

Máster Universitario en Ciencias Actuariales y Financieras  
2022-2023

*Trabajo Fin de Máster*

# “Estudio del impacto del cambio climático en la mortalidad mediante Auto Machine Learning”

Jonathan Jon Florindo López

Tutor/es

José Miguel Rodríguez-Pardo

Jesús R. Simón Del Potro

Madrid, Junio de 2023

## DETECCIÓN DEL PLAGIO

La Universidad utiliza el programa **Turnitin Feedback Studio** para comparar la originalidad del trabajo entregado por cada estudiante con millones de recursos electrónicos y detecta aquellas partes del texto copiadas y pegadas. Copiar o plagiar en un TFM es considerado una **Falta Grave**, y puede conllevar la expulsión definitiva de la Universidad.



Esta obra se encuentra sujeta a la licencia Creative Commons **Reconocimiento – No Comercial – Sin Obra Derivada**

Esta tesis es propiedad del autor. No está permitida la reproducción total o parcial de este documento sin mencionar su fuente. El contenido de este documento es de exclusiva responsabilidad del autor, quien declara que no se ha incurrido en plagio y que la totalidad de referencias a otros autores han sido expresadas en el texto.

En caso de obtener una calificación igual o superior a 9.0 (Sobresaliente), autorizo la publicación de este trabajo en el centro de Documentación de la Fundación Mapfre.

Sí,  autorizo a su publicación.

No,  desestimo su publicación.

Firmado:

Jonathan Jon Florindo López

## **RESUMEN**

El cambio climático es uno de los mayores desafíos que enfrentamos en la actualidad. Sus efectos se extienden a múltiples aspectos de la vida, incluida la salud humana. El presente trabajo tiene como objetivo investigar y comprender el impacto del cambio climático en la mortalidad utilizando técnicas de Auto Machine Learning (AML).

### **Palabras clave:**

Auto Machine Learning, Machine Learning, Mortalidad, Cambio climático.

## **ABSTRACT**

Climate change is one of the greatest challenges we face today. Its effects extend to multiple aspects of life, including human health. The present study aims to investigate and understand the impact of climate change on mortality using Auto Machine Learning (AML) techniques.

### **Palabras clave:**

Auto Machine Learning, Machine Learning, Mortality, Climate change

## **DEDICATORIA**

A mi familia y a mi pareja, por todo su apoyo.

## ÍNDICE

1	INTRODUCCIÓN.....	10
2	REVISIÓN DE LA LITERATURA.....	12
3	DESCRIPCIÓN DE LA MUESTRA/HIPÓTESIS DE PARTIDA .....	14
3.1	GRÁFICOS DE TEMPERATURAS.....	16
4	METODOLOGÍA: .....	19
5	RESULTADOS: .....	22
5.1	ANÁLISIS DE LAS 5 PROVINCIAS: .....	22
5.1.1	ANÁLISIS PARA HOMBRES:.....	22
5.1.2	ANÁLISIS PARA MUJERES: .....	30
5.1.3	CONCLUSIONES (5 provincias) .....	37
5.2	RESULTADOS MADRID: .....	38
5.2.1	ANÁLISIS PARA HOMBRES:.....	38
5.2.2	ANÁLISIS PARA MUJERES: .....	46
6	COMPARACIÓN DEL EFECTO DE LA TEMPERATURA CON EL FACTOR DE MEJORA DE LA PER2020_Ind_2ndo.orden .....	53
7	CONCLUSIONES.....	55
8	BIBLIOGRAFÍA .....	56

## ÍNDICE DE FIGURAS

Figura 1.....	12
Figura 2.....	13
Figura 3.....	15
Figura 4.....	16
Figura 5.....	16
Figura 6.....	17
Figura 7.....	17
Figura 8.....	18
Figura 5.....	22
Figura 6.....	23
Figura 7.....	24
Figura 8.....	24
Figura 9.....	25
Figura 10.....	26
Figura 11.....	27
Figura 12.....	28
Figura 13.....	29
Figura 14.....	30
Figura 15.....	30
Figura 16.....	31
Figura 17.....	31
Figura 18.....	32
Figura 19.....	33
Figura 20.....	34
Figura 21.....	35
Figura 22.....	36
Figura 23.....	38
Figura 24.....	38
Figura 25.....	39
Figura 26.....	39
Figura 27.....	41
Figura 28.....	42

