2	No	[4, 2, 1]	0	0.0292	0.1708	0.1501	-0.4010
Sí	6	3	Sí	[]	0.2	0.1304	0.3610	0.2711	-0.1485
Sí	6	3	Sí	[]	0	0.0797	0.2824	0.2394	0.2974
Sí	6	3	Sí	[3]	0.2	0.4329	0.6580	0.5565	-2.8144
Sí	6	3	Sí	[3]	0	0.1122	0.3350	0.2710	0.0113
Sí	6	3	Sí	[3, 1]	0.2	0.1869	0.4323	0.3347	-0.6463
Sí	6	3	Sí	[3, 1]	0	0.1952	0.4419	0.3418	-0.7201
Sí	6	3	Sí	[3, 1, 1]	0.2	0.1263	0.3553	0.2825	-0.1125
Sí	6	3	Sí	[3, 1, 1]	0	0.1408	0.3753	0.2948	-0.2407
Sí	6	3	Sí	[4, 1]	0.2	0.1931	0.4394	0.3404	-0.7010
Sí	6	3	Sí	[4, 1]	0	0.1257	0.3546	0.2823	-0.1078
Sí	6	3	Sí	[5, 2, 1]	0.2	0.1265	0.3556	0.2828	-0.1144
Sí	6	3	Sí	[5, 2, 1]	0	0.1253	0.3539	0.2818	-0.1036
Sí	6	3	No	[]	0.2	0.0238	0.1543	0.1274	-0.0455
Sí	6	3	No	[]	0	0.0180	0.1341	0.1105	0.2112
Sí	6	3	No	[3]	0.2	0.0281	0.1676	0.1453	-0.2327
Sí	6	3	No	[3]	0	0.0583	0.2415	0.2094	-1.5593
Sí	6	3	No	[3, 1]	0.2	0.0238	0.1541	0.1338	-0.0426
Sí	6	3	No	[3, 1]	0	0.1170	0.3421	0.3071	-4.1366
Sí	6	3	No	[3, 1, 1]	0.2	0.1015	0.3185	0.2806	-3.4535
Sí	6	3	No	[3, 1, 1]	0	0.0237	0.1538	0.1333	-0.0382
Sí	6	3	No	[4, 1]	0.2	0.0235	0.1533	0.1329	-0.0318
Sí	6	3	No	[4, 1]	0	0.0231	0.1518	0.1317	-0.0120

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	6	3	No	[5, 2, 1]	0.2	0.0236	0.1535	0.1331	-0.0341
Sí	6	3	No	[5, 2, 1]	0	0.0237	0.1539	0.1334	-0.0389
Sí	7	1	Sí	[]	0.2	0.1719	0.4146	0.3262	-0.5739
Sí	7	1	Sí	[]	0	0.1830	0.4278	0.3342	-0.6757
Sí	7	1	Sí	[1]	0.2	0.1181	0.3437	0.2734	-0.0814
Sí	7	1	Sí	[1]	0	0.1233	0.3511	0.2795	-0.1290
Sí	7	1	Sí	[1, 1]	0.2	0.3602	0.6001	0.5005	-2.2979
Sí	7	1	Sí	[1, 1]	0	0.1226	0.3501	0.2785	-0.1222
Sí	7	1	Sí	[1, 1, 1]	0.2	0.1220	0.3493	0.2777	-0.1174
Sí	7	1	Sí	[1, 1, 1]	0	0.1218	0.3490	0.2774	-0.1152
Sí	7	1	Sí	[2, 1]	0.2	0.1218	0.3489	0.2774	-0.1149
Sí	7	1	Sí	[2, 1]	0	0.1226	0.3502	0.2786	-0.1227
Sí	7	1	Sí	[3, 2, 1]	0.2	0.2440	0.4939	0.3799	-1.2338
Sí	7	1	Sí	[3, 2, 1]	0	0.2737	0.5232	0.4093	-1.5062
Sí	7	1	No	[]	0.2	0.0197	0.1404	0.1095	0.0533
Sí	7	1	No	[]	0	0.0225	0.1499	0.1310	-0.0783
Sí	7	1	No	[1]	0.2	0.0213	0.1460	0.1259	-0.0231
Sí	7	1	No	[1]	0	0.0220	0.1483	0.1290	-0.0556
Sí	7	1	No	[1, 1]	0.2	0.1694	0.4115	0.3851	-7.1303
Sí	7	1	No	[1, 1]	0	0.1179	0.3434	0.3116	-4.6618
Sí	7	1	No	[1, 1, 1]	0.2	0.0217	0.1473	0.1278	-0.0420
Sí	7	1	No	[1, 1, 1]	0	0.0217	0.1474	0.1279	-0.0424
Sí	7	1	No	[2, 1]	0.2	0.0216	0.1470	0.1274	-0.0374
Sí	7	1	No	[2, 1]	0	0.0220	0.1482	0.1290	-0.0543
Sí	7	1	No	[3, 2, 1]	0.2	0.0216	0.1471	0.1275	-0.0387
Sí	7	1	No	[3, 2, 1]	0	0.1893	0.4351	0.4105	-8.0880
Sí	7	2	Sí	[]	0.2	0.2531	0.5031	0.3774	-1.2301
Sí	7	2	Sí	[]	0	0.1624	0.4030	0.3140	-0.4308
Sí	7	2	Sí	[2]	0.2	0.1347	0.3670	0.2936	-0.1869
Sí	7	2	Sí	[2]	0	0.1145	0.3383	0.2693	-0.0085
Sí	7	2	Sí	[2, 1]	0.2	0.1250	0.3536	0.2813	-0.1016
Sí	7	2	Sí	[2, 1]	0	0.3272	0.5720	0.4589	-1.8825
Sí	7	2	Sí	[2, 1, 1]	0.2	0.1361	0.3689	0.2901	-0.1987
Sí	7	2	Sí	[2, 1, 1]	0	0.1264	0.3555	0.2826	-0.1137
Sí	7	2	Sí	[3, 1]	0.2	0.1271	0.3564	0.2833	-0.1194
Sí	7	2	Sí	[3, 1]	0	0.2321	0.4818	0.3734	-1.0453
Sí	7	2	Sí	[4, 2, 1]	0.2	0.1268	0.3561	0.2831	-0.1172
Sí	7	2	Sí	[4, 2, 1]	0	0.1268	0.3560	0.2831	-0.1169
Sí	7	2	No	[]	0.2	0.0254	0.1594	0.1401	-0.1154
Sí	7	2	No	[]	0	0.0290	0.1703	0.1497	-0.2728
Sí	7	2	No	[2]	0.2	0.0268	0.1637	0.1439	-0.1765
Sí	7	2	No	[2]	0	0.0208	0.1442	0.1220	0.0877
Sí	7	2	No	[2, 1]	0.2	0.1903	0.4363	0.4083	-7.3541
Sí	7	2	No	[2, 1]	0	0.0348	0.1866	0.1636	-0.5290
Sí	7	2	No	[2, 1, 1]	0.2	0.1546	0.3932	0.3631	-5.7862
Sí	7	2	No	[2, 1, 1]	0	0.0237	0.1540	0.1337	-0.0415
Sí	7	2	No	[3, 1]	0.2	0.0235	0.1533	0.1332	-0.0315
Sí	7	2	No	[3, 1]	0	0.0889	0.2982	0.2569	-2.9034
Sí	7	2	No	[4, 2, 1]	0.2	0.0237	0.1539	0.1333	-0.0392
Sí	7	2	No	[4, 2, 1]	0	0.0236	0.1536	0.1332	-0.0356

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	7	3	Sí	[]	0.2	0.1097	0.3312	0.2649	0.1141
Sí	7	3	Sí	[]	0	0.0938	0.3062	0.2683	0.2426
Sí	7	3	Sí	[3]	0.2	0.7658	0.8751	0.7792	-5.1847
Sí	7	3	Sí	[3]	0	0.2888	0.5374	0.4263	-1.3321
Sí	7	3	Sí	[3, 1]	0.2	0.1430	0.3782	0.3000	-0.1550
Sí	7	3	Sí	[3, 1]	0	0.1360	0.3688	0.2933	-0.0985
Sí	7	3	Sí	[3, 1, 1]	0.2	0.1381	0.3716	0.2954	-0.1150
Sí	7	3	Sí	[3, 1, 1]	0	0.1358	0.3685	0.2932	-0.0969
Sí	7	3	Sí	[4, 1]	0.2	0.1388	0.3725	0.2961	-0.1209
Sí	7	3	Sí	[4, 1]	0	0.4778	0.6912	0.5927	-2.8590
Sí	7	3	Sí	[5, 2, 1]	0.2	0.1397	0.3738	0.2971	-0.1286
Sí	7	3	Sí	[5, 2, 1]	0	0.1383	0.3719	0.2957	-0.1169
Sí	7	3	No	[]	0.2	0.0318	0.1784	0.1418	-0.1451
Sí	7	3	No	[]	0	0.0372	0.1929	0.1461	-0.3400
Sí	7	3	No	[3]	0.2	0.0694	0.2635	0.2219	-1.4994
Sí	7	3	No	[3]	0	0.0797	0.2823	0.2444	-1.8682
Sí	7	3	No	[3, 1]	0.2	0.0287	0.1693	0.1467	-0.0313
Sí	7	3	No	[3, 1]	0	0.0982	0.3134	0.2733	-2.5346
Sí	7	3	No	[3, 1, 1]	0.2	0.0288	0.1697	0.1471	-0.0367
Sí	7	3	No	[3, 1, 1]	0	0.1198	0.3461	0.3055	-3.3130
Sí	7	3	No	[4, 1]	0.2	0.0291	0.1706	0.1483	-0.0482
Sí	7	3	No	[4, 1]	0	0.0287	0.1695	0.1468	-0.0336
Sí	7	3	No	[5, 2, 1]	0.2	0.0289	0.1701	0.1476	-0.0420
Sí	7	3	No	[5, 2, 1]	0	0.0413	0.2033	0.1783	-0.4883
No	1	1	Sí	[]	0.2	0.1967	0.4435	0.3624	-1.1546
No	1	1	Sí	[]	0	0.3811	0.6173	0.4541	-3.1740
No	1	1	Sí	[16]	0.2	0.2756	0.5250	0.4142	-2.0189
No	1	1	Sí	[16]	0	0.5973	0.7728	0.7032	-5.5424
No	1	1	Sí	[16, 8]	0.2	0.1063	0.3260	0.2549	-0.1641
No	1	1	Sí	[16, 8]	0	0.1082	0.3289	0.2561	-0.1852
No	1	1	Sí	[16, 8, 5]	0.2	0.1377	0.3711	0.2885	-0.5084
No	1	1	Sí	[16, 8, 5]	0	0.1133	0.3366	0.2656	-0.2413
No	1	1	Sí	[24, 8]	0.2	0.1466	0.3829	0.2960	-0.6060
No	1	1	Sí	[24, 8]	0	0.1188	0.3447	0.2788	-0.3011
No	1	1	Sí	[29, 13, 5]	0.2	0.1666	0.4082	0.3136	-0.8250
No	1	1	Sí	[29, 13, 5]	0	0.1106	0.3325	0.2623	-0.2114
No	1	1	No	[]	0.2	0.2101	0.4584	0.3936	-14.5624
No	1	1	No	[]	0	0.2583	0.5082	0.3860	-18.1282
No	1	1	No	[16]	0.2	0.0183	0.1353	0.1122	-0.3552
No	1	1	No	[16]	0	0.0087	0.0932	0.0759	0.3565
No	1	1	No	[16, 8]	0.2	0.0108	0.1041	0.0865	0.1980
No	1	1	No	[16, 8]	0	0.0162	0.1272	0.1120	-0.1979
No	1	1	No	[16, 8, 5]	0.2	0.0154	0.1242	0.1094	-0.1427
No	1	1	No	[16, 8, 5]	0	0.0156	0.1250	0.1103	-0.1573
No	1	1	No	[24, 8]	0.2	0.1863	0.4316	0.4132	-12.7945
No	1	1	No	[24, 8]	0	0.1664	0.4080	0.3894	-11.3266
No	1	1	No	[29, 13, 5]	0.2	0.0160	0.1264	0.1115	-0.1825
No	1	1	No	[29, 13, 5]	0	0.0155	0.1243	0.1095	-0.1444
No	1	2	Sí	[]	0.2	0.3119	0.5585	0.4565	-2.0970
No	1	2	Sí	[]	0	0.2378	0.4877	0.3821	-1.3615

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	1	2	Sí	[32]	0.2	0.1866	0.4320	0.3482	-0.8533
No	1	2	Sí	[32]	0	0.1108	0.3329	0.2819	-0.1005
No	1	2	Sí	[32, 16]	0.2	0.1071	0.3273	0.2545	-0.0637
No	1	2	Sí	[32, 16]	0	0.3232	0.5685	0.4766	-2.2097
No	1	2	Sí	[32, 16, 10]	0.2	0.3781	0.6149	0.5256	-2.7542
No	1	2	Sí	[32, 16, 10]	0	0.3811	0.6173	0.5296	-2.7840
No	1	2	Sí	[48, 16]	0.2	0.1108	0.3328	0.2607	-0.1001
No	1	2	Sí	[48, 16]	0	0.1229	0.3505	0.2775	-0.2201
No	1	2	Sí	[58, 26, 10]	0.2	0.1115	0.3339	0.2623	-0.1070
No	1	2	Sí	[58, 26, 10]	0	0.1089	0.3300	0.2613	-0.0813
No	1	2	No	[]	0.2	0.3250	0.5701	0.4798	-17.9153
No	1	2	No	[]	0	0.1115	0.3338	0.2936	-5.4875
No	1	2	No	[32]	0.2	0.3307	0.5751	0.5395	-18.2519
No	1	2	No	[32]	0	0.0306	0.1749	0.1488	-0.7811
No	1	2	No	[32, 16]	0.2	0.0191	0.1382	0.1159	-0.1118
No	1	2	No	[32, 16]	0	0.0177	0.1331	0.1154	-0.0307
No	1	2	No	[32, 16, 10]	0.2	0.0166	0.1287	0.1114	0.0354
No	1	2	No	[32, 16, 10]	0	0.0301	0.1735	0.1501	-0.7516
No	1	2	No	[48, 16]	0.2	0.0181	0.1347	0.1132	-0.0559
No	1	2	No	[48, 16]	0	0.1661	0.4075	0.3876	-8.6657
No	1	2	No	[58, 26, 10]	0.2	0.0261	0.1616	0.1403	-0.5200
No	1	2	No	[58, 26, 10]	0	0.0179	0.1336	0.1152	-0.0391
No	1	3	Sí	[]	0.2	0.4175	0.6461	0.5222	-3.1028
No	1	3	Sí	[]	0	0.2229	0.4721	0.3692	-1.1907
No	1	3	Sí	[48]	0.2	0.3490	0.5908	0.4979	-2.4298
No	1	3	Sí	[48]	0	0.1121	0.3349	0.2733	-0.1020
No	1	3	Sí	[48, 24]	0.2	0.0987	0.3141	0.2515	0.0301
No	1	3	Sí	[48, 24]	0	0.2029	0.4505	0.3443	-0.9942
No	1	3	Sí	[48, 24, 16]	0.2	0.3286	0.5732	0.4729	-2.2294
No	1	3	Sí	[48, 24, 16]	0	0.1044	0.3231	0.2591	-0.0257
No	1	3	Sí	[72, 24]	0.2	0.1003	0.3167	0.2512	0.0142
No	1	3	Sí	[72, 24]	0	0.0984	0.3137	0.2529	0.0331
No	1	3	Sí	[88, 40, 16]	0.2	0.1416	0.3762	0.2919	-0.3911
No	1	3	Sí	[88, 40, 16]	0	0.2910	0.5395	0.4324	-1.8602
No	1	3	No	[]	0.2	0.1457	0.3817	0.3024	-7.2737
No	1	3	No	[]	0	0.0611	0.2472	0.2204	-2.4680
No	1	3	No	[48]	0.2	0.2964	0.5444	0.4980	-15.8289
No	1	3	No	[48]	0	0.0198	0.1407	0.1199	-0.1233
No	1	3	No	[48, 24]	0.2	0.0231	0.1519	0.1359	-0.3105
No	1	3	No	[48, 24]	0	0.1216	0.3488	0.3141	-5.9054
No	1	3	No	[48, 24, 16]	0.2	0.1071	0.3273	0.2992	-5.0830
No	1	3	No	[48, 24, 16]	0	0.0176	0.1326	0.1146	0.0011
No	1	3	No	[72, 24]	0.2	0.1308	0.3617	0.3384	-6.4267
No	1	3	No	[72, 24]	0	0.0902	0.3003	0.2721	-4.1189
No	1	3	No	[88, 40, 16]	0.2	0.1358	0.3686	0.3444	-6.7126
No	1	3	No	[88, 40, 16]	0	0.0188	0.1373	0.1139	-0.0697
No	2	1	Sí	[]	0.2	0.3623	0.6019	0.5570	-2.5979
No	2	1	Sí	[]	0	0.3270	0.5718	0.4728	-2.2472
No	2	1	Sí	[16]	0.2	0.1330	0.3648	0.3050	-0.3212
No	2	1	Sí	[16]	0	0.1008	0.3175	0.2588	-0.0012

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	2	1	Sí	[16, 8]	0.2	0.1148	0.3389	0.2724	-0.1404
No	2	1	Sí	[16, 8]	0	0.3815	0.6177	0.5347	-2.7883
No	2	1	Sí	[16, 8, 5]	0.2	0.1105	0.3324	0.2622	-0.0972
No	2	1	Sí	[16, 8, 5]	0	0.1102	0.3319	0.2649	-0.0940
No	2	1	Sí	[24, 8]	0.2	0.0957	0.3093	0.2336	0.0498
No	2	1	Sí	[24, 8]	0	0.1110	0.3332	0.2632	-0.1025
No	2	1	Sí	[29, 13, 5]	0.2	0.1104	0.3323	0.2605	-0.0966
No	2	1	Sí	[29, 13, 5]	0	0.1093	0.3306	0.2619	-0.0853
No	2	1	No	[]	0.2	0.0789	0.2808	0.2301	-3.5899
No	2	1	No	[]	0	0.0639	0.2528	0.2306	-2.7193
No	2	1	No	[16]	0.2	0.0200	0.1413	0.1131	-0.1629
No	2	1	No	[16]	0	0.0401	0.2003	0.1679	-1.3355
No	2	1	No	[16, 8]	0.2	0.0184	0.1356	0.1209	-0.0706
No	2	1	No	[16, 8]	0	0.0179	0.1340	0.1104	-0.0445
No	2	1	No	[16, 8, 5]	0.2	0.0289	0.1700	0.1476	-0.6814
No	2	1	No	[16, 8, 5]	0	0.0314	0.1771	0.1531	-0.8265
No	2	1	No	[24, 8]	0.2	0.0367	0.1915	0.1623	-1.1352
No	2	1	No	[24, 8]	0	0.0171	0.1309	0.1118	0.0024
No	2	1	No	[29, 13, 5]	0.2	0.0175	0.1322	0.1144	-0.0178
No	2	1	No	[29, 13, 5]	0	0.0733	0.2707	0.2370	-3.2647
No	2	2	Sí	[]	0.2	0.3916	0.6258	0.5443	-2.8485
No	2	2	Sí	[]	0	0.2134	0.4620	0.3912	-1.0972
No	2	2	Sí	[32]	0.2	0.0939	0.3065	0.2466	0.0767
No	2	2	Sí	[32]	0	0.0627	0.2505	0.1957	0.3833
No	2	2	Sí	[32, 16]	0.2	0.2718	0.5213	0.4227	-1.6709
No	2	2	Sí	[32, 16]	0	0.0989	0.3145	0.2515	0.0281
No	2	2	Sí	[32, 16, 10]	0.2	0.1070	0.3272	0.2621	-0.0520
No	2	2	Sí	[32, 16, 10]	0	0.1163	0.3410	0.2687	-0.1427
No	2	2	Sí	[48, 16]	0.2	0.3734	0.6111	0.5176	-2.6695
No	2	2	Sí	[48, 16]	0	0.1071	0.3272	0.2571	-0.0524
No	2	2	Sí	[58, 26, 10]	0.2	0.1120	0.3346	0.2699	-0.1002
No	2	2	Sí	[58, 26, 10]	0	0.1071	0.3272	0.2617	-0.0524
No	2	2	No	[]	0.2	0.1534	0.3916	0.3176	-7.7079
No	2	2	No	[]	0	0.1275	0.3570	0.2913	-6.2379
No	2	2	No	[32]	0.2	0.2216	0.4707	0.4488	-11.5797
No	2	2	No	[32]	0	0.0206	0.1437	0.1330	-0.1724
No	2	2	No	[32, 16]	0.2	0.0392	0.1979	0.1667	-1.2231
No	2	2	No	[32, 16]	0	0.1410	0.3755	0.3541	-7.0065
No	2	2	No	[32, 16, 10]	0.2	0.1287	0.3588	0.3343	-6.3075
No	2	2	No	[32, 16, 10]	0	0.0185	0.1361	0.1189	-0.0524
No	2	2	No	[48, 16]	0.2	0.0158	0.1256	0.1056	0.1039
No	2	2	No	[48, 16]	0	0.1250	0.3536	0.3315	-6.0982
No	2	2	No	[58, 26, 10]	0.2	0.0175	0.1323	0.1154	0.0060
No	2	2	No	[58, 26, 10]	0	0.0186	0.1365	0.1196	-0.0575
No	2	3	Sí	[]	0.2	0.2470	0.4970	0.4143	-1.4277
No	2	3	Sí	[]	0	0.1345	0.3668	0.2820	-0.3222
No	2	3	Sí	[48]	0.2	0.0729	0.2700	0.2224	0.2836
No	2	3	Sí	[48]	0	0.1348	0.3671	0.2801	-0.3245
No	2	3	Sí	[48, 24]	0.2	0.0979	0.3129	0.2522	0.0378
No	2	3	Sí	[48, 24]	0	0.0876	0.2959	0.2396	0.1393

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	2	3	Sí	[48, 24, 16]	0.2	0.1053	0.3245	0.2603	-0.0349
No	2	3	Sí	[48, 24, 16]	0	0.1041	0.3226	0.2626	-0.0227
No	2	3	Sí	[72, 24]	0.2	0.1090	0.3302	0.2586	-0.0713
No	2	3	Sí	[72, 24]	0	0.2072	0.4552	0.3444	-1.0367
No	2	3	Sí	[88, 40, 16]	0.2	0.1142	0.3380	0.2688	-0.1226
No	2	3	Sí	[88, 40, 16]	0	0.0976	0.3125	0.2540	0.0404
No	2	3	No	[]	0.2	0.0682	0.2612	0.2361	-2.8726
No	2	3	No	[]	0	0.0893	0.2989	0.2451	-4.0713
No	2	3	No	[48]	0.2	0.1928	0.4391	0.4154	-9.9477
No	2	3	No	[48]	0	0.0187	0.1367	0.1214	-0.0614
No	2	3	No	[48, 24]	0.2	0.0154	0.1239	0.1083	0.1284
No	2	3	No	[48, 24]	0	0.0169	0.1299	0.1191	0.0426
No	2	3	No	[48, 24, 16]	0.2	0.0180	0.1341	0.1193	-0.0213
No	2	3	No	[48, 24, 16]	0	0.0177	0.1332	0.1139	-0.0075
No	2	3	No	[72, 24]	0.2	0.0185	0.1360	0.1159	-0.0500
No	2	3	No	[72, 24]	0	0.0263	0.1622	0.1433	-0.4940
No	2	3	No	[88, 40, 16]	0.2	0.0202	0.1420	0.1257	-0.1454
No	2	3	No	[88, 40, 16]	0	0.0212	0.1458	0.1284	-0.2064
No	3	1	Sí	[]	0.2	0.2206	0.4697	0.3811	-1.1684
No	3	1	Sí	[]	0	0.1393	0.3733	0.2565	-0.3692
No	3	1	Sí	[16]	0.2	0.1680	0.4099	0.3359	-0.6508
No	3	1	Sí	[16]	0	0.1177	0.3431	0.2509	-0.1569
No	3	1	Sí	[16, 8]	0.2	0.1013	0.3183	0.2616	0.0043
No	3	1	Sí	[16, 8]	0	0.1046	0.3234	0.2671	-0.0278
No	3	1	Sí	[16, 8, 5]	0.2	0.1086	0.3296	0.2662	-0.0673
No	3	1	Sí	[16, 8, 5]	0	0.1426	0.3776	0.2937	-0.4011
No	3	1	Sí	[24, 8]	0.2	0.1106	0.3326	0.2699	-0.0868
No	3	1	Sí	[24, 8]	0	0.0957	0.3094	0.2539	0.0591
No	3	1	Sí	[29, 13, 5]	0.2	0.1109	0.3331	0.2667	-0.0901
No	3	1	Sí	[29, 13, 5]	0	0.1335	0.3654	0.2862	-0.3124
No	3	1	No	[]	0.2	0.0334	0.1828	0.1408	-0.8972
No	3	1	No	[]	0	0.1507	0.3882	0.2893	-7.5551
No	3	1	No	[16]	0.2	0.2940	0.5422	0.5179	-15.6904
No	3	1	No	[16]	0	0.1799	0.4241	0.4048	-9.2118
No	3	1	No	[16, 8]	0.2	0.0400	0.2000	0.1728	-1.2718
No	3	1	No	[16, 8]	0	0.0164	0.1282	0.1143	0.0668
No	3	1	No	[16, 8, 5]	0.2	0.0182	0.1349	0.1178	-0.0328
No	3	1	No	[16, 8, 5]	0	0.0324	0.1800	0.1570	-0.8391
No	3	1	No	[24, 8]	0.2	0.0182	0.1348	0.1167	-0.0318
No	3	1	No	[24, 8]	0	0.0173	0.1314	0.1169	0.0201
No	3	1	No	[29, 13, 5]	0.2	0.0181	0.1345	0.1166	-0.0266
No	3	1	No	[29, 13, 5]	0	0.1184	0.3441	0.3186	-5.7227
No	3	2	Sí	[]	0.2	0.2841	0.5330	0.4167	-1.7922
No	3	2	Sí	[]	0	0.2534	0.5033	0.4350	-1.4899
No	3	2	Sí	[32]	0.2	0.3335	0.5775	0.4741	-2.2773
No	3	2	Sí	[32]	0	0.0840	0.2899	0.2172	0.1740
No	3	2	Sí	[32, 16]	0.2	0.2556	0.5056	0.3992	-1.5121
No	3	2	Sí	[32, 16]	0	0.1070	0.3271	0.2643	-0.0514
No	3	2	Sí	[32, 16, 10]	0.2	0.1079	0.3285	0.2651	-0.0606
No	3	2	Sí	[32, 16, 10]	0	0.1095	0.3310	0.2673	-0.0765

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	3	2	Sí	[48, 16]	0.2	0.1237	0.3517	0.2851	-0.2153
No	3	2	Sí	[48, 16]	0	0.0829	0.2879	0.2481	0.1856
No	3	2	Sí	[58, 26, 10]	0.2	0.1769	0.4206	0.3264	-0.7388
No	3	2	Sí	[58, 26, 10]	0	0.1021	0.3196	0.2631	-0.0038
No	3	2	No	[]	0.2	0.1241	0.3522	0.3054	-6.0429
No	3	2	No	[]	0	0.0522	0.2285	0.1996	-1.9643
No	3	2	No	[32]	0.2	0.1142	0.3380	0.3094	-5.4848
No	3	2	No	[32]	0	0.0125	0.1118	0.0910	0.2899
No	3	2	No	[32, 16]	0.2	0.1332	0.3649	0.3379	-6.5614
No	3	2	No	[32, 16]	0	0.1445	0.3802	0.3548	-7.2060
No	3	2	No	[32, 16, 10]	0.2	0.0176	0.1328	0.1155	-0.0013
No	3	2	No	[32, 16, 10]	0	0.1720	0.4147	0.3928	-8.7631
No	3	2	No	[48, 16]	0.2	0.0259	0.1609	0.1423	-0.4695
No	3	2	No	[48, 16]	0	0.0187	0.1366	0.1138	-0.0600
No	3	2	No	[58, 26, 10]	0.2	0.1938	0.4403	0.4199	-10.0044
No	3	2	No	[58, 26, 10]	0	0.0175	0.1325	0.1174	0.0039
No	3	3	Sí	[]	0.2	0.2489	0.4989	0.4308	-1.4460
No	3	3	Sí	[]	0	0.7294	0.8541	0.6555	-6.1687
No	3	3	Sí	[48]	0.2	0.1175	0.3428	0.2803	-0.1552
No	3	3	Sí	[48]	0	0.0766	0.2768	0.2387	0.2472
No	3	3	Sí	[48, 24]	0.2	0.1039	0.3223	0.2635	-0.0212
No	3	3	Sí	[48, 24]	0	0.0961	0.3100	0.2532	0.0558
No	3	3	Sí	[48, 24, 16]	0.2	0.0980	0.3130	0.2581	0.0371
No	3	3	Sí	[48, 24, 16]	0	0.3560	0.5967	0.5031	-2.4985
No	3	3	Sí	[72, 24]	0.2	0.1041	0.3226	0.2611	-0.0230
No	3	3	Sí	[72, 24]	0	0.0978	0.3128	0.2586	0.0384
No	3	3	Sí	[88, 40, 16]	0.2	0.1059	0.3254	0.2651	-0.0407
No	3	3	Sí	[88, 40, 16]	0	0.1111	0.3333	0.2659	-0.0919
No	3	3	No	[]	0.2	0.0612	0.2475	0.1940	-2.4766
No	3	3	No	[]	0	0.1358	0.3686	0.2988	-6.7121
No	3	3	No	[48]	0.2	0.0183	0.1351	0.1085	-0.0368
No	3	3	No	[48]	0	0.1598	0.3997	0.3728	-8.0703
No	3	3	No	[48, 24]	0.2	0.0183	0.1355	0.1164	-0.0416
No	3	3	No	[48, 24]	0	0.1221	0.3495	0.3229	-5.9332
No	3	3	No	[48, 24, 16]	0.2	0.0181	0.1346	0.1186	-0.0292
No	3	3	No	[48, 24, 16]	0	0.1336	0.3655	0.3412	-6.5859
No	3	3	No	[72, 24]	0.2	0.0178	0.1335	0.1115	-0.0120
No	3	3	No	[72, 24]	0	0.0213	0.1458	0.1274	-0.2065
No	3	3	No	[88, 40, 16]	0.2	0.0938	0.3062	0.2749	-4.3228
No	3	3	No	[88, 40, 16]	0	0.0179	0.1339	0.1119	-0.0186
No	4	1	Sí	[]	0.2	0.3158	0.5620	0.4394	-2.1039
No	4	1	Sí	[]	0	0.2034	0.4510	0.4159	-0.9987
No	4	1	Sí	[16]	0.2	0.2312	0.4809	0.3788	-1.2726
No	4	1	Sí	[16]	0	0.1010	0.3177	0.2701	0.0078
No	4	1	Sí	[16, 8]	0.2	0.1331	0.3649	0.2887	-0.3082
No	4	1	Sí	[16, 8]	0	0.3727	0.6105	0.5213	-2.6628
No	4	1	Sí	[16, 8, 5]	0.2	0.1084	0.3292	0.2658	-0.0649
No	4	1	Sí	[16, 8, 5]	0	0.1108	0.3329	0.2664	-0.0890
No	4	1	Sí	[24, 8]	0.2	0.1041	0.3227	0.2661	-0.0233
No	4	1	Sí	[24, 8]	0	0.1744	0.4176	0.3179	-0.7138

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	4	1	Sí	[29, 13, 5]	0.2	0.1098	0.3314	0.2659	-0.0793
No	4	1	Sí	[29, 13, 5]	0	0.3897	0.6243	0.5361	-2.8300
No	4	1	No	[]	0.2	0.0708	0.2661	0.1775	-3.0196
No	4	1	No	[]	0	0.1812	0.4257	0.3192	-9.2887
No	4	1	No	[16]	0.2	0.0237	0.1538	0.1236	-0.3437
No	4	1	No	[16]	0	0.0577	0.2403	0.2181	-2.2783
No	4	1	No	[16, 8]	0.2	0.0172	0.1311	0.1154	0.0247
No	4	1	No	[16, 8]	0	0.0183	0.1354	0.1219	-0.0412
No	4	1	No	[16, 8, 5]	0.2	0.0182	0.1351	0.1182	-0.0355
No	4	1	No	[16, 8, 5]	0	0.1093	0.3306	0.3031	-5.2055
No	4	1	No	[24, 8]	0.2	0.1578	0.3972	0.3734	-7.9575
No	4	1	No	[24, 8]	0	0.0175	0.1323	0.1155	0.0056
No	4	1	No	[29, 13, 5]	0.2	0.1559	0.3949	0.3721	-7.8531
No	4	1	No	[29, 13, 5]	0	0.1654	0.4066	0.3845	-8.3877
No	4	2	Sí	[]	0.2	0.3293	0.5739	0.5065	-2.2364
No	4	2	Sí	[]	0	0.1645	0.4056	0.3095	-0.6165
No	4	2	Sí	[32]	0.2	0.0814	0.2854	0.2504	0.1997
No	4	2	Sí	[32]	0	0.0886	0.2977	0.2488	0.1293
No	4	2	Sí	[32, 16]	0.2	0.2588	0.5087	0.4100	-1.5436
No	4	2	Sí	[32, 16]	0	0.1066	0.3266	0.2656	-0.0480
No	4	2	Sí	[32, 16, 10]	0.2	0.1136	0.3371	0.2660	-0.1166
No	4	2	Sí	[32, 16, 10]	0	0.1076	0.3281	0.2622	-0.0577
No	4	2	Sí	[48, 16]	0.2	0.1085	0.3293	0.2684	-0.0658
No	4	2	Sí	[48, 16]	0	0.1109	0.3330	0.2623	-0.0900
No	4	2	Sí	[58, 26, 10]	0.2	0.1126	0.3356	0.2676	-0.1066
No	4	2	Sí	[58, 26, 10]	0	0.1142	0.3379	0.2685	-0.1222
No	4	2	No	[]	0.2	0.1069	0.3270	0.2262	-5.0703
No	4	2	No	[]	0	0.0952	0.3085	0.2200	-4.4033
No	4	2	No	[32]	0.2	0.0441	0.2101	0.1841	-1.5052
No	4	2	No	[32]	0	0.1654	0.4067	0.3847	-8.3916
No	4	2	No	[32, 16]	0.2	0.0171	0.1309	0.1154	0.0269
No	4	2	No	[32, 16]	0	0.1462	0.3824	0.3614	-7.3010
No	4	2	No	[32, 16, 10]	0.2	0.0186	0.1366	0.1210	-0.0586
No	4	2	No	[32, 16, 10]	0	0.1502	0.3876	0.3639	-7.5277
No	4	2	No	[48, 16]	0.2	0.0175	0.1324	0.1092	0.0055
No	4	2	No	[48, 16]	0	0.0248	0.1575	0.1380	-0.4089
No	4	2	No	[58, 26, 10]	0.2	0.0181	0.1344	0.1176	-0.0255
No	4	2	No	[58, 26, 10]	0	0.0186	0.1363	0.1185	-0.0550
No	4	3	Sí	[]	0.2	0.3049	0.5521	0.4406	-1.7914
No	4	3	Sí	[]	0	0.2226	0.4718	0.3458	-1.0385
No	4	3	Sí	[48]	0.2	0.3210	0.5666	0.4373	-1.9393
No	4	3	Sí	[48]	0	0.5300	0.7280	0.6133	-3.8533
No	4	3	Sí	[48, 24]	0.2	0.0976	0.3124	0.2625	0.1062
No	4	3	Sí	[48, 24]	0	0.0838	0.2894	0.2448	0.2331
No	4	3	Sí	[48, 24, 16]	0.2	0.1187	0.3445	0.2781	-0.0867
No	4	3	Sí	[48, 24, 16]	0	0.1139	0.3374	0.2718	-0.0425
No	4	3	Sí	[72, 24]	0.2	0.1197	0.3460	0.2771	-0.0962
No	4	3	Sí	[72, 24]	0	0.0972	0.3117	0.2584	0.1102
No	4	3	Sí	[88, 40, 16]	0.2	0.1199	0.3463	0.2756	-0.0979
No	4	3	Sí	[88, 40, 16]	0	0.1145	0.3383	0.2731	-0.0481

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	4	3	No	[]	0.2	0.2066	0.4545	0.3440	-8.9185
No	4	3	No	[]	0	0.1729	0.4159	0.3575	-7.3020
No	4	3	No	[48]	0.2	0.0373	0.1931	0.1562	-0.7902
No	4	3	No	[48]	0	0.0205	0.1431	0.1123	0.0163
No	4	3	No	[48, 24]	0.2	0.0219	0.1480	0.1292	-0.0520
No	4	3	No	[48, 24]	0	0.1323	0.3637	0.3356	-5.3495
No	4	3	No	[48, 24, 16]	0.2	0.0209	0.1445	0.1266	-0.0029
No	4	3	No	[48, 24, 16]	0	0.0211	0.1451	0.1259	-0.0110
No	4	3	No	[72, 24]	0.2	0.0196	0.1400	0.1218	0.0593
No	4	3	No	[72, 24]	0	0.0195	0.1397	0.1214	0.0635
No	4	3	No	[88, 40, 16]	0.2	0.0212	0.1457	0.1238	-0.0184
No	4	3	No	[88, 40, 16]	0	0.0221	0.1487	0.1288	-0.0618
No	5	1	Sí	[]	0.2	0.2930	0.5413	0.3762	-1.8796
No	5	1	Sí	[]	0	0.2107	0.4590	0.3647	-1.0707
No	5	1	Sí	[16]	0.2	0.1120	0.3346	0.2861	-0.1005
No	5	1	Sí	[16]	0	0.5955	0.7717	0.6745	-4.8522
No	5	1	Sí	[16, 8]	0.2	0.1144	0.3382	0.2693	-0.1239
No	5	1	Sí	[16, 8]	0	0.2881	0.5368	0.4333	-1.8314
No	5	1	Sí	[16, 8, 5]	0.2	0.1742	0.4174	0.3233	-0.7120
No	5	1	Sí	[16, 8, 5]	0	0.1108	0.3328	0.2653	-0.0888
No	5	1	Sí	[24, 8]	0.2	0.1059	0.3255	0.2610	-0.0410
No	5	1	Sí	[24, 8]	0	0.0943	0.3070	0.2472	0.0737
No	5	1	Sí	[29, 13, 5]	0.2	0.2484	0.4984	0.3879	-1.4412
No	5	1	Sí	[29, 13, 5]	0	0.1079	0.3285	0.2643	-0.0603
No	5	1	No	[]	0.2	0.2869	0.5356	0.4340	-15.2882
No	5	1	No	[]	0	0.1578	0.3972	0.3264	-7.9579
No	5	1	No	[16]	0.2	0.1517	0.3895	0.3548	-7.6124
No	5	1	No	[16]	0	0.1695	0.4117	0.3888	-8.6236
No	5	1	No	[16, 8]	0.2	0.0622	0.2494	0.2135	-2.5318
No	5	1	No	[16, 8]	0	0.1644	0.4055	0.3848	-8.3349
No	5	1	No	[16, 8, 5]	0.2	0.1850	0.4302	0.4094	-9.5052
No	5	1	No	[16, 8, 5]	0	0.0184	0.1358	0.1177	-0.0472
No	5	1	No	[24, 8]	0.2	0.0212	0.1456	0.1269	-0.2041
No	5	1	No	[24, 8]	0	0.0186	0.1364	0.1172	-0.0564
No	5	1	No	[29, 13, 5]	0.2	0.0926	0.3043	0.2746	-4.2579
No	5	1	No	[29, 13, 5]	0	0.0181	0.1344	0.1170	-0.0261
No	5	2	Sí	[]	0.2	0.2045	0.4522	0.3732	-0.8722
No	5	2	Sí	[]	0	0.1838	0.4287	0.3148	-0.6825
No	5	2	Sí	[32]	0.2	0.1621	0.4026	0.3279	-0.4844
No	5	2	Sí	[32]	0	0.5449	0.7381	0.6112	-3.9890
No	5	2	Sí	[32, 16]	0.2	0.1042	0.3228	0.2646	0.0457
No	5	2	Sí	[32, 16]	0	0.0961	0.3100	0.2575	0.1199
No	5	2	Sí	[32, 16, 10]	0.2	0.1213	0.3483	0.2776	-0.1110
No	5	2	Sí	[32, 16, 10]	0	0.1117	0.3342	0.2681	-0.0228
No	5	2	Sí	[48, 16]	0.2	0.2745	0.5240	0.4054	-1.5138
No	5	2	Sí	[48, 16]	0	0.1488	0.3858	0.3028	-0.3628
No	5	2	Sí	[58, 26, 10]	0.2	0.1179	0.3433	0.2739	-0.0792
No	5	2	Sí	[58, 26, 10]	0	0.1190	0.3450	0.2757	-0.0899
No	5	2	No	[]	0.2	0.0382	0.1955	0.1642	-0.8349
No	5	2	No	[]	0	0.0693	0.2633	0.2183	-2.3277