Figura 29.....	43
Figura 30.....	44
Figura 31.....	45
Figura 32.....	46
Figura 33.....	46
Figura 34.....	47
Figura 35.....	48
Figura 36.....	49
Figura 37.....	50
Figura 38.....	51
Figura 39.....	52
Figura 40.....	53
Figura 41.....	53



# 1 INTRODUCCIÓN

El cambio climático es un fenómeno global que está alterando significativamente los patrones climáticos en todo el mundo. Además de sus efectos evidentes en el medio ambiente, existe una creciente preocupación sobre cómo el cambio climático afecta la salud humana, especialmente en términos de mortalidad. La comprensión del impacto del cambio climático en la mortalidad es esencial para informar la formulación de políticas de salud y de adaptación a este.

La literatura científica ha documentado ampliamente la relación entre el cambio climático y la mortalidad humana, y se han llevado a cabo numerosos estudios en diferentes regiones del mundo para investigar esta relación compleja. Estos estudios se han centrado en comprender cómo los cambios en el clima, incluidas las temperaturas extremas y los eventos climáticos adversos, pueden influir en los patrones de mortalidad, aunque, como veremos en el siguiente apartado, no se ha realizado ningún estudio a nivel de España utilizando la metodología planteada en este.

McMichael, Woodruff y Hales (McMichael, 2006) examina los riesgos presentes y futuros del cambio climático para la salud humana, destacando la importancia de abordar el impacto en la mortalidad. Estudios como el de Watts et al. (Watts, 2015) resaltan las respuestas políticas necesarias para proteger la salud pública frente al cambio climático, reconociendo la vinculación entre el cambio climático y la mortalidad que, como veremos más adelante, nosotros vinculamos sobre todo a partir de los 75 años de edad.

Además, se han realizado investigaciones específicas en diferentes países para evaluar el impacto del cambio climático en la mortalidad. Por ejemplo, el estudio de Vicedo-Cabrera et al. (Vicedo-Cabrera, 2019) examina el exceso de mortalidad durante el verano de 2015 en Suiza, mostrando un aumento significativo en las tasas de mortalidad relacionado con las altas temperaturas.

Un estudio clave en este campo es el de Gasparrini et al. (Gasparrini, 2017), que proyecta la mortalidad en exceso relacionada con la temperatura bajo diferentes escenarios de cambio climático. Los resultados revelan un aumento sustancial en la mortalidad global debido al incremento de las temperaturas, lo que destaca la importancia de mitigar los efectos del cambio climático para evitar un aumento significativo de la mortalidad. En este trabajo se analizará también el efecto del cambio de temperatura en la mortalidad.

Además, el artículo de Patz et al. (Patz, 2005) examina el impacto del cambio climático regional en la salud humana, incluida la mortalidad. Se destaca la relación entre el cambio climático, las temperaturas más altas y los eventos climáticos extremos con el aumento de la mortalidad y los riesgos para la salud.

En resumen, la literatura científica ha proporcionado una sólida base de evidencia sobre el impacto del cambio climático en la mortalidad humana. Los estudios revisados en este análisis resaltan la importancia de abordar los efectos del cambio climático en la salud pública y la necesidad de implementar medidas de adaptación y mitigación para proteger a la población, sobre todo los de mayor edad.

La inclusión de la temperatura como representativa del cambio climático esta soportada por múltiples estudios como el IPCC (Lee, 2023).

La innovación dentro del campo de investigación viene por el método utilizado para la estimación mediante Auto Machine Learning que describiremos en la metodología.