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	5	2	No	[32]	0.2	0.0176	0.1328	0.1085	0.1540
No	5	2	No	[32]	0	0.0276	0.1663	0.1505	-0.3271
No	5	2	No	[32, 16]	0.2	0.0209	0.1445	0.1157	-0.0027
No	5	2	No	[32, 16]	0	0.0241	0.1551	0.1329	-0.1554
No	5	2	No	[32, 16, 10]	0.2	0.1062	0.3258	0.2918	-4.0971
No	5	2	No	[32, 16, 10]	0	0.1694	0.4115	0.3852	-7.1306
No	5	2	No	[48, 16]	0.2	0.0210	0.1450	0.1278	-0.0097
No	5	2	No	[48, 16]	0	0.0188	0.1370	0.1194	0.0989
No	5	2	No	[58, 26, 10]	0.2	0.0208	0.1444	0.1253	-0.0006
No	5	2	No	[58, 26, 10]	0	0.1528	0.3909	0.3633	-6.3352
No	5	3	Sí	[]	0.2	0.3995	0.6321	0.4668	-2.6579
No	5	3	Sí	[]	0	0.2179	0.4668	0.3875	-0.9954
No	5	3	Sí	[48]	0.2	0.0873	0.2955	0.2666	0.2005
No	5	3	Sí	[48]	0	0.6810	0.8252	0.7202	-5.2356
No	5	3	Sí	[48, 24]	0.2	0.1194	0.3456	0.2799	-0.0935
No	5	3	Sí	[48, 24]	0	0.0935	0.3057	0.2538	0.1441
No	5	3	Sí	[48, 24, 16]	0.2	0.1120	0.3347	0.2682	-0.0255
No	5	3	Sí	[48, 24, 16]	0	0.1208	0.3476	0.2761	-0.1063
No	5	3	Sí	[72, 24]	0.2	0.3013	0.5489	0.4280	-1.7586
No	5	3	Sí	[72, 24]	0	0.1083	0.3290	0.2651	0.0086
No	5	3	Sí	[88, 40, 16]	0.2	0.1173	0.3424	0.2751	-0.0736
No	5	3	Sí	[88, 40, 16]	0	0.1216	0.3487	0.2788	-0.1134
No	5	3	No	[]	0.2	0.0940	0.3066	0.2772	-3.5134
No	5	3	No	[]	0	0.0325	0.1802	0.1421	-0.5583
No	5	3	No	[48]	0.2	0.0322	0.1794	0.1403	-0.5454
No	5	3	No	[48]	0	0.0183	0.1352	0.1122	0.1229
No	5	3	No	[48, 24]	0.2	0.1435	0.3788	0.3492	-5.8880
No	5	3	No	[48, 24]	0	0.0182	0.1350	0.1185	0.1245
No	5	3	No	[48, 24, 16]	0.2	0.1396	0.3737	0.3441	-5.7039
No	5	3	No	[48, 24, 16]	0	0.1370	0.3701	0.3414	-5.5754
No	5	3	No	[72, 24]	0.2	0.1297	0.3601	0.3259	-5.2241
No	5	3	No	[72, 24]	0	0.0194	0.1393	0.1176	0.0685
No	5	3	No	[88, 40, 16]	0.2	0.0204	0.1428	0.1219	0.0208
No	5	3	No	[88, 40, 16]	0	0.0210	0.1448	0.1240	-0.0060
No	6	1	Sí	[]	0.2	0.3228	0.5681	0.4226	-1.9554
No	6	1	Sí	[]	0	0.2440	0.4940	0.3982	-1.2342
No	6	1	Sí	[16]	0.2	0.1763	0.4198	0.3350	-0.6139
No	6	1	Sí	[16]	0	0.1481	0.3848	0.3178	-0.3557
No	6	1	Sí	[16, 8]	0.2	0.3467	0.5888	0.4863	-2.1741
No	6	1	Sí	[16, 8]	0	0.0861	0.2935	0.2465	0.2114
No	6	1	Sí	[16, 8, 5]	0.2	0.1175	0.3429	0.2744	-0.0763
No	6	1	Sí	[16, 8, 5]	0	0.1190	0.3450	0.2757	-0.0896
No	6	1	Sí	[24, 8]	0.2	0.1072	0.3274	0.2675	0.0187
No	6	1	Sí	[24, 8]	0	0.1374	0.3707	0.2885	-0.2581
No	6	1	Sí	[29, 13, 5]	0.2	0.1492	0.3862	0.3048	-0.3659
No	6	1	Sí	[29, 13, 5]	0	0.1095	0.3309	0.2681	-0.0028
No	6	1	No	[]	0.2	0.1575	0.3968	0.2516	-6.5589
No	6	1	No	[]	0	0.1980	0.4450	0.3376	-8.5047
No	6	1	No	[16]	0.2	0.0184	0.1357	0.1172	0.1162
No	6	1	No	[16]	0	0.0377	0.1941	0.1577	-0.8086

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	6	1	No	[16, 8]	0.2	0.0232	0.1523	0.1317	-0.1133
No	6	1	No	[16, 8]	0	0.0613	0.2476	0.2207	-1.9431
No	6	1	No	[16, 8, 5]	0.2	0.0206	0.1437	0.1255	0.0088
No	6	1	No	[16, 8, 5]	0	0.0210	0.1448	0.1262	-0.0059
No	6	1	No	[24, 8]	0.2	0.0193	0.1390	0.1212	0.0718
No	6	1	No	[24, 8]	0	0.0214	0.1462	0.1272	-0.0258
No	6	1	No	[29, 13, 5]	0.2	0.0211	0.1452	0.1264	-0.0119
No	6	1	No	[29, 13, 5]	0	0.0207	0.1437	0.1255	0.0082
No	6	2	Sí	[]	0.2	0.2865	0.5353	0.4401	-1.6238
No	6	2	Sí	[]	0	0.1611	0.4014	0.3257	-0.4755
No	6	2	Sí	[32]	0.2	0.1181	0.3437	0.2877	-0.0816
No	6	2	Sí	[32]	0	0.2164	0.4652	0.3594	-0.9815
No	6	2	Sí	[32, 16]	0.2	0.3609	0.6008	0.4895	-2.3048
No	6	2	Sí	[32, 16]	0	0.1305	0.3612	0.2841	-0.1947
No	6	2	Sí	[32, 16, 10]	0.2	0.1312	0.3622	0.2857	-0.2013
No	6	2	Sí	[32, 16, 10]	0	0.1154	0.3398	0.2713	-0.0570
No	6	2	Sí	[48, 16]	0.2	0.1158	0.3403	0.2770	-0.0605
No	6	2	Sí	[48, 16]	0	0.1004	0.3169	0.2607	0.0802
No	6	2	Sí	[58, 26, 10]	0.2	0.1080	0.3286	0.2654	0.0112
No	6	2	Sí	[58, 26, 10]	0	0.1187	0.3445	0.2748	-0.0865
No	6	2	No	[]	0.2	0.1284	0.3583	0.2971	-5.1634
No	6	2	No	[]	0	0.1014	0.3184	0.2340	-3.8671
No	6	2	No	[32]	0.2	0.2840	0.5329	0.5013	-12.6322
No	6	2	No	[32]	0	0.0249	0.1577	0.1336	-0.1943
No	6	2	No	[32, 16]	0.2	0.1703	0.4127	0.3811	-7.1755
No	6	2	No	[32, 16]	0	0.3061	0.5533	0.5277	-13.6941
No	6	2	No	[32, 16, 10]	0.2	0.0622	0.2494	0.2109	-1.9864
No	6	2	No	[32, 16, 10]	0	0.0215	0.1467	0.1272	-0.0330
No	6	2	No	[48, 16]	0.2	0.0210	0.1448	0.1272	-0.0067
No	6	2	No	[48, 16]	0	0.0190	0.1377	0.1195	0.0903
No	6	2	No	[58, 26, 10]	0.2	0.0206	0.1435	0.1250	0.0119
No	6	2	No	[58, 26, 10]	0	0.0218	0.1477	0.1292	-0.0476
No	6	3	Sí	[]	0.2	0.1894	0.4352	0.3119	-0.6690
No	6	3	Sí	[]	0	0.1883	0.4339	0.3553	-0.6588
No	6	3	Sí	[48]	0.2	0.5075	0.7124	0.5739	-3.4715
No	6	3	Sí	[48]	0	0.2242	0.4735	0.3759	-0.9754
No	6	3	Sí	[48, 24]	0.2	0.1103	0.3321	0.2640	0.0286
No	6	3	Sí	[48, 24]	0	0.1211	0.3480	0.2788	-0.0671
No	6	3	Sí	[48, 24, 16]	0.2	0.1139	0.3375	0.2718	-0.0039
No	6	3	Sí	[48, 24, 16]	0	0.1881	0.4337	0.3366	-0.6573
No	6	3	Sí	[72, 24]	0.2	0.0986	0.3140	0.2549	0.1311
No	6	3	Sí	[72, 24]	0	0.1221	0.3494	0.2751	-0.0758
No	6	3	Sí	[88, 40, 16]	0.2	0.1257	0.3546	0.2815	-0.1076
No	6	3	Sí	[88, 40, 16]	0	0.1892	0.4350	0.3368	-0.6669
No	6	3	No	[]	0.2	0.2277	0.4772	0.3853	-8.9938
No	6	3	No	[]	0	0.0667	0.2583	0.2136	-1.9293
No	6	3	No	[48]	0.2	0.0294	0.1715	0.1294	-0.2902
No	6	3	No	[48]	0	0.0124	0.1112	0.0912	0.4577
No	6	3	No	[48, 24]	0.2	0.0650	0.2550	0.2153	-1.8528
No	6	3	No	[48, 24]	0	0.1427	0.3778	0.3454	-5.2651

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	6	3	No	[48, 24, 16]	0.2	0.0214	0.1464	0.1281	0.0598
No	6	3	No	[48, 24, 16]	0	0.0235	0.1532	0.1338	-0.0303
No	6	3	No	[72, 24]	0.2	0.1261	0.3551	0.3169	-4.5345
No	6	3	No	[72, 24]	0	0.1473	0.3838	0.3565	-5.4653
No	6	3	No	[88, 40, 16]	0.2	0.1605	0.4006	0.3718	-6.0442
No	6	3	No	[88, 40, 16]	0	0.1148	0.3388	0.3031	-4.0372
No	7	1	Sí	[]	0.2	0.1942	0.4407	0.3409	-0.7780
No	7	1	Sí	[]	0	0.3660	0.6050	0.5372	-2.3511
No	7	1	Sí	[16]	0.2	0.0959	0.3096	0.2284	0.1221
No	7	1	Sí	[16]	0	0.1158	0.3403	0.2942	-0.0603
No	7	1	Sí	[16, 8]	0.2	0.1103	0.3321	0.2640	-0.0102
No	7	1	Sí	[16, 8]	0	0.1230	0.3507	0.2790	-0.1265
No	7	1	Sí	[16, 8, 5]	0.2	0.1163	0.3411	0.2723	-0.0652
No	7	1	Sí	[16, 8, 5]	0	0.1169	0.3418	0.2728	-0.0700
No	7	1	Sí	[24, 8]	0.2	0.1207	0.3475	0.2775	-0.1056
No	7	1	Sí	[24, 8]	0	0.1333	0.3651	0.2932	-0.2207
No	7	1	Sí	[29, 13, 5]	0.2	0.1196	0.3459	0.2755	-0.0956
No	7	1	Sí	[29, 13, 5]	0	0.1153	0.3396	0.2715	-0.0558
No	7	1	No	[]	0.2	0.1480	0.3847	0.2340	-6.1032
No	7	1	No	[]	0	0.0680	0.2608	0.2081	-2.2662
No	7	1	No	[16]	0.2	0.0233	0.1527	0.1290	-0.1197
No	7	1	No	[16]	0	0.0332	0.1822	0.1556	-0.5930
No	7	1	No	[16, 8]	0.2	0.0206	0.1436	0.1249	0.0106
No	7	1	No	[16, 8]	0	0.0176	0.1327	0.1137	0.1547
No	7	1	No	[16, 8, 5]	0.2	0.0495	0.2224	0.1881	-1.3743
No	7	1	No	[16, 8, 5]	0	0.0232	0.1522	0.1339	-0.1128
No	7	1	No	[24, 8]	0.2	0.0264	0.1624	0.1449	-0.2654
No	7	1	No	[24, 8]	0	0.0201	0.1418	0.1211	0.0341
No	7	1	No	[29, 13, 5]	0.2	0.0305	0.1746	0.1523	-0.4627
No	7	1	No	[29, 13, 5]	0	0.1142	0.3379	0.3054	-4.4801
No	7	2	Sí	[]	0.2	0.3356	0.5794	0.3927	-1.9573
No	7	2	Sí	[]	0	0.2051	0.4528	0.3807	-0.8067
No	7	2	Sí	[32]	0.2	0.0613	0.2476	0.2084	0.4597
No	7	2	Sí	[32]	0	0.4744	0.6888	0.5674	-3.1802
No	7	2	Sí	[32, 16]	0.2	0.1145	0.3384	0.2704	-0.0087
No	7	2	Sí	[32, 16]	0	0.1244	0.3528	0.2854	-0.0965
No	7	2	Sí	[32, 16, 10]	0.2	0.1375	0.3707	0.2906	-0.2110
No	7	2	Sí	[32, 16, 10]	0	0.1263	0.3554	0.2835	-0.1127
No	7	2	Sí	[48, 16]	0.2	0.1246	0.3529	0.2848	-0.0974
No	7	2	Sí	[48, 16]	0	0.1351	0.3676	0.2942	-0.1904
No	7	2	Sí	[58, 26, 10]	0.2	0.1260	0.3550	0.2824	-0.1105
No	7	2	Sí	[58, 26, 10]	0	0.1259	0.3548	0.2815	-0.1092
No	7	2	No	[]	0.2	0.1152	0.3393	0.2782	-4.0541
No	7	2	No	[]	0	0.1383	0.3719	0.2868	-5.0703
No	7	2	No	[32]	0.2	0.0317	0.1781	0.1477	-0.3915
No	7	2	No	[32]	0	0.0645	0.2540	0.2113	-1.8306
No	7	2	No	[32, 16]	0.2	0.0189	0.1376	0.1209	0.1685
No	7	2	No	[32, 16]	0	0.0223	0.1494	0.1313	0.0208
No	7	2	No	[32, 16, 10]	0.2	0.0227	0.1507	0.1302	0.0031
No	7	2	No	[32, 16, 10]	0	0.2073	0.4553	0.4291	-8.0968

Continúa en la siguiente página

Sum.	Lags	Prev.	Log	H.L.	Drop	MSE	RMSE	MAE	R2
No	7	2	No	[48, 16]	0.2	0.0228	0.1511	0.1297	-0.0021
No	7	2	No	[48, 16]	0	0.1090	0.3301	0.2920	-3.7819
No	7	2	No	[58, 26, 10]	0.2	0.1333	0.3651	0.3330	-4.8503
No	7	2	No	[58, 26, 10]	0	0.0234	0.1531	0.1318	-0.0285
No	7	3	Sí	[]	0.2	0.2538	0.5038	0.4670	-1.0496
No	7	3	Sí	[]	0	0.1519	0.3898	0.3156	-0.2271
No	7	3	Sí	[48]	0.2	0.1116	0.3340	0.2692	0.0990
No	7	3	Sí	[48]	0	0.1306	0.3614	0.2789	-0.0551
No	7	3	Sí	[48, 24]	0.2	0.1368	0.3699	0.2963	-0.1049
No	7	3	Sí	[48, 24]	0	0.4163	0.6452	0.5254	-2.3623
No	7	3	Sí	[48, 24, 16]	0.2	0.1282	0.3581	0.2856	-0.0354
No	7	3	Sí	[48, 24, 16]	0	0.1323	0.3638	0.2902	-0.0688
No	7	3	Sí	[72, 24]	0.2	0.3298	0.5743	0.4493	-1.6633
No	7	3	Sí	[72, 24]	0	0.1152	0.3395	0.2725	0.0692
No	7	3	Sí	[88, 40, 16]	0.2	0.3035	0.5509	0.4322	-1.4512
No	7	3	Sí	[88, 40, 16]	0	0.3758	0.6130	0.5020	-2.0352
No	7	3	No	[]	0.2	0.0726	0.2695	0.2279	-1.6136
No	7	3	No	[]	0	0.1713	0.4139	0.3557	-5.1672
No	7	3	No	[48]	0.2	0.0645	0.2539	0.2156	-1.3206
No	7	3	No	[48]	0	0.0319	0.1787	0.1478	-0.1489
No	7	3	No	[48, 24]	0.2	0.0239	0.1546	0.1333	0.1393
No	7	3	No	[48, 24]	0	0.0752	0.2743	0.2327	-1.7081
No	7	3	No	[48, 24, 16]	0.2	0.0283	0.1682	0.1460	-0.0180
No	7	3	No	[48, 24, 16]	0	0.0268	0.1638	0.1416	0.0344
No	7	3	No	[72, 24]	0.2	0.0326	0.1804	0.1562	-0.1720
No	7	3	No	[72, 24]	0	0.1699	0.4122	0.3739	-5.1172
No	7	3	No	[88, 40, 16]	0.2	0.0297	0.1723	0.1513	-0.0691
No	7	3	No	[88, 40, 16]	0	0.0300	0.1731	0.1525	-0.0785

Fin de la tabla

APÉNDICE E

Tabla comparativa de configuraciones de estimador: red neuronal recurrente

En esta búsqueda exhaustiva se han entrenado y evaluado 1008 configuraciones.

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	1	Sí	2	[10]	[1]	0.2	0.0846	0.2908	0.2537	-0.0079
Sí	1	Sí	2	[10]	[1]	0	0.0843	0.2904	0.2473	-0.0047
Sí	1	Sí	2	[10, 10]	[1]	0.2	0.2684	0.5181	0.4327	-2.1987
Sí	1	Sí	2	[10, 10]	[1]	0	0.2780	0.5273	0.4422	-2.3131
Sí	1	Sí	2	[10]	[1, 1]	0.2	0.2770	0.5263	0.4409	-2.3003
Sí	1	Sí	2	[10]	[1, 1]	0	0.2761	0.5254	0.4409	-2.2896
Sí	1	Sí	2	[10, 10]	[1, 1]	0.2	0.2854	0.5342	0.4499	-2.4005
Sí	1	Sí	2	[10, 10]	[1, 1]	0	0.2799	0.5290	0.4428	-2.3350
Sí	1	Sí	2	[10]	[2, 1]	0.2	0.2850	0.5338	0.4481	-2.3956
Sí	1	Sí	2	[10]	[2, 1]	0	0.0912	0.3020	0.2422	-0.0870
Sí	1	Sí	2	[10, 10]	[2, 1]	0.2	0.2748	0.5242	0.4408	-2.2742
Sí	1	Sí	2	[10, 10]	[2, 1]	0	0.2139	0.4625	0.3748	-1.5490
Sí	1	Sí	3	[10]	[1]	0.2	0.1707	0.4132	0.3366	-1.1596
Sí	1	Sí	3	[10]	[1]	0	0.0834	0.2888	0.2565	-0.0549
Sí	1	Sí	3	[10, 10]	[1]	0.2	0.1692	0.4114	0.3362	-1.1409
Sí	1	Sí	3	[10, 10]	[1]	0	0.1521	0.3900	0.3097	-0.9246
Sí	1	Sí	3	[10]	[1, 1]	0.2	0.2013	0.4487	0.3679	-1.5466
Sí	1	Sí	3	[10]	[1, 1]	0	0.3098	0.5566	0.4805	-2.9193
Sí	1	Sí	3	[10, 10]	[1, 1]	0.2	0.2371	0.4870	0.4115	-2.0000
Sí	1	Sí	3	[10, 10]	[1, 1]	0	0.1874	0.4328	0.3574	-1.3702
Sí	1	Sí	3	[10]	[2, 1]	0.2	0.2326	0.4823	0.4069	-1.9428
Sí	1	Sí	3	[10]	[2, 1]	0	0.2605	0.5104	0.4351	-2.2955
Sí	1	Sí	3	[10, 10]	[2, 1]	0.2	0.2118	0.4602	0.3837	-1.6790
Sí	1	Sí	3	[10, 10]	[2, 1]	0	0.2043	0.4520	0.3714	-1.5842
Sí	1	Sí	5	[10]	[1]	0.2	0.3085	0.5554	0.4956	-3.8356
Sí	1	Sí	5	[10]	[1]	0	0.0484	0.2199	0.1774	0.2417
Sí	1	Sí	5	[10, 10]	[1]	0.2	0.2876	0.5363	0.4734	-3.5093
Sí	1	Sí	5	[10, 10]	[1]	0	0.0762	0.2761	0.2283	-0.1948
Sí	1	Sí	5	[10]	[1, 1]	0.2	0.1292	0.3594	0.2929	-1.0251
Sí	1	Sí	5	[10]	[1, 1]	0	0.1013	0.3182	0.2688	-0.5874

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	1	Sí	5	[10, 10]	[1, 1]	0.2	0.1252	0.3538	0.2875	-0.9620
Sí	1	Sí	5	[10, 10]	[1, 1]	0	0.3608	0.6006	0.5449	-4.6558
Sí	1	Sí	5	[10]	[2, 1]	0.2	0.2851	0.5339	0.4695	-3.4692
Sí	1	Sí	5	[10]	[2, 1]	0	0.3973	0.6303	0.5781	-5.2288
Sí	1	Sí	5	[10, 10]	[2, 1]	0.2	0.1187	0.3445	0.2803	-0.8609
Sí	1	Sí	5	[10, 10]	[2, 1]	0	0.1121	0.3348	0.2614	-0.7568
Sí	1	No	2	[10]	[1]	0.2	0.0185	0.1359	0.1044	-0.6631
Sí	1	No	2	[10]	[1]	0	0.0288	0.1698	0.1372	-1.5987
Sí	1	No	2	[10, 10]	[1]	0.2	0.0166	0.1290	0.1000	-0.4990
Sí	1	No	2	[10, 10]	[1]	0	0.0238	0.1544	0.1193	-1.1487
Sí	1	No	2	[10]	[1, 1]	0.2	0.0263	0.1623	0.1238	-1.3731
Sí	1	No	2	[10]	[1, 1]	0	0.0408	0.2020	0.1806	-2.6752
Sí	1	No	2	[10, 10]	[1, 1]	0.2	0.0264	0.1625	0.1239	-1.3795
Sí	1	No	2	[10, 10]	[1, 1]	0	0.0913	0.3021	0.2832	-7.2229
Sí	1	No	2	[10]	[2, 1]	0.2	0.1026	0.3203	0.3025	-8.2427
Sí	1	No	2	[10]	[2, 1]	0	0.0257	0.1602	0.1231	-1.3112
Sí	1	No	2	[10, 10]	[2, 1]	0.2	0.0261	0.1615	0.1232	-1.3514
Sí	1	No	2	[10, 10]	[2, 1]	0	0.0269	0.1639	0.1265	-1.4209
Sí	1	No	3	[10]	[1]	0.2	0.0173	0.1316	0.0977	-0.7500
Sí	1	No	3	[10]	[1]	0	0.0221	0.1487	0.1109	-1.2351
Sí	1	No	3	[10, 10]	[1]	0.2	0.0153	0.1237	0.0910	-0.5476
Sí	1	No	3	[10, 10]	[1]	0	0.0168	0.1295	0.0965	-0.6943
Sí	1	No	3	[10]	[1, 1]	0.2	0.0213	0.1459	0.1089	-1.1517
Sí	1	No	3	[10]	[1, 1]	0	0.0195	0.1398	0.1031	-0.9762
Sí	1	No	3	[10, 10]	[1, 1]	0.2	0.1083	0.3291	0.3137	-9.9455
Sí	1	No	3	[10, 10]	[1, 1]	0	0.0960	0.3098	0.2935	-8.7024
Sí	1	No	3	[10]	[2, 1]	0.2	0.0979	0.3130	0.2969	-8.9006
Sí	1	No	3	[10]	[2, 1]	0	0.0192	0.1386	0.1021	-0.9428
Sí	1	No	3	[10, 10]	[2, 1]	0.2	0.0854	0.2923	0.2752	-7.6367
Sí	1	No	3	[10, 10]	[2, 1]	0	0.0196	0.1399	0.1033	-0.9781
Sí	1	No	5	[10]	[1]	0.2	0.0066	0.0813	0.0627	-0.2783
Sí	1	No	5	[10]	[1]	0	0.0109	0.1044	0.0788	-1.1082
Sí	1	No	5	[10, 10]	[1]	0.2	0.0404	0.2009	0.1885	-6.8020
Sí	1	No	5	[10, 10]	[1]	0	0.1190	0.3449	0.3373	-22.0028
Sí	1	No	5	[10]	[1, 1]	0.2	0.0059	0.0768	0.0654	-0.1413
Sí	1	No	5	[10]	[1, 1]	0	0.0054	0.0737	0.0648	-0.0490
Sí	1	No	5	[10, 10]	[1, 1]	0.2	0.0052	0.0722	0.0629	-0.0074
Sí	1	No	5	[10, 10]	[1, 1]	0	0.1251	0.3537	0.3463	-23.1942
Sí	1	No	5	[10]	[2, 1]	0.2	0.0088	0.0940	0.0713	-0.7088
Sí	1	No	5	[10]	[2, 1]	0	0.0106	0.1029	0.0776	-1.0491
Sí	1	No	5	[10, 10]	[2, 1]	0.2	0.0072	0.0849	0.0709	-0.3933
Sí	1	No	5	[10, 10]	[2, 1]	0	0.0103	0.1013	0.0764	-0.9824
Sí	2	Sí	2	[10]	[1]	0.2	0.0937	0.3062	0.2595	-0.0125
Sí	2	Sí	2	[10]	[1]	0	0.2950	0.5432	0.4579	-2.1871
Sí	2	Sí	2	[10, 10]	[1]	0.2	0.1947	0.4412	0.3533	-1.1028
Sí	2	Sí	2	[10, 10]	[1]	0	0.1289	0.3590	0.2964	-0.3924
Sí	2	Sí	2	[10]	[1, 1]	0.2	0.1574	0.3967	0.3110	-0.7001
Sí	2	Sí	2	[10]	[1, 1]	0	0.2069	0.4549	0.3837	-1.2350
Sí	2	Sí	2	[10, 10]	[1, 1]	0.2	0.1199	0.3462	0.3106	-0.2947
Sí	2	Sí	2	[10, 10]	[1, 1]	0	0.1661	0.4075	0.3202	-0.7941

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	2	Sí	2	[10]	[2, 1]	0.2	0.2714	0.5209	0.4308	-1.9315
Sí	2	Sí	2	[10]	[2, 1]	0	0.3053	0.5525	0.4634	-2.2976
Sí	2	Sí	2	[10, 10]	[2, 1]	0.2	0.1472	0.3837	0.3000	-0.5903
Sí	2	Sí	2	[10, 10]	[2, 1]	0	0.2350	0.4848	0.4047	-1.5383
Sí	2	Sí	3	[10]	[1]	0.2	0.2093	0.4575	0.3783	-1.4004
Sí	2	Sí	3	[10]	[1]	0	0.2028	0.4503	0.3734	-1.3257
Sí	2	Sí	3	[10, 10]	[1]	0.2	0.2175	0.4664	0.3869	-1.4945
Sí	2	Sí	3	[10, 10]	[1]	0	0.2297	0.4793	0.3944	-1.6344
Sí	2	Sí	3	[10]	[1, 1]	0.2	0.2173	0.4661	0.3836	-1.4917
Sí	2	Sí	3	[10]	[1, 1]	0	0.1216	0.3487	0.3083	-0.3941
Sí	2	Sí	3	[10, 10]	[1, 1]	0.2	0.2214	0.4705	0.3872	-1.5390
Sí	2	Sí	3	[10, 10]	[1, 1]	0	0.0909	0.3014	0.2515	-0.0420
Sí	2	Sí	3	[10]	[2, 1]	0.2	0.1095	0.3309	0.2569	-0.2558
Sí	2	Sí	3	[10]	[2, 1]	0	0.1344	0.3666	0.3187	-0.5417
Sí	2	Sí	3	[10, 10]	[2, 1]	0.2	0.1146	0.3385	0.3016	-0.3139
Sí	2	Sí	3	[10, 10]	[2, 1]	0	0.2123	0.4608	0.3808	-1.4348
Sí	2	Sí	5	[10]	[1]	0.2	0.2012	0.4485	0.3718	-1.8587
Sí	2	Sí	5	[10]	[1]	0	0.0416	0.2040	0.1723	0.4084
Sí	2	Sí	5	[10, 10]	[1]	0.2	0.0850	0.2916	0.2417	-0.2082
Sí	2	Sí	5	[10, 10]	[1]	0	0.0738	0.2716	0.2359	-0.0486
Sí	2	Sí	5	[10]	[1, 1]	0.2	0.0801	0.2830	0.2601	-0.1378
Sí	2	Sí	5	[10]	[1, 1]	0	0.1406	0.3749	0.3049	-0.9978
Sí	2	Sí	5	[10, 10]	[1, 1]	0.2	0.4005	0.6328	0.5744	-4.6912
Sí	2	Sí	5	[10, 10]	[1, 1]	0	0.1439	0.3794	0.3071	-1.0452
Sí	2	Sí	5	[10]	[2, 1]	0.2	0.3477	0.5897	0.5276	-3.9415
Sí	2	Sí	5	[10]	[2, 1]	0	0.1455	0.3814	0.3091	-1.0671
Sí	2	Sí	5	[10, 10]	[2, 1]	0.2	0.1418	0.3765	0.3074	-1.0149
Sí	2	Sí	5	[10, 10]	[2, 1]	0	0.3285	0.5731	0.5079	-3.6683
Sí	2	No	2	[10]	[1]	0.2	0.0574	0.2395	0.2149	-3.0618
Sí	2	No	2	[10]	[1]	0	0.0272	0.1650	0.1452	-0.9276
Sí	2	No	2	[10, 10]	[1]	0.2	0.0683	0.2613	0.2362	-3.8354
Sí	2	No	2	[10, 10]	[1]	0	0.0143	0.1197	0.0973	-0.0153
Sí	2	No	2	[10]	[1, 1]	0.2	0.0346	0.1860	0.1430	-1.4506
Sí	2	No	2	[10]	[1, 1]	0	0.1034	0.3216	0.2990	-6.3255
Sí	2	No	2	[10, 10]	[1, 1]	0.2	0.1245	0.3529	0.3322	-7.8196
Sí	2	No	2	[10, 10]	[1, 1]	0	0.0324	0.1801	0.1596	-1.2974
Sí	2	No	2	[10]	[2, 1]	0.2	0.0341	0.1846	0.1416	-1.4135
Sí	2	No	2	[10]	[2, 1]	0	0.0161	0.1268	0.1004	-0.1385
Sí	2	No	2	[10, 10]	[2, 1]	0.2	0.0328	0.1810	0.1374	-1.3205
Sí	2	No	2	[10, 10]	[2, 1]	0	0.0329	0.1813	0.1376	-1.3272
Sí	2	No	3	[10]	[1]	0.2	0.0223	0.1494	0.1119	-0.7734
Sí	2	No	3	[10]	[1]	0	0.0250	0.1581	0.1178	-0.9867
Sí	2	No	3	[10, 10]	[1]	0.2	0.0439	0.2096	0.1922	-2.4917
Sí	2	No	3	[10, 10]	[1]	0	0.0165	0.1283	0.1063	-0.3075
Sí	2	No	3	[10]	[1, 1]	0.2	0.0239	0.1544	0.1145	-0.8951
Sí	2	No	3	[10]	[1, 1]	0	0.1635	0.4043	0.3884	-11.9905
Sí	2	No	3	[10, 10]	[1, 1]	0.2	0.0268	0.1638	0.1215	-1.1322
Sí	2	No	3	[10, 10]	[1, 1]	0	0.1281	0.3579	0.3398	-9.1747
Sí	2	No	3	[10]	[2, 1]	0.2	0.1246	0.3530	0.3348	-8.9026
Sí	2	No	3	[10]	[2, 1]	0	0.0255	0.1598	0.1183	-1.0288

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	2	No	3	[10, 10]	[2, 1]	0.2	0.1164	0.3412	0.3222	-8.2475
Sí	2	No	3	[10, 10]	[2, 1]	0	0.0260	0.1612	0.1190	-1.0648
Sí	2	No	5	[10]	[1]	0.2	0.0602	0.2453	0.2323	-8.1420
Sí	2	No	5	[10]	[1]	0	0.0436	0.2088	0.1954	-5.6258
Sí	2	No	5	[10, 10]	[1]	0.2	0.0398	0.1996	0.1844	-5.0519
Sí	2	No	5	[10, 10]	[1]	0	0.0100	0.1002	0.0843	-0.5249
Sí	2	No	5	[10]	[1, 1]	0.2	0.0130	0.1140	0.0862	-0.9754
Sí	2	No	5	[10]	[1, 1]	0	0.1647	0.4058	0.3977	-24.0325
Sí	2	No	5	[10, 10]	[1, 1]	0.2	0.0131	0.1146	0.0866	-0.9966
Sí	2	No	5	[10, 10]	[1, 1]	0	0.0141	0.1186	0.0893	-1.1386
Sí	2	No	5	[10]	[2, 1]	0.2	0.0075	0.0869	0.0739	-0.1474
Sí	2	No	5	[10]	[2, 1]	0	0.0133	0.1152	0.0866	-1.0177
Sí	2	No	5	[10, 10]	[2, 1]	0.2	0.0137	0.1171	0.0881	-1.0831
Sí	2	No	5	[10, 10]	[2, 1]	0	0.0892	0.2986	0.2876	-12.5518
Sí	3	Sí	2	[10]	[1]	0.2	0.1111	0.3334	0.2617	-0.1881
Sí	3	Sí	2	[10]	[1]	0	0.1809	0.4253	0.3385	-0.9336
Sí	3	Sí	2	[10, 10]	[1]	0.2	0.3084	0.5554	0.4674	-2.2973
Sí	3	Sí	2	[10, 10]	[1]	0	0.0937	0.3060	0.2619	-0.0013
Sí	3	Sí	2	[10]	[1, 1]	0.2	0.3044	0.5518	0.4612	-2.2548
Sí	3	Sí	2	[10]	[1, 1]	0	0.2548	0.5047	0.4131	-1.7236
Sí	3	Sí	2	[10, 10]	[1, 1]	0.2	0.3038	0.5512	0.4596	-2.2479
Sí	3	Sí	2	[10, 10]	[1, 1]	0	0.2932	0.5415	0.4514	-2.1347
Sí	3	Sí	2	[10]	[2, 1]	0.2	0.1145	0.3383	0.2647	-0.2237
Sí	3	Sí	2	[10]	[2, 1]	0	0.1260	0.3550	0.2756	-0.3472
Sí	3	Sí	2	[10, 10]	[2, 1]	0.2	0.3155	0.5617	0.4712	-2.3729
Sí	3	Sí	2	[10, 10]	[2, 1]	0	0.1358	0.3685	0.3274	-0.4519
Sí	3	Sí	3	[10]	[1]	0.2	0.2112	0.4596	0.3820	-1.3974
Sí	3	Sí	3	[10]	[1]	0	0.0992	0.3149	0.2530	-0.1256
Sí	3	Sí	3	[10, 10]	[1]	0.2	0.1644	0.4054	0.3417	-0.8656
Sí	3	Sí	3	[10, 10]	[1]	0	0.2194	0.4684	0.3842	-1.4906
Sí	3	Sí	3	[10]	[1, 1]	0.2	0.3626	0.6022	0.5199	-3.1155
Sí	3	Sí	3	[10]	[1, 1]	0	0.2179	0.4667	0.3834	-1.4726
Sí	3	Sí	3	[10, 10]	[1, 1]	0.2	0.1864	0.4318	0.3461	-1.1160
Sí	3	Sí	3	[10, 10]	[1, 1]	0	0.1727	0.4156	0.3306	-0.9603
Sí	3	Sí	3	[10]	[2, 1]	0.2	0.2128	0.4614	0.3771	-1.4158
Sí	3	Sí	3	[10]	[2, 1]	0	0.2118	0.4602	0.3752	-1.4043
Sí	3	Sí	3	[10, 10]	[2, 1]	0.2	0.3665	0.6054	0.5245	-3.1596
Sí	3	Sí	3	[10, 10]	[2, 1]	0	0.2244	0.4737	0.3886	-1.5468
Sí	3	Sí	5	[10]	[1]	0.2	0.2242	0.4735	0.3987	-2.1531
Sí	3	Sí	5	[10]	[1]	0	0.1550	0.3937	0.3182	-1.1799
Sí	3	Sí	5	[10, 10]	[1]	0.2	0.0833	0.2886	0.2408	-0.1715
Sí	3	Sí	5	[10, 10]	[1]	0	0.0835	0.2889	0.2485	-0.1741
Sí	3	Sí	5	[10]	[1, 1]	0.2	0.0731	0.2703	0.2498	-0.0279
Sí	3	Sí	5	[10]	[1, 1]	0	0.1464	0.3826	0.3118	-1.0587
Sí	3	Sí	5	[10, 10]	[1, 1]	0.2	0.3037	0.5511	0.4825	-3.2713
Sí	3	Sí	5	[10, 10]	[1, 1]	0	0.0894	0.2990	0.2679	-0.2571
Sí	3	Sí	5	[10]	[2, 1]	0.2	0.1395	0.3735	0.3052	-0.9622
Sí	3	Sí	5	[10]	[2, 1]	0	0.1415	0.3762	0.3075	-0.9904
Sí	3	Sí	5	[10, 10]	[2, 1]	0.2	0.2744	0.5239	0.4511	-2.8600
Sí	3	Sí	5	[10, 10]	[2, 1]	0	0.1426	0.3776	0.3089	-1.0050

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	3	No	2	[10]	[1]	0.2	0.0368	0.1920	0.1499	-1.5452
Sí	3	No	2	[10]	[1]	0	0.0465	0.2157	0.1897	-2.2130
Sí	3	No	2	[10, 10]	[1]	0.2	0.0275	0.1658	0.1458	-0.9000
Sí	3	No	2	[10, 10]	[1]	0	0.0165	0.1285	0.1079	-0.1409
Sí	3	No	2	[10]	[1, 1]	0.2	0.0359	0.1895	0.1467	-1.4799
Sí	3	No	2	[10]	[1, 1]	0	0.0332	0.1823	0.1385	-1.2950
Sí	3	No	2	[10, 10]	[1, 1]	0.2	0.0357	0.1890	0.1458	-1.4669
Sí	3	No	2	[10, 10]	[1, 1]	0	0.1277	0.3574	0.3365	-7.8220
Sí	3	No	2	[10]	[2, 1]	0.2	0.0295	0.1719	0.1517	-1.0402
Sí	3	No	2	[10]	[2, 1]	0	0.0514	0.2268	0.2024	-2.5517
Sí	3	No	2	[10, 10]	[2, 1]	0.2	0.1084	0.3293	0.3066	-6.4910
Sí	3	No	2	[10, 10]	[2, 1]	0	0.0879	0.2965	0.2709	-5.0708
Sí	3	No	3	[10]	[1]	0.2	0.0215	0.1467	0.1054	-0.6671
Sí	3	No	3	[10]	[1]	0	0.0271	0.1648	0.1215	-1.1038
Sí	3	No	3	[10, 10]	[1]	0.2	0.0220	0.1484	0.1084	-0.7061
Sí	3	No	3	[10, 10]	[1]	0	0.0233	0.1527	0.1110	-0.8059
Sí	3	No	3	[10]	[1, 1]	0.2	0.0831	0.2882	0.2663	-5.4382
Sí	3	No	3	[10]	[1, 1]	0	0.0937	0.3060	0.2844	-6.2581
Sí	3	No	3	[10, 10]	[1, 1]	0.2	0.0263	0.1623	0.1198	-1.0415
Sí	3	No	3	[10, 10]	[1, 1]	0	0.0255	0.1598	0.1180	-0.9787
Sí	3	No	3	[10]	[2, 1]	0.2	0.0252	0.1588	0.1169	-0.9543
Sí	3	No	3	[10]	[2, 1]	0	0.0258	0.1605	0.1184	-0.9967
Sí	3	No	3	[10, 10]	[2, 1]	0.2	0.0277	0.1664	0.1235	-1.1459
Sí	3	No	3	[10, 10]	[2, 1]	0	0.0928	0.3046	0.2827	-6.1923
Sí	3	No	5	[10]	[1]	0.2	0.0110	0.1049	0.0790	-0.6316
Sí	3	No	5	[10]	[1]	0	0.0111	0.1055	0.0802	-0.6485
Sí	3	No	5	[10, 10]	[1]	0.2	0.0089	0.0942	0.0756	-0.3167
Sí	3	No	5	[10, 10]	[1]	0	0.0137	0.1171	0.0892	-1.0343
Sí	3	No	5	[10]	[1, 1]	0.2	0.1215	0.3486	0.3388	-17.0154
Sí	3	No	5	[10]	[1, 1]	0	0.0209	0.1446	0.1246	-2.0983
Sí	3	No	5	[10, 10]	[1, 1]	0.2	0.0125	0.1119	0.0851	-0.8571
Sí	3	No	5	[10, 10]	[1, 1]	0	0.0858	0.2929	0.2812	-11.7204
Sí	3	No	5	[10]	[2, 1]	0.2	0.0133	0.1152	0.0872	-0.9686
Sí	3	No	5	[10]	[2, 1]	0	0.0711	0.2666	0.2545	-9.5376
Sí	3	No	5	[10, 10]	[2, 1]	0.2	0.0219	0.1480	0.1280	-2.2479
Sí	3	No	5	[10, 10]	[2, 1]	0	0.1418	0.3766	0.3675	-20.0251
Sí	4	Sí	2	[10]	[1]	0.2	0.1117	0.3343	0.3001	-0.1945
Sí	4	Sí	2	[10]	[1]	0	0.2590	0.5089	0.4245	-1.7689
Sí	4	Sí	2	[10, 10]	[1]	0.2	0.2396	0.4895	0.4089	-1.5614
Sí	4	Sí	2	[10, 10]	[1]	0	0.2829	0.5319	0.4425	-2.0247
Sí	4	Sí	2	[10]	[1, 1]	0.2	0.1623	0.4029	0.3492	-0.7354
Sí	4	Sí	2	[10]	[1, 1]	0	0.2107	0.4591	0.3870	-1.2531
Sí	4	Sí	2	[10, 10]	[1, 1]	0.2	0.3460	0.5882	0.4945	-2.6991
Sí	4	Sí	2	[10, 10]	[1, 1]	0	0.1288	0.3589	0.3206	-0.3773
Sí	4	Sí	2	[10]	[2, 1]	0.2	0.1111	0.3333	0.2993	-0.1877
Sí	4	Sí	2	[10]	[2, 1]	0	0.2091	0.4572	0.3699	-1.2349
Sí	4	Sí	2	[10, 10]	[2, 1]	0.2	0.2480	0.4980	0.4142	-1.6509
Sí	4	Sí	2	[10, 10]	[2, 1]	0	0.1283	0.3582	0.2777	-0.3715
Sí	4	Sí	3	[10]	[1]	0.2	0.2004	0.4477	0.3723	-1.2747
Sí	4	Sí	3	[10]	[1]	0	0.1000	0.3163	0.2530	-0.1352