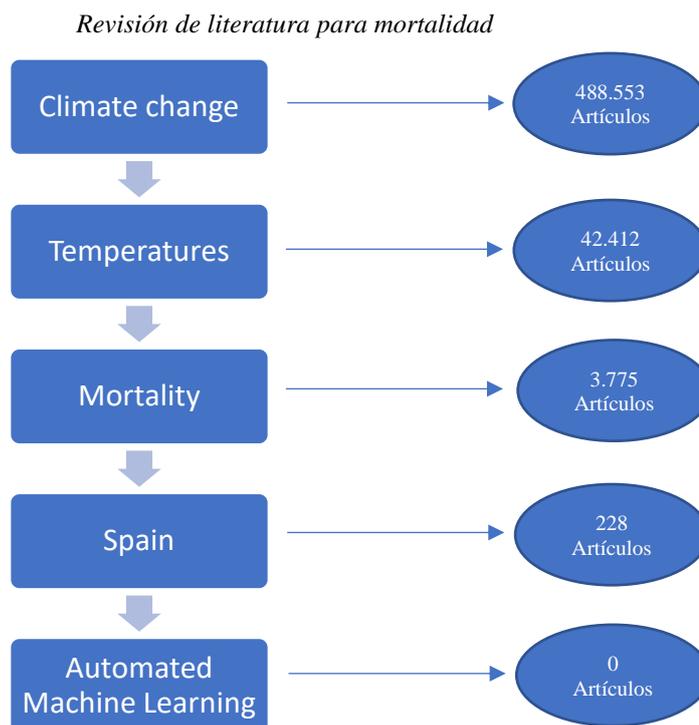
## 2 REVISIÓN DE LA LITERATURA

En este apartado del trabajo se realizará un estudio de la documentación existente con los temas relacionados con la investigación.

Para el estudio de la literatura previa se utilizará la misma metodología que se usa en McDermott-Levy (McDermott-Levy, 2021) y que usó Carlos Crisóstomo Mazaira en su TFM “Modelo actuarial de la medida del impacto del cambio climático en los riesgos de mortalidad y longevidad” (Mazaira, 2022).

Como se puede ver en las figuras este trabajo supone el primero para describir el efecto entre temperaturas y mortalidad en España mediante Automated Machine Learning.

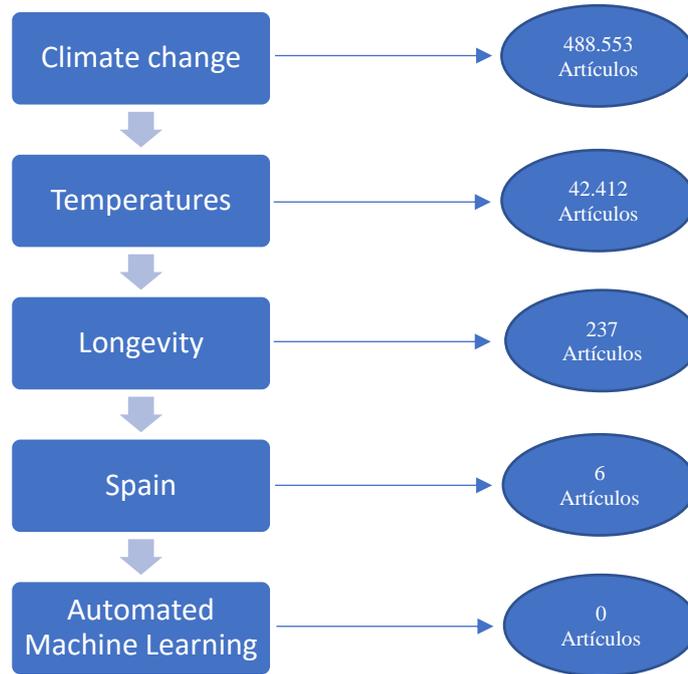
**Figura 1**



*Fuente: Elaboración propia*

**Figura 2.**

*Revisión de literatura para longevidad*



*Fuente: Elaboración propia*

### 3 DESCRIPCIÓN DE LA MUESTRA/HIPÓTESIS DE PARTIDA

La base de datos a analizar son datos de sección cruzada desde el 01/01/2000 hasta el 24/12/2022 con frecuencia semanal. Se trata por un lado de datos demográficos: Fallecidos semanales por provincia y grupos de edad (EUROSTAT, s.f.), población por provincia anual y grupo de edad (INE, s.f.). Para poder tener los datos de mortalidad semanal se ha realizado interpolación lineal de la población para poder obtener los datos de población semanal y así dividir el número de fallecidos en una semana entre la población de la provincia en concreto de esa semana.