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	4	Sí	3	[10, 10]	[1]	0.2	0.2014	0.4488	0.3720	-1.2864
Sí	4	Sí	3	[10, 10]	[1]	0	0.1511	0.3887	0.3040	-0.7145
Sí	4	Sí	3	[10]	[1, 1]	0.2	0.3372	0.5807	0.4993	-2.8276
Sí	4	Sí	3	[10]	[1, 1]	0	0.2090	0.4571	0.3761	-1.3718
Sí	4	Sí	3	[10, 10]	[1, 1]	0.2	0.0922	0.3037	0.2691	-0.0468
Sí	4	Sí	3	[10, 10]	[1, 1]	0	0.1085	0.3294	0.2954	-0.2318
Sí	4	Sí	3	[10]	[2, 1]	0.2	0.0975	0.3122	0.2531	-0.1064
Sí	4	Sí	3	[10]	[2, 1]	0	0.2301	0.4796	0.3943	-1.6111
Sí	4	Sí	3	[10, 10]	[2, 1]	0.2	0.1610	0.4012	0.3163	-0.8269
Sí	4	Sí	3	[10, 10]	[2, 1]	0	0.2218	0.4710	0.3867	-1.5178
Sí	4	Sí	5	[10]	[1]	0.2	0.2229	0.4722	0.3906	-2.1354
Sí	4	Sí	5	[10]	[1]	0	0.1959	0.4426	0.3763	-1.7557
Sí	4	Sí	5	[10, 10]	[1]	0.2	0.0788	0.2808	0.2368	-0.1087
Sí	4	Sí	5	[10, 10]	[1]	0	0.0988	0.3144	0.2598	-0.3900
Sí	4	Sí	5	[10]	[1, 1]	0.2	0.1482	0.3850	0.3119	-1.0846
Sí	4	Sí	5	[10]	[1, 1]	0	0.1404	0.3748	0.3070	-0.9753
Sí	4	Sí	5	[10, 10]	[1, 1]	0.2	0.1494	0.3865	0.3132	-1.1015
Sí	4	Sí	5	[10, 10]	[1, 1]	0	0.0715	0.2675	0.2452	-0.0062
Sí	4	Sí	5	[10]	[2, 1]	0.2	0.1050	0.3240	0.2776	-0.4769
Sí	4	Sí	5	[10]	[2, 1]	0	0.2461	0.4961	0.4257	-2.4612
Sí	4	Sí	5	[10, 10]	[2, 1]	0.2	0.3863	0.6216	0.5612	-4.4337
Sí	4	Sí	5	[10, 10]	[2, 1]	0	0.3597	0.5997	0.5371	-4.0589
Sí	4	No	2	[10]	[1]	0.2	0.0317	0.1781	0.1347	-1.1901
Sí	4	No	2	[10]	[1]	0	0.0200	0.1414	0.1101	-0.3808
Sí	4	No	2	[10, 10]	[1]	0.2	0.0219	0.1481	0.1095	-0.5147
Sí	4	No	2	[10, 10]	[1]	0	0.0435	0.2086	0.1857	-2.0048
Sí	4	No	2	[10]	[1, 1]	0.2	0.0220	0.1484	0.1290	-0.5215
Sí	4	No	2	[10]	[1, 1]	0	0.0343	0.1852	0.1410	-1.3688
Sí	4	No	2	[10, 10]	[1, 1]	0.2	0.0159	0.1261	0.1003	-0.0985
Sí	4	No	2	[10, 10]	[1, 1]	0	0.0720	0.2684	0.2428	-3.9765
Sí	4	No	2	[10]	[2, 1]	0.2	0.0304	0.1745	0.1306	-1.1028
Sí	4	No	2	[10]	[2, 1]	0	0.0679	0.2606	0.2355	-3.6926
Sí	4	No	2	[10, 10]	[2, 1]	0.2	0.1143	0.3381	0.3160	-6.8980
Sí	4	No	2	[10, 10]	[2, 1]	0	0.0361	0.1900	0.1471	-1.4936
Sí	4	No	3	[10]	[1]	0.2	0.0266	0.1632	0.1208	-1.0640
Sí	4	No	3	[10]	[1]	0	0.0490	0.2213	0.2057	-2.7963
Sí	4	No	3	[10, 10]	[1]	0.2	0.0268	0.1639	0.1439	-1.0807
Sí	4	No	3	[10, 10]	[1]	0	0.0216	0.1470	0.1269	-0.6740
Sí	4	No	3	[10]	[1, 1]	0.2	0.0635	0.2520	0.2330	-3.9226
Sí	4	No	3	[10]	[1, 1]	0	0.1183	0.3439	0.3246	-8.1646
Sí	4	No	3	[10, 10]	[1, 1]	0.2	0.0273	0.1651	0.1222	-1.1136
Sí	4	No	3	[10, 10]	[1, 1]	0	0.0623	0.2496	0.2308	-3.8288
Sí	4	No	3	[10]	[2, 1]	0.2	0.0257	0.1603	0.1183	-0.9905
Sí	4	No	3	[10]	[2, 1]	0	0.0163	0.1275	0.0979	-0.2601
Sí	4	No	3	[10, 10]	[2, 1]	0.2	0.0185	0.1360	0.1146	-0.4344
Sí	4	No	3	[10, 10]	[2, 1]	0	0.0267	0.1633	0.1204	-1.0653
Sí	4	No	5	[10]	[1]	0.2	0.0588	0.2424	0.2285	-7.7107
Sí	4	No	5	[10]	[1]	0	0.0133	0.1155	0.0874	-0.9786
Sí	4	No	5	[10, 10]	[1]	0.2	0.0162	0.1272	0.0993	-1.3966
Sí	4	No	5	[10, 10]	[1]	0	0.0074	0.0863	0.0738	-0.1037

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	4	No	5	[10]	[1, 1]	0.2	0.0130	0.1141	0.0862	-0.9310
Sí	4	No	5	[10]	[1, 1]	0	0.0137	0.1172	0.0883	-1.0350
Sí	4	No	5	[10, 10]	[1, 1]	0.2	0.0301	0.1735	0.1527	-3.4602
Sí	4	No	5	[10, 10]	[1, 1]	0	0.0947	0.3077	0.2965	-13.0322
Sí	4	No	5	[10]	[2, 1]	0.2	0.0513	0.2265	0.2112	-6.6068
Sí	4	No	5	[10]	[2, 1]	0	0.0542	0.2329	0.2204	-7.0389
Sí	4	No	5	[10, 10]	[2, 1]	0.2	0.0141	0.1189	0.0894	-1.0960
Sí	4	No	5	[10, 10]	[2, 1]	0	0.0965	0.3107	0.2997	-13.3089
Sí	5	Sí	2	[10]	[1]	0.2	0.2376	0.4875	0.4084	-1.5405
Sí	5	Sí	2	[10]	[1]	0	0.1470	0.3834	0.3068	-0.5714
Sí	5	Sí	2	[10, 10]	[1]	0.2	0.1242	0.3525	0.2734	-0.3283
Sí	5	Sí	2	[10, 10]	[1]	0	0.1651	0.4063	0.3250	-0.7647
Sí	5	Sí	2	[10]	[1, 1]	0.2	0.3166	0.5627	0.4729	-2.3849
Sí	5	Sí	2	[10]	[1, 1]	0	0.2620	0.5119	0.4199	-1.8010
Sí	5	Sí	2	[10, 10]	[1, 1]	0.2	0.3072	0.5543	0.4629	-2.2844
Sí	5	Sí	2	[10, 10]	[1, 1]	0	0.2225	0.4717	0.3807	-1.3783
Sí	5	Sí	2	[10]	[2, 1]	0.2	0.0942	0.3069	0.2609	-0.0067
Sí	5	Sí	2	[10]	[2, 1]	0	0.2022	0.4497	0.3606	-1.1618
Sí	5	Sí	2	[10, 10]	[2, 1]	0.2	0.3089	0.5558	0.4643	-2.3022
Sí	5	Sí	2	[10, 10]	[2, 1]	0	0.0988	0.3143	0.2780	-0.0564
Sí	5	Sí	3	[10]	[1]	0.2	0.1527	0.3907	0.3323	-0.7327
Sí	5	Sí	3	[10]	[1]	0	0.3780	0.6148	0.5366	-3.2906
Sí	5	Sí	3	[10, 10]	[1]	0.2	0.0904	0.3007	0.2528	-0.0263
Sí	5	Sí	3	[10, 10]	[1]	0	0.1092	0.3304	0.2963	-0.2391
Sí	5	Sí	3	[10]	[1, 1]	0.2	0.1050	0.3240	0.2530	-0.1917
Sí	5	Sí	3	[10]	[1, 1]	0	0.1051	0.3243	0.2913	-0.1934
Sí	5	Sí	3	[10, 10]	[1, 1]	0.2	0.2468	0.4968	0.4166	-1.8009
Sí	5	Sí	3	[10, 10]	[1, 1]	0	0.2436	0.4936	0.4160	-1.7651
Sí	5	Sí	3	[10]	[2, 1]	0.2	0.2149	0.4636	0.3823	-1.4391
Sí	5	Sí	3	[10]	[2, 1]	0	0.1237	0.3518	0.3105	-0.4044
Sí	5	Sí	3	[10, 10]	[2, 1]	0.2	0.1729	0.4158	0.3307	-0.9622
Sí	5	Sí	3	[10, 10]	[2, 1]	0	0.1085	0.3293	0.2556	-0.2311
Sí	5	Sí	5	[10]	[1]	0.2	0.0811	0.2848	0.2601	-0.1408
Sí	5	Sí	5	[10]	[1]	0	0.2756	0.5250	0.4547	-2.8765
Sí	5	Sí	5	[10, 10]	[1]	0.2	0.2314	0.4810	0.4042	-2.2545
Sí	5	Sí	5	[10, 10]	[1]	0	0.1370	0.3702	0.2950	-0.9273
Sí	5	Sí	5	[10]	[1, 1]	0.2	0.3562	0.5969	0.5321	-4.0104
Sí	5	Sí	5	[10]	[1, 1]	0	0.0916	0.3027	0.2475	-0.2888
Sí	5	Sí	5	[10, 10]	[1, 1]	0.2	0.3766	0.6136	0.5526	-4.2962
Sí	5	Sí	5	[10, 10]	[1, 1]	0	0.2131	0.4616	0.3791	-1.9969
Sí	5	Sí	5	[10]	[2, 1]	0.2	0.3924	0.6264	0.5605	-4.5189
Sí	5	Sí	5	[10]	[2, 1]	0	0.1460	0.3821	0.3106	-1.0539
Sí	5	Sí	5	[10, 10]	[2, 1]	0.2	0.1203	0.3469	0.2701	-0.6922
Sí	5	Sí	5	[10, 10]	[2, 1]	0	0.1444	0.3800	0.3098	-1.0306
Sí	5	No	2	[10]	[1]	0.2	0.1028	0.3207	0.2976	-6.1025
Sí	5	No	2	[10]	[1]	0	0.0355	0.1884	0.1452	-1.4531
Sí	5	No	2	[10, 10]	[1]	0.2	0.0447	0.2115	0.1895	-2.0901
Sí	5	No	2	[10, 10]	[1]	0	0.0161	0.1271	0.1008	-0.1155
Sí	5	No	2	[10]	[1, 1]	0.2	0.0355	0.1885	0.1455	-1.4536
Sí	5	No	2	[10]	[1, 1]	0	0.0786	0.2804	0.2548	-4.4294

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	5	No	2	[10, 10]	[1, 1]	0.2	0.1131	0.3363	0.3140	-6.8140
Sí	5	No	2	[10, 10]	[1, 1]	0	0.1053	0.3245	0.3014	-6.2731
Sí	5	No	2	[10]	[2, 1]	0.2	0.0268	0.1636	0.1434	-0.8483
Sí	5	No	2	[10]	[2, 1]	0	0.0778	0.2790	0.2538	-4.3760
Sí	5	No	2	[10, 10]	[2, 1]	0.2	0.0353	0.1879	0.1444	-1.4393
Sí	5	No	2	[10, 10]	[2, 1]	0	0.0364	0.1907	0.1482	-1.5129
Sí	5	No	3	[10]	[1]	0.2	0.0223	0.1495	0.1070	-0.7320
Sí	5	No	3	[10]	[1]	0	0.0462	0.2149	0.2008	-2.5787
Sí	5	No	3	[10, 10]	[1]	0.2	0.0234	0.1530	0.1119	-0.8141
Sí	5	No	3	[10, 10]	[1]	0	0.0137	0.1168	0.0913	-0.0579
Sí	5	No	3	[10]	[1, 1]	0.2	0.1005	0.3170	0.2959	-6.7868
Sí	5	No	3	[10]	[1, 1]	0	0.1087	0.3297	0.3095	-7.4219
Sí	5	No	3	[10, 10]	[1, 1]	0.2	0.0133	0.1155	0.0909	-0.0333
Sí	5	No	3	[10, 10]	[1, 1]	0	0.0280	0.1674	0.1243	-1.1706
Sí	5	No	3	[10]	[2, 1]	0.2	0.0276	0.1661	0.1231	-1.1384
Sí	5	No	3	[10]	[2, 1]	0	0.0275	0.1659	0.1227	-1.1318
Sí	5	No	3	[10, 10]	[2, 1]	0.2	0.1205	0.3471	0.3279	-8.3389
Sí	5	No	3	[10, 10]	[2, 1]	0	0.0638	0.2525	0.2347	-3.9410
Sí	5	No	5	[10]	[1]	0.2	0.0557	0.2360	0.2222	-7.2550
Sí	5	No	5	[10]	[1]	0	0.0068	0.0826	0.0719	-0.0109
Sí	5	No	5	[10, 10]	[1]	0.2	0.1025	0.3201	0.3090	-14.1913
Sí	5	No	5	[10, 10]	[1]	0	0.1372	0.3704	0.3610	-19.3324
Sí	5	No	5	[10]	[1, 1]	0.2	0.0159	0.1261	0.1071	-1.3580
Sí	5	No	5	[10]	[1, 1]	0	0.0133	0.1152	0.0871	-0.9678
Sí	5	No	5	[10, 10]	[1, 1]	0.2	0.0797	0.2824	0.2701	-10.8181
Sí	5	No	5	[10, 10]	[1, 1]	0	0.0427	0.2067	0.1906	-5.3305
Sí	5	No	5	[10]	[2, 1]	0.2	0.0126	0.1124	0.0856	-0.8725
Sí	5	No	5	[10]	[2, 1]	0	0.0392	0.1980	0.1801	-4.8096
Sí	5	No	5	[10, 10]	[2, 1]	0.2	0.0807	0.2841	0.2719	-10.9660
Sí	5	No	5	[10, 10]	[2, 1]	0	0.0135	0.1160	0.0877	-0.9960
Sí	6	Sí	2	[10]	[1]	0.2	0.1080	0.3287	0.2636	-0.0762
Sí	6	Sí	2	[10]	[1]	0	0.3205	0.5661	0.4716	-2.1923
Sí	6	Sí	2	[10, 10]	[1]	0.2	0.1348	0.3672	0.2848	-0.3432
Sí	6	Sí	2	[10, 10]	[1]	0	0.1703	0.4127	0.3238	-0.6966
Sí	6	Sí	2	[10]	[1, 1]	0.2	0.2100	0.4582	0.3882	-1.0916
Sí	6	Sí	2	[10]	[1, 1]	0	0.1557	0.3946	0.3081	-0.5513
Sí	6	Sí	2	[10, 10]	[1, 1]	0.2	0.1120	0.3347	0.2988	-0.1160
Sí	6	Sí	2	[10, 10]	[1, 1]	0	0.1957	0.4423	0.3506	-0.9489
Sí	6	Sí	2	[10]	[2, 1]	0.2	0.3391	0.5824	0.4899	-2.3782
Sí	6	Sí	2	[10]	[2, 1]	0	0.1370	0.3701	0.2870	-0.3642
Sí	6	Sí	2	[10, 10]	[2, 1]	0.2	0.3081	0.5550	0.4615	-2.0686
Sí	6	Sí	2	[10, 10]	[2, 1]	0	0.1032	0.3212	0.2681	-0.0278
Sí	6	Sí	3	[10]	[1]	0.2	0.0990	0.3146	0.2613	-0.0466
Sí	6	Sí	3	[10]	[1]	0	0.2021	0.4495	0.3718	-1.1369
Sí	6	Sí	3	[10, 10]	[1]	0.2	0.1175	0.3427	0.2658	-0.2421
Sí	6	Sí	3	[10, 10]	[1]	0	0.2348	0.4845	0.3974	-1.4826
Sí	6	Sí	3	[10]	[1, 1]	0.2	0.1634	0.4042	0.3164	-0.7278
Sí	6	Sí	3	[10]	[1, 1]	0	0.1237	0.3517	0.3136	-0.3083
Sí	6	Sí	3	[10, 10]	[1, 1]	0.2	0.1915	0.4377	0.3491	-1.0256
Sí	6	Sí	3	[10, 10]	[1, 1]	0	0.2801	0.5293	0.4469	-1.9622

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	6	Sí	3	[10]	[2, 1]	0.2	0.3442	0.5867	0.5022	-2.6397
Sí	6	Sí	3	[10]	[2, 1]	0	0.2405	0.4904	0.4028	-1.5434
Sí	6	Sí	3	[10, 10]	[2, 1]	0.2	0.2467	0.4967	0.4082	-1.6089
Sí	6	Sí	3	[10, 10]	[2, 1]	0	0.1329	0.3645	0.3218	-0.4053
Sí	6	Sí	5	[10]	[1]	0.2	0.1013	0.3183	0.2577	-0.3276
Sí	6	Sí	5	[10]	[1]	0	0.1605	0.4006	0.3251	-1.1029
Sí	6	Sí	5	[10, 10]	[1]	0.2	0.1471	0.3835	0.3153	-0.9275
Sí	6	Sí	5	[10, 10]	[1]	0	0.1609	0.4011	0.3255	-1.1081
Sí	6	Sí	5	[10]	[1, 1]	0.2	0.1334	0.3653	0.2852	-0.7483
Sí	6	Sí	5	[10]	[1, 1]	0	0.0954	0.3089	0.2544	-0.2508
Sí	6	Sí	5	[10, 10]	[1, 1]	0.2	0.0887	0.2978	0.2719	-0.1623
Sí	6	Sí	5	[10, 10]	[1, 1]	0	0.2696	0.5193	0.4400	-2.5333
Sí	6	Sí	5	[10]	[2, 1]	0.2	0.0784	0.2800	0.2588	-0.0274
Sí	6	Sí	5	[10]	[2, 1]	0	0.1421	0.3770	0.3120	-0.8626
Sí	6	Sí	5	[10, 10]	[2, 1]	0.2	0.0902	0.3003	0.2731	-0.1814
Sí	6	Sí	5	[10, 10]	[2, 1]	0	0.1611	0.4013	0.3257	-1.1107
Sí	6	No	2	[10]	[1]	0.2	0.0398	0.1995	0.1526	-1.3244
Sí	6	No	2	[10]	[1]	0	0.0349	0.1869	0.1413	-1.0396
Sí	6	No	2	[10, 10]	[1]	0.2	0.0248	0.1574	0.1365	-0.4471
Sí	6	No	2	[10, 10]	[1]	0	0.0400	0.2001	0.1522	-1.3381
Sí	6	No	2	[10]	[1, 1]	0.2	0.0406	0.2015	0.1535	-1.3708
Sí	6	No	2	[10]	[1, 1]	0	0.1534	0.3916	0.3690	-7.9584
Sí	6	No	2	[10, 10]	[1, 1]	0.2	0.0531	0.2303	0.2038	-2.0987
Sí	6	No	2	[10, 10]	[1, 1]	0	0.0411	0.2028	0.1549	-1.4013
Sí	6	No	2	[10]	[2, 1]	0.2	0.0198	0.1406	0.1182	-0.1539
Sí	6	No	2	[10]	[2, 1]	0	0.0433	0.2081	0.1623	-1.5306
Sí	6	No	2	[10, 10]	[2, 1]	0.2	0.1108	0.3329	0.3061	-5.4735
Sí	6	No	2	[10, 10]	[2, 1]	0	0.0187	0.1367	0.1137	-0.0922
Sí	6	No	3	[10]	[1]	0.2	0.0266	0.1630	0.1413	-0.7402
Sí	6	No	3	[10]	[1]	0	0.0637	0.2524	0.2339	-3.1731
Sí	6	No	3	[10, 10]	[1]	0.2	0.0538	0.2320	0.2139	-2.5262
Sí	6	No	3	[10, 10]	[1]	0	0.0153	0.1236	0.0989	-0.0003
Sí	6	No	3	[10]	[1, 1]	0.2	0.1165	0.3413	0.3181	-6.6324
Sí	6	No	3	[10]	[1, 1]	0	0.1538	0.3921	0.3720	-9.0762
Sí	6	No	3	[10, 10]	[1, 1]	0.2	0.0318	0.1783	0.1317	-1.0833
Sí	6	No	3	[10, 10]	[1, 1]	0	0.1057	0.3252	0.3008	-5.9284
Sí	6	No	3	[10]	[2, 1]	0.2	0.0669	0.2587	0.2389	-3.3865
Sí	6	No	3	[10]	[2, 1]	0	0.0327	0.1809	0.1341	-1.1453
Sí	6	No	3	[10, 10]	[2, 1]	0.2	0.0164	0.1279	0.1028	-0.0728
Sí	6	No	3	[10, 10]	[2, 1]	0	0.0225	0.1500	0.1138	-0.4735
Sí	6	No	5	[10]	[1]	0.2	0.0132	0.1149	0.0877	-0.6555
Sí	6	No	5	[10]	[1]	0	0.0097	0.0985	0.0828	-0.2158
Sí	6	No	5	[10, 10]	[1]	0.2	0.0173	0.1315	0.0987	-1.1678
Sí	6	No	5	[10, 10]	[1]	0	0.0199	0.1411	0.1196	-1.4969
Sí	6	No	5	[10]	[1, 1]	0.2	0.1242	0.3524	0.3408	-14.5616
Sí	6	No	5	[10]	[1, 1]	0	0.0163	0.1276	0.0961	-1.0416
Sí	6	No	5	[10, 10]	[1, 1]	0.2	0.1243	0.3525	0.3410	-14.5736
Sí	6	No	5	[10, 10]	[1, 1]	0	0.0159	0.1260	0.0953	-0.9909
Sí	6	No	5	[10]	[2, 1]	0.2	0.0162	0.1273	0.0960	-1.0298
Sí	6	No	5	[10]	[2, 1]	0	0.1604	0.4005	0.3904	-19.1041

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	6	No	5	[10, 10]	[2, 1]	0.2	0.0161	0.1268	0.0957	-1.0139
Sí	6	No	5	[10, 10]	[2, 1]	0	0.1572	0.3965	0.3863	-18.7073
Sí	7	Sí	2	[10]	[1]	0.2	0.2438	0.4937	0.3997	-1.4281
Sí	7	Sí	2	[10]	[1]	0	0.1540	0.3924	0.3466	-0.5340
Sí	7	Sí	2	[10, 10]	[1]	0.2	0.2173	0.4661	0.3747	-1.1644
Sí	7	Sí	2	[10, 10]	[1]	0	0.2795	0.5287	0.4399	-1.7839
Sí	7	Sí	2	[10]	[1, 1]	0.2	0.1266	0.3559	0.3196	-0.2614
Sí	7	Sí	2	[10]	[1, 1]	0	0.2598	0.5097	0.4145	-1.5882
Sí	7	Sí	2	[10, 10]	[1, 1]	0.2	0.1531	0.3912	0.3050	-0.5247
Sí	7	Sí	2	[10, 10]	[1, 1]	0	0.3194	0.5651	0.4710	-2.1813
Sí	7	Sí	2	[10]	[2, 1]	0.2	0.3280	0.5727	0.4784	-2.2669
Sí	7	Sí	2	[10]	[2, 1]	0	0.1359	0.3686	0.3297	-0.3537
Sí	7	Sí	2	[10, 10]	[2, 1]	0.2	0.2981	0.5460	0.4521	-1.9695
Sí	7	Sí	2	[10, 10]	[2, 1]	0	0.1388	0.3725	0.3326	-0.3822
Sí	7	Sí	3	[10]	[1]	0.2	0.0982	0.3133	0.2617	-0.0381
Sí	7	Sí	3	[10]	[1]	0	0.2266	0.4760	0.3924	-1.3961
Sí	7	Sí	3	[10, 10]	[1]	0.2	0.2378	0.4876	0.4003	-1.5147
Sí	7	Sí	3	[10, 10]	[1]	0	0.1379	0.3714	0.3261	-0.4588
Sí	7	Sí	3	[10]	[1, 1]	0.2	0.2449	0.4948	0.4066	-1.5895
Sí	7	Sí	3	[10]	[1, 1]	0	0.1957	0.4423	0.3699	-1.0691
Sí	7	Sí	3	[10, 10]	[1, 1]	0.2	0.3523	0.5935	0.5104	-2.7255
Sí	7	Sí	3	[10, 10]	[1, 1]	0	0.1529	0.3910	0.3372	-0.6171
Sí	7	Sí	3	[10]	[2, 1]	0.2	0.0957	0.3094	0.2620	-0.0122
Sí	7	Sí	3	[10]	[2, 1]	0	0.2588	0.5087	0.4255	-1.7365
Sí	7	Sí	3	[10, 10]	[2, 1]	0.2	0.2397	0.4895	0.4021	-1.5343
Sí	7	Sí	3	[10, 10]	[2, 1]	0	0.3023	0.5498	0.4675	-2.1964
Sí	7	Sí	5	[10]	[1]	0.2	0.1468	0.3831	0.3150	-0.9232
Sí	7	Sí	5	[10]	[1]	0	0.1244	0.3526	0.2951	-0.6297
Sí	7	Sí	5	[10, 10]	[1]	0.2	0.1087	0.3297	0.2857	-0.4248
Sí	7	Sí	5	[10, 10]	[1]	0	0.1687	0.4108	0.3303	-1.2111
Sí	7	Sí	5	[10]	[1, 1]	0.2	0.1611	0.4014	0.3256	-1.1116
Sí	7	Sí	5	[10]	[1, 1]	0	0.2801	0.5293	0.4514	-2.6712
Sí	7	Sí	5	[10, 10]	[1, 1]	0.2	0.1612	0.4015	0.3258	-1.1129
Sí	7	Sí	5	[10, 10]	[1, 1]	0	0.2770	0.5263	0.4475	-2.6302
Sí	7	Sí	5	[10]	[2, 1]	0.2	0.1236	0.3516	0.2963	-0.6203
Sí	7	Sí	5	[10]	[2, 1]	0	0.3240	0.5692	0.4975	-3.2454
Sí	7	Sí	5	[10, 10]	[2, 1]	0.2	0.3395	0.5827	0.5131	-3.4495
Sí	7	Sí	5	[10, 10]	[2, 1]	0	0.1573	0.3966	0.3126	-1.0615
Sí	7	No	2	[10]	[1]	0.2	0.0384	0.1959	0.1483	-1.2415
Sí	7	No	2	[10]	[1]	0	0.0417	0.2042	0.1567	-1.4352
Sí	7	No	2	[10, 10]	[1]	0.2	0.0755	0.2748	0.2477	-3.4122
Sí	7	No	2	[10, 10]	[1]	0	0.0732	0.2706	0.2437	-3.2772
Sí	7	No	2	[10]	[1, 1]	0.2	0.0187	0.1367	0.1135	-0.0909
Sí	7	No	2	[10]	[1, 1]	0	0.0181	0.1344	0.1113	-0.0551
Sí	7	No	2	[10, 10]	[1, 1]	0.2	0.1145	0.3384	0.3120	-5.6874
Sí	7	No	2	[10, 10]	[1, 1]	0	0.0427	0.2067	0.1600	-1.4961
Sí	7	No	2	[10]	[2, 1]	0.2	0.0585	0.2420	0.2154	-2.4192
Sí	7	No	2	[10]	[2, 1]	0	0.0394	0.1985	0.1507	-1.3007
Sí	7	No	2	[10, 10]	[2, 1]	0.2	0.1123	0.3351	0.3084	-5.5582
Sí	7	No	2	[10, 10]	[2, 1]	0	0.0616	0.2482	0.2217	-2.5974

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
Sí	7	No	3	[10]	[1]	0.2	0.0277	0.1663	0.1445	-0.8131
Sí	7	No	3	[10]	[1]	0	0.0295	0.1716	0.1274	-0.9306
Sí	7	No	3	[10, 10]	[1]	0.2	0.1206	0.3472	0.3238	-6.8996
Sí	7	No	3	[10, 10]	[1]	0	0.0192	0.1387	0.1143	-0.2597
Sí	7	No	3	[10]	[1, 1]	0.2	0.0347	0.1863	0.1659	-1.2732
Sí	7	No	3	[10]	[1, 1]	0	0.0323	0.1797	0.1330	-1.1150
Sí	7	No	3	[10, 10]	[1, 1]	0.2	0.0666	0.2580	0.2383	-3.3630
Sí	7	No	3	[10, 10]	[1, 1]	0	0.0327	0.1810	0.1342	-1.1459
Sí	7	No	3	[10]	[2, 1]	0.2	0.0307	0.1751	0.1295	-1.0092
Sí	7	No	3	[10]	[2, 1]	0	0.0700	0.2645	0.2444	-3.5854
Sí	7	No	3	[10, 10]	[2, 1]	0.2	0.0308	0.1755	0.1297	-1.0190
Sí	7	No	3	[10, 10]	[2, 1]	0	0.0841	0.2900	0.2682	-4.5124
Sí	7	No	5	[10]	[1]	0.2	0.0341	0.1848	0.1618	-3.2790
Sí	7	No	5	[10]	[1]	0	0.0159	0.1261	0.0953	-0.9945
Sí	7	No	5	[10, 10]	[1]	0.2	0.0168	0.1297	0.0974	-1.1070
Sí	7	No	5	[10, 10]	[1]	0	0.0302	0.1738	0.1529	-2.7877
Sí	7	No	5	[10]	[1, 1]	0.2	0.0162	0.1272	0.0959	-1.0279
Sí	7	No	5	[10]	[1, 1]	0	0.0168	0.1296	0.0973	-1.1047
Sí	7	No	5	[10, 10]	[1, 1]	0.2	0.0159	0.1259	0.0952	-0.9871
Sí	7	No	5	[10, 10]	[1, 1]	0	0.0154	0.1242	0.0942	-0.9341
Sí	7	No	5	[10]	[2, 1]	0.2	0.0164	0.1280	0.0964	-1.0525
Sí	7	No	5	[10]	[2, 1]	0	0.0113	0.1065	0.0888	-0.4223
Sí	7	No	5	[10, 10]	[2, 1]	0.2	0.0110	0.1050	0.0877	-0.3824
Sí	7	No	5	[10, 10]	[2, 1]	0	0.0153	0.1237	0.0939	-0.9175
No	1	Sí	2	[10]	[16]	0.2	0.2085	0.4566	0.3691	-1.4841
No	1	Sí	2	[10]	[16]	0	0.0975	0.3123	0.2475	-0.1622
No	1	Sí	2	[16, 10]	[16]	0.2	0.2410	0.4909	0.4175	-1.8719
No	1	Sí	2	[16, 10]	[16]	0	0.1491	0.3862	0.3034	-0.7769
No	1	Sí	2	[10]	[16, 8]	0.2	0.2707	0.5203	0.4341	-2.2253
No	1	Sí	2	[10]	[16, 8]	0	0.0984	0.3137	0.2824	-0.1728
No	1	Sí	2	[16, 10]	[16, 8]	0.2	0.2329	0.4826	0.3961	-1.7755
No	1	Sí	2	[16, 10]	[16, 8]	0	0.0900	0.3000	0.2654	-0.0722
No	1	Sí	2	[10]	[24, 8]	0.2	0.0865	0.2942	0.2428	-0.0313
No	1	Sí	2	[10]	[24, 8]	0	0.3278	0.5726	0.4948	-2.9066
No	1	Sí	2	[16, 10]	[24, 8]	0.2	0.3142	0.5605	0.4801	-2.7441
No	1	Sí	2	[16, 10]	[24, 8]	0	0.1180	0.3436	0.3063	-0.4065
No	1	Sí	3	[10]	[16]	0.2	0.1708	0.4133	0.3309	-1.1609
No	1	Sí	3	[10]	[16]	0	0.1418	0.3766	0.3151	-0.7941
No	1	Sí	3	[16, 10]	[16]	0.2	0.0928	0.3046	0.2736	-0.1740
No	1	Sí	3	[16, 10]	[16]	0	0.2127	0.4612	0.3795	-1.6914
No	1	Sí	3	[10]	[16, 8]	0.2	0.2086	0.4568	0.3756	-1.6394
No	1	Sí	3	[10]	[16, 8]	0	0.2073	0.4553	0.3842	-1.6229
No	1	Sí	3	[16, 10]	[16, 8]	0.2	0.1852	0.4303	0.3555	-1.3427
No	1	Sí	3	[16, 10]	[16, 8]	0	0.0873	0.2955	0.2652	-0.1044
No	1	Sí	3	[10]	[24, 8]	0.2	0.1909	0.4369	0.3591	-1.4152
No	1	Sí	3	[10]	[24, 8]	0	0.1642	0.4052	0.3326	-1.0773
No	1	Sí	3	[16, 10]	[24, 8]	0.2	0.2369	0.4867	0.4112	-1.9966
No	1	Sí	3	[16, 10]	[24, 8]	0	0.1936	0.4400	0.3626	-1.4494
No	1	Sí	5	[10]	[16]	0.2	0.1334	0.3652	0.2919	-1.0912
No	1	Sí	5	[10]	[16]	0	0.3189	0.5648	0.5077	-4.0000

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	1	Sí	5	[16, 10]	[16]	0.2	0.1016	0.3188	0.2595	-0.5935
No	1	Sí	5	[16, 10]	[16]	0	0.3349	0.5787	0.5207	-4.2507
No	1	Sí	5	[10]	[16, 8]	0.2	0.3258	0.5708	0.5118	-4.1067
No	1	Sí	5	[10]	[16, 8]	0	0.1529	0.3910	0.3099	-1.3967
No	1	Sí	5	[16, 10]	[16, 8]	0.2	0.3681	0.6067	0.5518	-4.7698
No	1	Sí	5	[16, 10]	[16, 8]	0	0.1086	0.3296	0.2724	-0.7031
No	1	Sí	5	[10]	[24, 8]	0.2	0.1556	0.3945	0.3151	-1.4394
No	1	Sí	5	[10]	[24, 8]	0	0.1927	0.4390	0.3606	-2.0214
No	1	Sí	5	[16, 10]	[24, 8]	0.2	0.0722	0.2688	0.2461	-0.1326
No	1	Sí	5	[16, 10]	[24, 8]	0	0.0659	0.2567	0.2229	-0.0332
No	1	No	2	[10]	[16]	0.2	0.0678	0.2605	0.2421	-5.1123
No	1	No	2	[10]	[16]	0	0.0388	0.1970	0.1682	-2.4984
No	1	No	2	[16, 10]	[16]	0.2	0.1207	0.3475	0.3322	-9.8794
No	1	No	2	[16, 10]	[16]	0	0.0201	0.1416	0.1126	-0.8079
No	1	No	2	[10]	[16, 8]	0.2	0.0310	0.1761	0.1423	-1.7953
No	1	No	2	[10]	[16, 8]	0	0.0634	0.2518	0.2299	-4.7133
No	1	No	2	[16, 10]	[16, 8]	0.2	0.0999	0.3160	0.2996	-7.9989
No	1	No	2	[16, 10]	[16, 8]	0	0.0158	0.1258	0.1093	-0.4268
No	1	No	2	[10]	[24, 8]	0.2	0.0110	0.1047	0.0861	0.0120
No	1	No	2	[10]	[24, 8]	0	0.0305	0.1746	0.1404	-1.7472
No	1	No	2	[16, 10]	[24, 8]	0.2	0.0204	0.1427	0.1253	-0.8359
No	1	No	2	[16, 10]	[24, 8]	0	0.0442	0.2102	0.1822	-2.9804
No	1	No	3	[10]	[16]	0.2	0.0840	0.2898	0.2738	-7.4903
No	1	No	3	[10]	[16]	0	0.0110	0.1049	0.0822	-0.1129
No	1	No	3	[16, 10]	[16]	0.2	0.0154	0.1240	0.0924	-0.5550
No	1	No	3	[16, 10]	[16]	0	0.0223	0.1493	0.1323	-1.2519
No	1	No	3	[10]	[16, 8]	0.2	0.0116	0.1078	0.0843	-0.1748
No	1	No	3	[10]	[16, 8]	0	0.0195	0.1398	0.1219	-0.9755
No	1	No	3	[16, 10]	[16, 8]	0.2	0.0168	0.1297	0.0964	-0.7006
No	1	No	3	[16, 10]	[16, 8]	0	0.0304	0.1744	0.1619	-2.0762
No	1	No	3	[10]	[24, 8]	0.2	0.0137	0.1171	0.0911	-0.3864
No	1	No	3	[10]	[24, 8]	0	0.0253	0.1590	0.1402	-1.5555
No	1	No	3	[16, 10]	[24, 8]	0.2	0.0368	0.1918	0.1767	-2.7204
No	1	No	3	[16, 10]	[24, 8]	0	0.0185	0.1361	0.1005	-0.8730
No	1	No	5	[10]	[16]	0.2	0.0452	0.2126	0.2047	-7.7414
No	1	No	5	[10]	[16]	0	0.0491	0.2216	0.2146	-8.4967
No	1	No	5	[16, 10]	[16]	0.2	0.0051	0.0713	0.0578	0.0183
No	1	No	5	[16, 10]	[16]	0	0.0042	0.0648	0.0564	0.1875
No	1	No	5	[10]	[16, 8]	0.2	0.0830	0.2881	0.2788	-15.0499
No	1	No	5	[10]	[16, 8]	0	0.0088	0.0939	0.0721	-0.7052
No	1	No	5	[16, 10]	[16, 8]	0.2	0.0067	0.0822	0.0639	-0.3050
No	1	No	5	[16, 10]	[16, 8]	0	0.0114	0.1068	0.0842	-1.2040
No	1	No	5	[10]	[24, 8]	0.2	0.0067	0.0819	0.0636	-0.2971
No	1	No	5	[10]	[24, 8]	0	0.1174	0.3427	0.3348	-21.7083
No	1	No	5	[16, 10]	[24, 8]	0.2	0.0089	0.0943	0.0717	-0.7199
No	1	No	5	[16, 10]	[24, 8]	0	0.0186	0.1363	0.1254	-2.5945
No	2	Sí	2	[10]	[16]	0.2	0.2755	0.5248	0.4353	-1.9756
No	2	Sí	2	[10]	[16]	0	0.0972	0.3118	0.2715	-0.0505
No	2	Sí	2	[16, 10]	[16]	0.2	0.1205	0.3472	0.2713	-0.3019
No	2	Sí	2	[16, 10]	[16]	0	0.3298	0.5743	0.4876	-2.5626

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	2	Sí	2	[10]	[16, 8]	0.2	0.1342	0.3663	0.2846	-0.4495
No	2	Sí	2	[10]	[16, 8]	0	0.1760	0.4196	0.3393	-0.9014
No	2	Sí	2	[16, 10]	[16, 8]	0.2	0.3471	0.5891	0.5054	-2.7492
No	2	Sí	2	[16, 10]	[16, 8]	0	0.2327	0.4823	0.4027	-1.5132
No	2	Sí	2	[10]	[24, 8]	0.2	0.2964	0.5445	0.4548	-2.2021
No	2	Sí	2	[10]	[24, 8]	0	0.2531	0.5031	0.4187	-1.7339
No	2	Sí	2	[16, 10]	[24, 8]	0.2	0.1094	0.3308	0.2970	-0.1819
No	2	Sí	2	[16, 10]	[24, 8]	0	0.3269	0.5718	0.4841	-2.5313
No	2	Sí	3	[10]	[16]	0.2	0.1011	0.3180	0.2407	-0.1595
No	2	Sí	3	[10]	[16]	0	0.2417	0.4916	0.4055	-1.7719
No	2	Sí	3	[16, 10]	[16]	0.2	0.1741	0.4173	0.3479	-0.9967
No	2	Sí	3	[16, 10]	[16]	0	0.0858	0.2928	0.2425	0.0165
No	2	Sí	3	[10]	[16, 8]	0.2	0.2226	0.4718	0.3884	-1.5526
No	2	Sí	3	[10]	[16, 8]	0	0.1806	0.4250	0.3540	-1.0713
No	2	Sí	3	[16, 10]	[16, 8]	0.2	0.2432	0.4932	0.4133	-1.7895
No	2	Sí	3	[16, 10]	[16, 8]	0	0.2896	0.5381	0.4591	-2.3212
No	2	Sí	3	[10]	[24, 8]	0.2	0.2254	0.4748	0.3917	-1.5848
No	2	Sí	3	[10]	[24, 8]	0	0.0860	0.2933	0.2551	0.0137
No	2	Sí	3	[16, 10]	[24, 8]	0.2	0.2951	0.5432	0.4642	-2.3841
No	2	Sí	3	[16, 10]	[24, 8]	0	0.1837	0.4286	0.3573	-1.1071
No	2	Sí	5	[10]	[16]	0.2	0.3928	0.6268	0.5673	-4.5829
No	2	Sí	5	[10]	[16]	0	0.1829	0.4276	0.3696	-1.5990
No	2	Sí	5	[16, 10]	[16]	0.2	0.0498	0.2231	0.1794	0.2925
No	2	Sí	5	[16, 10]	[16]	0	0.1615	0.4019	0.3239	-1.2954
No	2	Sí	5	[10]	[16, 8]	0.2	0.1309	0.3618	0.2976	-0.8599
No	2	Sí	5	[10]	[16, 8]	0	0.2736	0.5230	0.4513	-2.8879
No	2	Sí	5	[16, 10]	[16, 8]	0.2	0.1477	0.3843	0.3101	-1.0992
No	2	Sí	5	[16, 10]	[16, 8]	0	0.0819	0.2862	0.2593	-0.1641
No	2	Sí	5	[10]	[24, 8]	0.2	0.3844	0.6200	0.5595	-4.4622
No	2	Sí	5	[10]	[24, 8]	0	0.1467	0.3830	0.3111	-1.0842
No	2	Sí	5	[16, 10]	[24, 8]	0.2	0.1282	0.3580	0.2930	-0.8213
No	2	Sí	5	[16, 10]	[24, 8]	0	0.0824	0.2871	0.2418	-0.1710
No	2	No	2	[10]	[16]	0.2	0.0341	0.1847	0.1429	-1.4173
No	2	No	2	[10]	[16]	0	0.0501	0.2238	0.1878	-2.5480
No	2	No	2	[16, 10]	[16]	0.2	0.0264	0.1624	0.1218	-0.8675
No	2	No	2	[16, 10]	[16]	0	0.0402	0.2004	0.1759	-1.8454
No	2	No	2	[10]	[16, 8]	0.2	0.0443	0.2104	0.1734	-2.1350
No	2	No	2	[10]	[16, 8]	0	0.1106	0.3326	0.3102	-6.8364
No	2	No	2	[16, 10]	[16, 8]	0.2	0.0376	0.1938	0.1531	-1.6604
No	2	No	2	[16, 10]	[16, 8]	0	0.0427	0.2066	0.1694	-2.0242
No	2	No	2	[10]	[24, 8]	0.2	0.0251	0.1584	0.1203	-0.7760
No	2	No	2	[10]	[24, 8]	0	0.0237	0.1539	0.1182	-0.6778
No	2	No	2	[16, 10]	[24, 8]	0.2	0.0391	0.1977	0.1588	-1.7686
No	2	No	2	[16, 10]	[24, 8]	0	0.0321	0.1791	0.1358	-1.2725
No	2	No	3	[10]	[16]	0.2	0.0324	0.1801	0.1337	-1.5778
No	2	No	3	[10]	[16]	0	0.0161	0.1269	0.0872	-0.2795
No	2	No	3	[16, 10]	[16]	0.2	0.0270	0.1642	0.1242	-1.1429
No	2	No	3	[16, 10]	[16]	0	0.0165	0.1285	0.0960	-0.3112
No	2	No	3	[10]	[16, 8]	0.2	0.0262	0.1620	0.1230	-1.0841
No	2	No	3	[10]	[16, 8]	0	0.0298	0.1725	0.1312	-1.3655

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	2	No	3	[16, 10]	[16, 8]	0.2	0.1128	0.3359	0.3173	-7.9647
No	2	No	3	[16, 10]	[16, 8]	0	0.0378	0.1943	0.1599	-2.0007
No	2	No	3	[10]	[24, 8]	0.2	0.0214	0.1463	0.1101	-0.7005
No	2	No	3	[10]	[24, 8]	0	0.0667	0.2583	0.2386	-4.2997
No	2	No	3	[16, 10]	[24, 8]	0.2	0.0506	0.2250	0.2074	-3.0223
No	2	No	3	[16, 10]	[24, 8]	0	0.1194	0.3456	0.3267	-8.4906
No	2	No	5	[10]	[16]	0.2	0.1273	0.3567	0.3471	-18.3419
No	2	No	5	[10]	[16]	0	0.0410	0.2025	0.1647	-5.2302
No	2	No	5	[16, 10]	[16]	0.2	0.0060	0.0775	0.0611	0.0861
No	2	No	5	[16, 10]	[16]	0	0.0031	0.0558	0.0447	0.5269
No	2	No	5	[10]	[16, 8]	0.2	0.0168	0.1295	0.1030	-1.5489
No	2	No	5	[10]	[16, 8]	0	0.0189	0.1374	0.1203	-1.8682
No	2	No	5	[16, 10]	[16, 8]	0.2	0.0146	0.1207	0.1025	-1.2155
No	2	No	5	[16, 10]	[16, 8]	0	0.0139	0.1179	0.0888	-1.1139
No	2	No	5	[10]	[24, 8]	0.2	0.1212	0.3481	0.3384	-17.4173
No	2	No	5	[10]	[24, 8]	0	0.0121	0.1098	0.0822	-0.8332
No	2	No	5	[16, 10]	[24, 8]	0.2	0.1308	0.3617	0.3517	-18.8809
No	2	No	5	[16, 10]	[24, 8]	0	0.1364	0.3693	0.3600	-19.7308
No	3	Sí	2	[10]	[16]	0.2	0.2113	0.4597	0.3693	-1.2592
No	3	Sí	2	[10]	[16]	0	0.1274	0.3570	0.2764	-0.3624
No	3	Sí	2	[16, 10]	[16]	0.2	0.3224	0.5678	0.4869	-2.4468
No	3	Sí	2	[16, 10]	[16]	0	0.3453	0.5876	0.5048	-2.6915
No	3	Sí	2	[10]	[16, 8]	0.2	0.3550	0.5958	0.5123	-2.7955
No	3	Sí	2	[10]	[16, 8]	0	0.3037	0.5511	0.4597	-2.2468
No	3	Sí	2	[16, 10]	[16, 8]	0.2	0.2810	0.5301	0.4398	-2.0039
No	3	Sí	2	[16, 10]	[16, 8]	0	0.1779	0.4218	0.3598	-0.9019
No	3	Sí	2	[10]	[24, 8]	0.2	0.0996	0.3156	0.2797	-0.0650
No	3	Sí	2	[10]	[24, 8]	0	0.1015	0.3186	0.2543	-0.0852
No	3	Sí	2	[16, 10]	[24, 8]	0.2	0.1451	0.3809	0.2983	-0.5514
No	3	Sí	2	[16, 10]	[24, 8]	0	0.3232	0.5685	0.4792	-2.4550
No	3	Sí	3	[10]	[16]	0.2	0.0882	0.2969	0.2424	-0.0008
No	3	Sí	3	[10]	[16]	0	0.0920	0.3033	0.2716	-0.0442
No	3	Sí	3	[16, 10]	[16]	0.2	0.3819	0.6180	0.5394	-3.3344
No	3	Sí	3	[16, 10]	[16]	0	0.0922	0.3036	0.2698	-0.0463
No	3	Sí	3	[10]	[16, 8]	0.2	0.1266	0.3558	0.2755	-0.4366
No	3	Sí	3	[10]	[16, 8]	0	0.1453	0.3812	0.3089	-0.6494
No	3	Sí	3	[16, 10]	[16, 8]	0.2	0.1928	0.4391	0.3596	-1.1886
No	3	Sí	3	[16, 10]	[16, 8]	0	0.2219	0.4711	0.3870	-1.5186
No	3	Sí	3	[10]	[24, 8]	0.2	0.2106	0.4589	0.3758	-1.3900
No	3	Sí	3	[10]	[24, 8]	0	0.1657	0.4070	0.3247	-0.8803
No	3	Sí	3	[16, 10]	[24, 8]	0.2	0.1839	0.4288	0.3492	-1.0868
No	3	Sí	3	[16, 10]	[24, 8]	0	0.1819	0.4264	0.3405	-1.0641
No	3	Sí	5	[10]	[16]	0.2	0.0688	0.2623	0.2201	0.0323
No	3	Sí	5	[10]	[16]	0	0.2441	0.4940	0.4113	-2.4327
No	3	Sí	5	[16, 10]	[16]	0.2	0.2498	0.4998	0.4310	-2.5134
No	3	Sí	5	[16, 10]	[16]	0	0.1033	0.3213	0.2552	-0.4524
No	3	Sí	5	[10]	[16, 8]	0.2	0.1492	0.3863	0.3090	-1.0984
No	3	Sí	5	[10]	[16, 8]	0	0.1605	0.4007	0.3177	-1.2577
No	3	Sí	5	[16, 10]	[16, 8]	0.2	0.0953	0.3087	0.2497	-0.3402
No	3	Sí	5	[16, 10]	[16, 8]	0	0.1736	0.4166	0.3352	-1.4412

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	3	Sí	5	[10]	[24, 8]	0.2	0.1104	0.3323	0.2595	-0.5535
No	3	Sí	5	[10]	[24, 8]	0	0.0719	0.2682	0.2471	-0.0116
No	3	Sí	5	[16, 10]	[24, 8]	0.2	0.1086	0.3296	0.2787	-0.5276
No	3	Sí	5	[16, 10]	[24, 8]	0	0.3727	0.6105	0.5497	-4.2426
No	3	No	2	[10]	[16]	0.2	0.0355	0.1885	0.1653	-1.4546
No	3	No	2	[10]	[16]	0	0.0337	0.1836	0.1577	-1.3277
No	3	No	2	[16, 10]	[16]	0.2	0.0704	0.2654	0.2374	-3.8643
No	3	No	2	[16, 10]	[16]	0	0.0334	0.1827	0.1379	-1.3065
No	3	No	2	[10]	[16, 8]	0.2	0.0148	0.1216	0.0984	-0.0219
No	3	No	2	[10]	[16, 8]	0	0.1564	0.3954	0.3767	-9.8010
No	3	No	2	[16, 10]	[16, 8]	0.2	0.1377	0.3711	0.3508	-8.5131
No	3	No	2	[16, 10]	[16, 8]	0	0.0281	0.1677	0.1368	-0.9425
No	3	No	2	[10]	[24, 8]	0.2	0.0210	0.1448	0.1253	-0.4479
No	3	No	2	[10]	[24, 8]	0	0.0672	0.2593	0.2338	-3.6450
No	3	No	2	[16, 10]	[24, 8]	0.2	0.0351	0.1874	0.1466	-1.4247
No	3	No	2	[16, 10]	[24, 8]	0	0.1428	0.3779	0.3584	-8.8651
No	3	No	3	[10]	[16]	0.2	0.0376	0.1940	0.1767	-1.9159
No	3	No	3	[10]	[16]	0	0.0173	0.1315	0.0993	-0.3402
No	3	No	3	[16, 10]	[16]	0.2	0.0157	0.1255	0.0954	-0.2199
No	3	No	3	[16, 10]	[16]	0	0.0210	0.1451	0.1045	-0.6308
No	3	No	3	[10]	[16, 8]	0.2	0.0259	0.1610	0.1195	-1.0091
No	3	No	3	[10]	[16, 8]	0	0.0200	0.1416	0.1164	-0.5534
No	3	No	3	[16, 10]	[16, 8]	0.2	0.0339	0.1841	0.1463	-1.6269
No	3	No	3	[16, 10]	[16, 8]	0	0.0171	0.1306	0.0998	-0.3223
No	3	No	3	[10]	[24, 8]	0.2	0.0181	0.1346	0.0988	-0.4038
No	3	No	3	[10]	[24, 8]	0	0.0324	0.1799	0.1622	-1.5083
No	3	No	3	[16, 10]	[24, 8]	0.2	0.0527	0.2296	0.2103	-3.0835
No	3	No	3	[16, 10]	[24, 8]	0	0.0357	0.1891	0.1585	-1.7698
No	3	No	5	[10]	[16]	0.2	0.0121	0.1100	0.0868	-0.7920
No	3	No	5	[10]	[16]	0	0.0339	0.1841	0.1533	-4.0239
No	3	No	5	[16, 10]	[16]	0.2	0.1188	0.3447	0.3347	-16.6123
No	3	No	5	[16, 10]	[16]	0	0.0068	0.0824	0.0649	-0.0076
No	3	No	5	[10]	[16, 8]	0.2	0.0157	0.1253	0.0973	-1.3267
No	3	No	5	[10]	[16, 8]	0	0.0153	0.1237	0.0966	-1.2700
No	3	No	5	[16, 10]	[16, 8]	0.2	0.1373	0.3706	0.3607	-19.3563
No	3	No	5	[16, 10]	[16, 8]	0	0.0103	0.1015	0.0780	-0.5263
No	3	No	5	[10]	[24, 8]	0.2	0.1050	0.3240	0.3124	-14.5603
No	3	No	5	[10]	[24, 8]	0	0.1348	0.3672	0.3574	-18.9833
No	3	No	5	[16, 10]	[24, 8]	0.2	0.1279	0.3577	0.3473	-17.9648
No	3	No	5	[16, 10]	[24, 8]	0	0.0112	0.1056	0.0817	-0.6539
No	4	Sí	2	[10]	[16]	0.2	0.0987	0.3142	0.2571	-0.0557
No	4	Sí	2	[10]	[16]	0	0.1341	0.3662	0.3233	-0.4340
No	4	Sí	2	[16, 10]	[16]	0.2	0.0985	0.3138	0.2779	-0.0526
No	4	Sí	2	[16, 10]	[16]	0	0.2533	0.5033	0.4185	-1.7076
No	4	Sí	2	[10]	[16, 8]	0.2	0.2956	0.5437	0.4540	-2.1600
No	4	Sí	2	[10]	[16, 8]	0	0.2885	0.5371	0.4470	-2.0841
No	4	Sí	2	[16, 10]	[16, 8]	0.2	0.2927	0.5410	0.4507	-2.1292
No	4	Sí	2	[16, 10]	[16, 8]	0	0.1535	0.3917	0.3070	-0.6405
No	4	Sí	2	[10]	[24, 8]	0.2	0.3241	0.5693	0.4809	-2.4653
No	4	Sí	2	[10]	[24, 8]	0	0.1025	0.3202	0.2850	-0.0963

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	4	Sí	2	[16, 10]	[24, 8]	0.2	0.0944	0.3073	0.2690	-0.0097
No	4	Sí	2	[16, 10]	[24, 8]	0	0.0969	0.3113	0.2588	-0.0360
No	4	Sí	3	[10]	[16]	0.2	0.1395	0.3735	0.3174	-0.5835
No	4	Sí	3	[10]	[16]	0	0.3053	0.5525	0.4739	-2.4653
No	4	Sí	3	[16, 10]	[16]	0.2	0.2938	0.5420	0.4646	-2.3348
No	4	Sí	3	[16, 10]	[16]	0	0.0857	0.2928	0.2455	0.0269
No	4	Sí	3	[10]	[16, 8]	0.2	0.3315	0.5758	0.4972	-2.7631
No	4	Sí	3	[10]	[16, 8]	0	0.0840	0.2898	0.2311	0.0465
No	4	Sí	3	[16, 10]	[16, 8]	0.2	0.1920	0.4382	0.3597	-1.1796
No	4	Sí	3	[16, 10]	[16, 8]	0	0.2392	0.4891	0.4095	-1.7150
No	4	Sí	3	[10]	[24, 8]	0.2	0.1150	0.3391	0.2623	-0.3053
No	4	Sí	3	[10]	[24, 8]	0	0.0938	0.3063	0.2723	-0.0646
No	4	Sí	3	[16, 10]	[24, 8]	0.2	0.3468	0.5889	0.5087	-2.9359
No	4	Sí	3	[16, 10]	[24, 8]	0	0.2163	0.4651	0.3808	-1.4550
No	4	Sí	5	[10]	[16]	0.2	0.1107	0.3328	0.2914	-0.5574
No	4	Sí	5	[10]	[16]	0	0.1083	0.3291	0.2834	-0.5230
No	4	Sí	5	[16, 10]	[16]	0.2	0.0708	0.2661	0.2283	0.0040
No	4	Sí	5	[16, 10]	[16]	0	0.0868	0.2946	0.2456	-0.2203
No	4	Sí	5	[10]	[16, 8]	0.2	0.0792	0.2815	0.2416	-0.1142
No	4	Sí	5	[10]	[16, 8]	0	0.1214	0.3484	0.2904	-0.7077
No	4	Sí	5	[16, 10]	[16, 8]	0.2	0.0969	0.3112	0.2633	-0.3622
No	4	Sí	5	[16, 10]	[16, 8]	0	0.1006	0.3172	0.2514	-0.4153
No	4	Sí	5	[10]	[24, 8]	0.2	0.4383	0.6620	0.6000	-5.1641
No	4	Sí	5	[10]	[24, 8]	0	0.0793	0.2815	0.2565	-0.1147
No	4	Sí	5	[16, 10]	[24, 8]	0.2	0.3514	0.5928	0.5271	-3.9429
No	4	Sí	5	[16, 10]	[24, 8]	0	0.0844	0.2905	0.2412	-0.1869
No	4	No	2	[10]	[16]	0.2	0.0367	0.1916	0.1491	-1.5359
No	4	No	2	[10]	[16]	0	0.0697	0.2639	0.2425	-3.8116
No	4	No	2	[16, 10]	[16]	0.2	0.0192	0.1386	0.0992	-0.3264
No	4	No	2	[16, 10]	[16]	0	0.0360	0.1897	0.1488	-1.4865
No	4	No	2	[10]	[16, 8]	0.2	0.0732	0.2705	0.2448	-4.0531
No	4	No	2	[10]	[16, 8]	0	0.0267	0.1635	0.1213	-0.8468
No	4	No	2	[16, 10]	[16, 8]	0.2	0.1209	0.3477	0.3265	-7.3521
No	4	No	2	[16, 10]	[16, 8]	0	0.0266	0.1632	0.1493	-0.8407
No	4	No	2	[10]	[24, 8]	0.2	0.1265	0.3557	0.3356	-7.7417
No	4	No	2	[10]	[24, 8]	0	0.0336	0.1832	0.1438	-1.3183
No	4	No	2	[16, 10]	[24, 8]	0.2	0.0220	0.1484	0.1150	-0.5212
No	4	No	2	[16, 10]	[24, 8]	0	0.0363	0.1904	0.1475	-1.5052
No	4	No	3	[10]	[16]	0.2	0.0205	0.1431	0.1073	-0.5877
No	4	No	3	[10]	[16]	0	0.0109	0.1045	0.0658	0.1534
No	4	No	3	[16, 10]	[16]	0.2	0.0211	0.1453	0.1300	-0.6350
No	4	No	3	[16, 10]	[16]	0	0.0191	0.1383	0.1030	-0.4823
No	4	No	3	[10]	[16, 8]	0.2	0.1259	0.3548	0.3352	-8.7578
No	4	No	3	[10]	[16, 8]	0	0.1066	0.3265	0.3059	-7.2623
No	4	No	3	[16, 10]	[16, 8]	0.2	0.0681	0.2610	0.2413	-4.2803
No	4	No	3	[16, 10]	[16, 8]	0	0.0232	0.1523	0.1111	-0.7971
No	4	No	3	[10]	[24, 8]	0.2	0.0130	0.1140	0.0917	-0.0075
No	4	No	3	[10]	[24, 8]	0	0.0154	0.1240	0.0940	-0.1925
No	4	No	3	[16, 10]	[24, 8]	0.2	0.0350	0.1870	0.1509	-1.7090
No	4	No	3	[16, 10]	[24, 8]	0	0.0270	0.1643	0.1225	-1.0931

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	4	No	5	[10]	[16]	0.2	0.0583	0.2414	0.2329	-7.6369
No	4	No	5	[10]	[16]	0	0.0117	0.1083	0.0830	-0.7386
No	4	No	5	[16, 10]	[16]	0.2	0.0099	0.0996	0.0775	-0.4718
No	4	No	5	[16, 10]	[16]	0	0.0362	0.1903	0.1725	-4.3703
No	4	No	5	[10]	[16, 8]	0.2	0.0198	0.1406	0.1193	-1.9306
No	4	No	5	[10]	[16, 8]	0	0.0070	0.0835	0.0687	-0.0338
No	4	No	5	[16, 10]	[16, 8]	0.2	0.1159	0.3404	0.3297	-16.1808
No	4	No	5	[16, 10]	[16, 8]	0	0.0277	0.1663	0.1453	-3.0996
No	4	No	5	[10]	[24, 8]	0.2	0.0099	0.0994	0.0826	-0.4637
No	4	No	5	[10]	[24, 8]	0	0.1062	0.3258	0.3163	-14.7380
No	4	No	5	[16, 10]	[24, 8]	0.2	0.0147	0.1212	0.0913	-1.1788
No	4	No	5	[16, 10]	[24, 8]	0	0.0380	0.1950	0.1769	-4.6371
No	5	Sí	2	[10]	[16]	0.2	0.0569	0.2386	0.1903	0.3912
No	5	Sí	2	[10]	[16]	0	0.1031	0.3211	0.2567	-0.1024
No	5	Sí	2	[16, 10]	[16]	0.2	0.2750	0.5244	0.4324	-1.9400
No	5	Sí	2	[16, 10]	[16]	0	0.2599	0.5098	0.4288	-1.7783
No	5	Sí	2	[10]	[16, 8]	0.2	0.3200	0.5657	0.4748	-2.4208
No	5	Sí	2	[10]	[16, 8]	0	0.2085	0.4566	0.3862	-1.2288
No	5	Sí	2	[16, 10]	[16, 8]	0.2	0.2749	0.5243	0.4362	-1.9389
No	5	Sí	2	[16, 10]	[16, 8]	0	0.1119	0.3345	0.2625	-0.1961
No	5	Sí	2	[10]	[24, 8]	0.2	0.2878	0.5365	0.4479	-2.0772
No	5	Sí	2	[10]	[24, 8]	0	0.1860	0.4313	0.3465	-0.9883
No	5	Sí	2	[16, 10]	[24, 8]	0.2	0.1111	0.3333	0.2993	-0.1879
No	5	Sí	2	[16, 10]	[24, 8]	0	0.1309	0.3618	0.3026	-0.3995
No	5	Sí	3	[10]	[16]	0.2	0.1714	0.4140	0.3334	-0.9456
No	5	Sí	3	[10]	[16]	0	0.2142	0.4628	0.3769	-1.4308
No	5	Sí	3	[16, 10]	[16]	0.2	0.1245	0.3529	0.2737	-0.4132
No	5	Sí	3	[16, 10]	[16]	0	0.1990	0.4462	0.3683	-1.2592
No	5	Sí	3	[10]	[16, 8]	0.2	0.3431	0.5858	0.5037	-2.8944
No	5	Sí	3	[10]	[16, 8]	0	0.1259	0.3548	0.2852	-0.4287
No	5	Sí	3	[16, 10]	[16, 8]	0.2	0.1711	0.4137	0.3472	-0.9422
No	5	Sí	3	[16, 10]	[16, 8]	0	0.3140	0.5603	0.4803	-2.5636
No	5	Sí	3	[10]	[24, 8]	0.2	0.1983	0.4453	0.3653	-1.2502
No	5	Sí	3	[10]	[24, 8]	0	0.1996	0.4468	0.3680	-1.2655
No	5	Sí	3	[16, 10]	[24, 8]	0.2	0.1306	0.3614	0.3164	-0.4827
No	5	Sí	3	[16, 10]	[24, 8]	0	0.1467	0.3830	0.3283	-0.6651
No	5	Sí	5	[10]	[16]	0.2	0.2624	0.5122	0.4365	-2.6899
No	5	Sí	5	[10]	[16]	0	0.1224	0.3499	0.2845	-0.7219
No	5	Sí	5	[16, 10]	[16]	0.2	0.0702	0.2650	0.2442	0.0121
No	5	Sí	5	[16, 10]	[16]	0	0.1388	0.3726	0.3049	-0.9526
No	5	Sí	5	[10]	[16, 8]	0.2	0.3555	0.5962	0.5316	-3.9995
No	5	Sí	5	[10]	[16, 8]	0	0.1689	0.4110	0.3312	-1.3755
No	5	Sí	5	[16, 10]	[16, 8]	0.2	0.4655	0.6823	0.6207	-5.5470
No	5	Sí	5	[16, 10]	[16, 8]	0	0.3570	0.5975	0.5356	-4.0217
No	5	Sí	5	[10]	[24, 8]	0.2	0.1698	0.4121	0.3315	-1.3883
No	5	Sí	5	[10]	[24, 8]	0	0.1554	0.3942	0.3120	-1.1856
No	5	Sí	5	[16, 10]	[24, 8]	0.2	0.1233	0.3511	0.2910	-0.7338
No	5	Sí	5	[16, 10]	[24, 8]	0	0.1465	0.3827	0.3115	-1.0604
No	5	No	2	[10]	[16]	0.2	0.0273	0.1651	0.1203	-0.8840
No	5	No	2	[10]	[16]	0	0.0218	0.1477	0.1306	-0.5071

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	5	No	2	[16, 10]	[16]	0.2	0.0150	0.1223	0.1005	-0.0328
No	5	No	2	[16, 10]	[16]	0	0.0158	0.1258	0.0996	-0.0936
No	5	No	2	[10]	[16, 8]	0.2	0.0390	0.1976	0.1566	-1.6971
No	5	No	2	[10]	[16, 8]	0	0.0271	0.1647	0.1227	-0.8743
No	5	No	2	[16, 10]	[16, 8]	0.2	0.0444	0.2107	0.1728	-2.0668
No	5	No	2	[16, 10]	[16, 8]	0	0.0274	0.1655	0.1455	-0.8927
No	5	No	2	[10]	[24, 8]	0.2	0.1359	0.3686	0.3456	-8.3854
No	5	No	2	[10]	[24, 8]	0	0.0178	0.1333	0.0904	-0.2268
No	5	No	2	[16, 10]	[24, 8]	0.2	0.1036	0.3219	0.2986	-6.1564
No	5	No	2	[16, 10]	[24, 8]	0	0.0533	0.2308	0.1970	-2.6792
No	5	No	3	[10]	[16]	0.2	0.0216	0.1471	0.1056	-0.6764
No	5	No	3	[10]	[16]	0	0.0117	0.1083	0.0692	0.0915
No	5	No	3	[16, 10]	[16]	0.2	0.0985	0.3139	0.2933	-6.6361
No	5	No	3	[16, 10]	[16]	0	0.0108	0.1038	0.0720	0.1651
No	5	No	3	[10]	[16, 8]	0.2	0.0199	0.1410	0.1044	-0.5404
No	5	No	3	[10]	[16, 8]	0	0.0330	0.1817	0.1647	-1.5580
No	5	No	3	[16, 10]	[16, 8]	0.2	0.1199	0.3463	0.3269	-8.2926
No	5	No	3	[16, 10]	[16, 8]	0	0.0266	0.1632	0.1472	-1.0649
No	5	No	3	[10]	[24, 8]	0.2	0.0254	0.1595	0.1163	-0.9709
No	5	No	3	[10]	[24, 8]	0	0.0156	0.1250	0.1114	-0.2102
No	5	No	3	[16, 10]	[24, 8]	0.2	0.0594	0.2437	0.2270	-3.6009
No	5	No	3	[16, 10]	[24, 8]	0	0.0267	0.1634	0.1459	-1.0693
No	5	No	5	[10]	[16]	0.2	0.0086	0.0925	0.0740	-0.2694
No	5	No	5	[10]	[16]	0	0.0309	0.1758	0.1570	-3.5817
No	5	No	5	[16, 10]	[16]	0.2	0.1448	0.3805	0.3724	-20.4616
No	5	No	5	[16, 10]	[16]	0	0.0312	0.1768	0.1663	-3.6318
No	5	No	5	[10]	[16, 8]	0.2	0.0181	0.1344	0.1081	-1.6789
No	5	No	5	[10]	[16, 8]	0	0.0261	0.1614	0.1545	-2.8636
No	5	No	5	[16, 10]	[16, 8]	0.2	0.0082	0.0903	0.0713	-0.2086
No	5	No	5	[16, 10]	[16, 8]	0	0.0148	0.1218	0.0917	-1.1994
No	5	No	5	[10]	[24, 8]	0.2	0.0771	0.2777	0.2655	-10.4300
No	5	No	5	[10]	[24, 8]	0	0.1259	0.3548	0.3457	-17.6593
No	5	No	5	[16, 10]	[24, 8]	0.2	0.0099	0.0996	0.0784	-0.4691
No	5	No	5	[16, 10]	[24, 8]	0	0.0136	0.1167	0.0884	-1.0194
No	6	Sí	2	[10]	[16]	0.2	0.0947	0.3078	0.2686	0.0565
No	6	Sí	2	[10]	[16]	0	0.2446	0.4946	0.4137	-1.4364
No	6	Sí	2	[16, 10]	[16]	0.2	0.1005	0.3170	0.2716	-0.0011
No	6	Sí	2	[16, 10]	[16]	0	0.2054	0.4532	0.3601	-1.0458
No	6	Sí	2	[10]	[16, 8]	0.2	0.1059	0.3255	0.2658	-0.0552
No	6	Sí	2	[10]	[16, 8]	0	0.1663	0.4078	0.3183	-0.6564
No	6	Sí	2	[16, 10]	[16, 8]	0.2	0.3802	0.6166	0.5313	-2.7870
No	6	Sí	2	[16, 10]	[16, 8]	0	0.1033	0.3214	0.2830	-0.0289
No	6	Sí	2	[10]	[24, 8]	0.2	0.2394	0.4893	0.4105	-1.3848
No	6	Sí	2	[10]	[24, 8]	0	0.3573	0.5978	0.5138	-2.5595
No	6	Sí	2	[16, 10]	[24, 8]	0.2	0.1066	0.3265	0.2888	-0.0620
No	6	Sí	2	[16, 10]	[24, 8]	0	0.1435	0.3788	0.3047	-0.4294
No	6	Sí	3	[10]	[16]	0.2	0.0891	0.2985	0.2602	0.0579
No	6	Sí	3	[10]	[16]	0	0.1608	0.4010	0.3316	-0.7001
No	6	Sí	3	[16, 10]	[16]	0.2	0.5071	0.7121	0.5893	-4.3623
No	6	Sí	3	[16, 10]	[16]	0	0.2428	0.4927	0.4023	-1.5672

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	6	Sí	3	[10]	[16, 8]	0.2	0.1037	0.3221	0.2885	-0.0970
No	6	Sí	3	[10]	[16, 8]	0	0.1047	0.3235	0.2899	-0.1068
No	6	Sí	3	[16, 10]	[16, 8]	0.2	0.1410	0.3754	0.2893	-0.4907
No	6	Sí	3	[16, 10]	[16, 8]	0	0.1143	0.3381	0.3029	-0.2087
No	6	Sí	3	[10]	[24, 8]	0.2	0.2331	0.4828	0.3983	-1.4653
No	6	Sí	3	[10]	[24, 8]	0	0.3220	0.5674	0.4857	-2.4051
No	6	Sí	3	[16, 10]	[24, 8]	0.2	0.1964	0.4431	0.3608	-1.0765
No	6	Sí	3	[16, 10]	[24, 8]	0	0.2730	0.5225	0.4299	-1.8875
No	6	Sí	5	[10]	[16]	0.2	0.1289	0.3590	0.2779	-0.6893
No	6	Sí	5	[10]	[16]	0	0.3622	0.6018	0.5261	-3.7464
No	6	Sí	5	[16, 10]	[16]	0.2	0.1434	0.3787	0.3125	-0.8794
No	6	Sí	5	[16, 10]	[16]	0	0.0771	0.2777	0.2492	-0.0106
No	6	Sí	5	[10]	[16, 8]	0.2	0.3575	0.5979	0.5316	-3.6854
No	6	Sí	5	[10]	[16, 8]	0	0.0775	0.2783	0.2346	-0.0150
No	6	Sí	5	[16, 10]	[16, 8]	0.2	0.1868	0.4322	0.3452	-1.4478
No	6	Sí	5	[16, 10]	[16, 8]	0	0.1407	0.3751	0.3099	-0.8434
No	6	Sí	5	[10]	[24, 8]	0.2	0.1476	0.3842	0.3149	-0.9348
No	6	Sí	5	[10]	[24, 8]	0	0.0694	0.2634	0.2274	0.0907
No	6	Sí	5	[16, 10]	[24, 8]	0.2	0.1250	0.3535	0.2961	-0.6377
No	6	Sí	5	[16, 10]	[24, 8]	0	0.1121	0.3348	0.2645	-0.4686
No	6	No	2	[10]	[16]	0.2	0.0225	0.1501	0.1167	-0.3158
No	6	No	2	[10]	[16]	0	0.0653	0.2556	0.2219	-2.8157
No	6	No	2	[16, 10]	[16]	0.2	0.0413	0.2031	0.1572	-1.4095
No	6	No	2	[16, 10]	[16]	0	0.0338	0.1839	0.1398	-0.9746
No	6	No	2	[10]	[16, 8]	0.2	0.0349	0.1868	0.1408	-1.0379
No	6	No	2	[10]	[16, 8]	0	0.0244	0.1562	0.1220	-0.4255
No	6	No	2	[16, 10]	[16, 8]	0.2	0.1228	0.3504	0.3256	-6.1719
No	6	No	2	[16, 10]	[16, 8]	0	0.0371	0.1926	0.1457	-1.1666
No	6	No	2	[10]	[24, 8]	0.2	0.0294	0.1714	0.1303	-0.7169
No	6	No	2	[10]	[24, 8]	0	0.0345	0.1857	0.1651	-1.0150
No	6	No	2	[16, 10]	[24, 8]	0.2	0.0822	0.2867	0.2586	-3.8021
No	6	No	2	[16, 10]	[24, 8]	0	0.1053	0.3245	0.2969	-5.1511
No	6	No	3	[10]	[16]	0.2	0.0228	0.1511	0.1146	-0.4952
No	6	No	3	[10]	[16]	0	0.0236	0.1535	0.1081	-0.5444
No	6	No	3	[16, 10]	[16]	0.2	0.0433	0.2081	0.1678	-1.8365
No	6	No	3	[16, 10]	[16]	0	0.0447	0.2114	0.1709	-1.9279
No	6	No	3	[10]	[16, 8]	0.2	0.1324	0.3639	0.3426	-7.6762
No	6	No	3	[10]	[16, 8]	0	0.0253	0.1589	0.1194	-0.6548
No	6	No	3	[16, 10]	[16, 8]	0.2	0.0362	0.1904	0.1705	-1.3750
No	6	No	3	[16, 10]	[16, 8]	0	0.0333	0.1824	0.1573	-1.1790
No	6	No	3	[10]	[24, 8]	0.2	0.0896	0.2994	0.2774	-4.8738
No	6	No	3	[10]	[24, 8]	0	0.0313	0.1770	0.1538	-1.0534
No	6	No	3	[16, 10]	[24, 8]	0.2	0.0339	0.1842	0.1385	-1.2221
No	6	No	3	[16, 10]	[24, 8]	0	0.0276	0.1660	0.1232	-0.8067
No	6	No	5	[10]	[16]	0.2	0.0091	0.0952	0.0709	-0.1355
No	6	No	5	[10]	[16]	0	0.0208	0.1441	0.1179	-1.6031
No	6	No	5	[16, 10]	[16]	0.2	0.0142	0.1190	0.0953	-0.7736
No	6	No	5	[16, 10]	[16]	0	0.0492	0.2218	0.2106	-5.1648
No	6	No	5	[10]	[16, 8]	0.2	0.1286	0.3586	0.3472	-15.1138
No	6	No	5	[10]	[16, 8]	0	0.0090	0.0950	0.0773	-0.1311

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	6	No	5	[16, 10]	[16, 8]	0.2	0.0170	0.1305	0.0975	-1.1336
No	6	No	5	[16, 10]	[16, 8]	0	0.0755	0.2748	0.2597	-8.4669
No	6	No	5	[10]	[24, 8]	0.2	0.0102	0.1011	0.0803	-0.2809
No	6	No	5	[10]	[24, 8]	0	0.0155	0.1245	0.0942	-0.9433
No	6	No	5	[16, 10]	[24, 8]	0.2	0.1075	0.3279	0.3156	-12.4797
No	6	No	5	[16, 10]	[24, 8]	0	0.0882	0.2971	0.2828	-10.0598
No	7	Sí	2	[10]	[16]	0.2	0.1095	0.3309	0.2650	-0.0906
No	7	Sí	2	[10]	[16]	0	0.2234	0.4727	0.3776	-1.2255
No	7	Sí	2	[16, 10]	[16]	0.2	0.1080	0.3287	0.2680	-0.0762
No	7	Sí	2	[16, 10]	[16]	0	0.2021	0.4495	0.3715	-1.0127
No	7	Sí	2	[10]	[16, 8]	0.2	0.1277	0.3573	0.2764	-0.2719
No	7	Sí	2	[10]	[16, 8]	0	0.1133	0.3366	0.3008	-0.1284
No	7	Sí	2	[16, 10]	[16, 8]	0.2	0.1370	0.3701	0.3307	-0.3647
No	7	Sí	2	[16, 10]	[16, 8]	0	0.3241	0.5693	0.4745	-2.2285
No	7	Sí	2	[10]	[24, 8]	0.2	0.3253	0.5703	0.4782	-2.2401
No	7	Sí	2	[10]	[24, 8]	0	0.1900	0.4359	0.3566	-0.8929
No	7	Sí	2	[16, 10]	[24, 8]	0.2	0.1185	0.3443	0.2707	-0.1805
No	7	Sí	2	[16, 10]	[24, 8]	0	0.3830	0.6189	0.5322	-2.8150
No	7	Sí	3	[10]	[16]	0.2	0.3343	0.5782	0.4967	-2.5350
No	7	Sí	3	[10]	[16]	0	0.1938	0.4403	0.3660	-1.0498
No	7	Sí	3	[16, 10]	[16]	0.2	0.3727	0.6105	0.5273	-2.9418
No	7	Sí	3	[16, 10]	[16]	0	0.1840	0.4290	0.3783	-0.9458
No	7	Sí	3	[10]	[16, 8]	0.2	0.1827	0.4274	0.3387	-0.9322
No	7	Sí	3	[10]	[16, 8]	0	0.1859	0.4311	0.3430	-0.9658
No	7	Sí	3	[16, 10]	[16, 8]	0.2	0.3374	0.5809	0.4975	-2.5680
No	7	Sí	3	[16, 10]	[16, 8]	0	0.2863	0.5351	0.4397	-2.0280
No	7	Sí	3	[10]	[24, 8]	0.2	0.0963	0.3103	0.2603	-0.0179
No	7	Sí	3	[10]	[24, 8]	0	0.0999	0.3161	0.2605	-0.0567
No	7	Sí	3	[16, 10]	[24, 8]	0.2	0.3006	0.5483	0.4665	-2.1792
No	7	Sí	3	[16, 10]	[24, 8]	0	0.2228	0.4720	0.3895	-1.3561
No	7	Sí	5	[10]	[16]	0.2	0.0951	0.3084	0.2590	-0.2468
No	7	Sí	5	[10]	[16]	0	0.1715	0.4141	0.3390	-1.2475
No	7	Sí	5	[16, 10]	[16]	0.2	0.4276	0.6539	0.5899	-4.6036
No	7	Sí	5	[16, 10]	[16]	0	0.1006	0.3171	0.2852	-0.3180
No	7	Sí	5	[10]	[16, 8]	0.2	0.3708	0.6089	0.5406	-3.8590
No	7	Sí	5	[10]	[16, 8]	0	0.2268	0.4762	0.4008	-1.9720
No	7	Sí	5	[16, 10]	[16, 8]	0.2	0.1501	0.3874	0.3172	-0.9666
No	7	Sí	5	[16, 10]	[16, 8]	0	0.1421	0.3770	0.3104	-0.8627
No	7	Sí	5	[10]	[24, 8]	0.2	0.1712	0.4138	0.3325	-1.2440
No	7	Sí	5	[10]	[24, 8]	0	0.3268	0.5717	0.5003	-3.2830
No	7	Sí	5	[16, 10]	[24, 8]	0.2	0.1172	0.3423	0.2894	-0.5353
No	7	Sí	5	[16, 10]	[24, 8]	0	0.0792	0.2814	0.2465	-0.0375
No	7	No	2	[10]	[16]	0.2	0.0722	0.2686	0.2453	-3.2142
No	7	No	2	[10]	[16]	0	0.1013	0.3183	0.2910	-4.9184
No	7	No	2	[16, 10]	[16]	0.2	0.0393	0.1981	0.1503	-1.2928
No	7	No	2	[16, 10]	[16]	0	0.0657	0.2563	0.2299	-2.8382
No	7	No	2	[10]	[16, 8]	0.2	0.0330	0.1816	0.1599	-0.9270
No	7	No	2	[10]	[16, 8]	0	0.0375	0.1936	0.1478	-1.1886
No	7	No	2	[16, 10]	[16, 8]	0.2	0.1243	0.3526	0.3274	-6.2619
No	7	No	2	[16, 10]	[16, 8]	0	0.0521	0.2283	0.1878	-2.0445

Continúa en la siguiente página

Sum.	Lags	Log	Tim.	M.L.	H.L.	Drop	MSE	RMSE	MAE	R2
No	7	No	2	[10]	[24, 8]	0.2	0.0334	0.1828	0.1379	-0.9512
No	7	No	2	[10]	[24, 8]	0	0.1246	0.3530	0.3282	-6.2782
No	7	No	2	[16, 10]	[24, 8]	0.2	0.0387	0.1966	0.1489	-1.2577
No	7	No	2	[16, 10]	[24, 8]	0	0.0878	0.2963	0.2680	-4.1276
No	7	No	3	[10]	[16]	0.2	0.1859	0.4312	0.4086	-11.1839
No	7	No	3	[10]	[16]	0	0.0182	0.1348	0.1080	-0.1912
No	7	No	3	[16, 10]	[16]	0.2	0.0173	0.1317	0.1047	-0.1367
No	7	No	3	[16, 10]	[16]	0	0.0227	0.1508	0.1275	-0.4907
No	7	No	3	[10]	[16, 8]	0.2	0.0328	0.1810	0.1346	-1.1461
No	7	No	3	[10]	[16, 8]	0	0.0281	0.1677	0.1359	-0.8431
No	7	No	3	[16, 10]	[16, 8]	0.2	0.1229	0.3506	0.3279	-7.0523
No	7	No	3	[16, 10]	[16, 8]	0	0.0414	0.2035	0.1900	-1.7129
No	7	No	3	[10]	[24, 8]	0.2	0.0686	0.2618	0.2408	-3.4924
No	7	No	3	[10]	[24, 8]	0	0.0267	0.1633	0.1396	-0.7480
No	7	No	3	[16, 10]	[24, 8]	0.2	0.0343	0.1853	0.1388	-1.2488
No	7	No	3	[16, 10]	[24, 8]	0	0.0294	0.1713	0.1269	-0.9236
No	7	No	5	[10]	[16]	0.2	0.0238	0.1542	0.1196	-1.9820
No	7	No	5	[10]	[16]	0	0.0159	0.1259	0.0992	-0.9874
No	7	No	5	[16, 10]	[16]	0.2	0.1557	0.3946	0.3861	-18.5152
No	7	No	5	[16, 10]	[16]	0	0.0183	0.1353	0.1080	-1.2939
No	7	No	5	[10]	[16, 8]	0.2	0.0819	0.2862	0.2726	-9.2640
No	7	No	5	[10]	[16, 8]	0	0.0793	0.2815	0.2678	-8.9335
No	7	No	5	[16, 10]	[16, 8]	0.2	0.0188	0.1373	0.1039	-1.3624
No	7	No	5	[16, 10]	[16, 8]	0	0.1448	0.3806	0.3704	-17.1530
No	7	No	5	[10]	[24, 8]	0.2	0.0148	0.1217	0.0920	-0.8556
No	7	No	5	[10]	[24, 8]	0	0.1346	0.3669	0.3555	-15.8690
No	7	No	5	[16, 10]	[24, 8]	0.2	0.0078	0.0883	0.0769	0.0223
No	7	No	5	[16, 10]	[24, 8]	0	0.0147	0.1214	0.0933	-0.8487

Fin de la tabla

APÉNDICE F

Licencia

Copyright 2020 Víctor Dorado Javier

Por la presente se concede permiso, libre de cargos, a cualquier persona que obtenga una copia de este software y de los archivos de documentación asociados (el «Software»), a utilizar el Software sin restricción, incluyendo sin limitación los derechos a usar, copiar, modificar, fusionar, publicar, distribuir, sublicenciar, y/o vender copias del Software, y a permitir a las personas a las que se les proporcione el Software a hacer lo mismo, sujeto a las siguientes condiciones:

El aviso de copyright anterior y este aviso de permiso se incluirán en todas las copias o partes sustanciales del Software.

EL SOFTWARE SE PROPORCIONA «COMO ESTÁ», SIN GARANTÍA DE NINGÚN TIPO, EXPRESA O IMPLÍCITA, INCLUYENDO PERO NO LIMITADO A GARANTÍAS DE COMERCIALIZACIÓN, IDONEIDAD PARA UN PROPÓSITO PARTICULAR E INCUMPLIMIENTO. EN NINGÚN CASO LOS AUTORES O PROPIETARIOS DE LOS DERECHOS DE AUTOR SERÁN RESPONSABLES DE NINGUNA RECLAMACIÓN, DAÑOS U OTRAS RESPONSABILIDADES, YA SEA EN UNA ACCIÓN DE CONTRATO, AGRAVIO O CUALQUIER OTRO MOTIVO, DERIVADAS DE, FUERA DE O EN CONEXIÓN CON EL SOFTWARE O SU USO U OTRO TIPO DE ACCIONES EN EL SOFTWARE.

APÉNDICE G

License

Copyright 2020 Víctor Dorado Javier

Permission is hereby granted, free of charge, to any person obtaining a copy of this software and associated documentation files (the «Software»), to deal in the Software without restriction, including without limitation the rights to use, copy, modify, merge, publish, distribute, sublicense, and/or sell copies of the Software, and to permit persons to whom the Software is furnished to do so, subject to the following conditions:

The above copyright notice and this permission notice shall be included in all copies or substantial portions of the Software.

THE SOFTWARE IS PROVIDED «AS IS», WITHOUT WARRANTY OF ANY KIND, EXPRESS OR IMPLIED, INCLUDING BUT NOT LIMITED TO THE WARRANTIES OF MERCHANTABILITY, FITNESS FOR A PARTICULAR PURPOSE AND NONINFRINGEMENT. IN NO EVENT SHALL THE AUTHORS OR COPYRIGHT HOLDERS BE LIABLE FOR ANY CLAIM, DAMAGES OR OTHER LIABILITY, WHETHER IN AN ACTION OF CONTRACT, TORT OR OTHERWISE, ARISING FROM, OUT OF OR IN CONNECTION WITH THE SOFTWARE OR THE USE OR OTHER DEALINGS IN THE SOFTWARE.