Los grupos de edad son los siguientes:

0-4 / 5-9 / 10-14 / 15-19 / 20-24 / 25-29 / 30-34 / 35-39 / 40-44 / 45-49 / 50-54 / 55-59 / 60-64 / 65-69 / 70-74 / 75-79 / 80-84 / 85-89 / Más 90.

Por otro lado se han obtenido los datos meteorológicos (AEMET, s.f.) provinciales diarios, para obtener los datos semanales se ha realizado la media semanal de los datos meteorológicos. En concreto, se han utilizado las siguientes variables en el estudio:

- Temperatura máxima.
- Temperatura mínima.
- Temperatura media.
- Precipitaciones.

Ante la gran cantidad de datos en el estudio se utilizarán las siguientes provincias para hacerlo manejable:

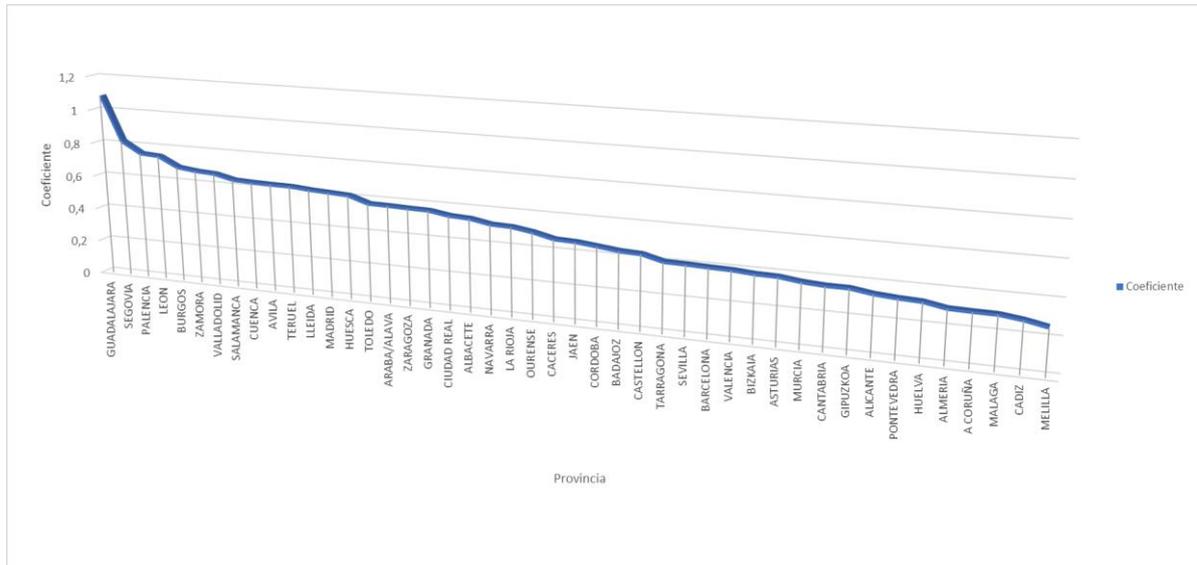
- Guadalajara.
- Segovia.
- Madrid
- A Coruña
- Cádiz.

Para elegir estas provincias se han seleccionado en base a la siguiente fórmula:

$$\frac{SD_{TMAX}}{MEAN_{TMAX}} * 0,5 + \frac{SD_{TMIN}}{MEAN_{TMIN}} * 0,5$$

**Figura 3**

*Coefficiente descrito por provincia*



*Fuente: Elaboración propia.*

De esta forma se han elegido dos provincias en las que este coeficiente es elevado, dos en las que es bajo y Madrid que se encuentra en la mitad superior, pero, ya que este trabajo se está desarrollando desde Madrid, se ha encontrado cierto interés en analizarla.

Para el estudio se ha utilizado hasta el 06/02/2016 como Training y a partir de esa fecha como Test, siendo de esta manera un 70% Training y un 30% Test.

Habiendo restringido los datos provinciales a los descritos falta por explicar las variables añadidas.

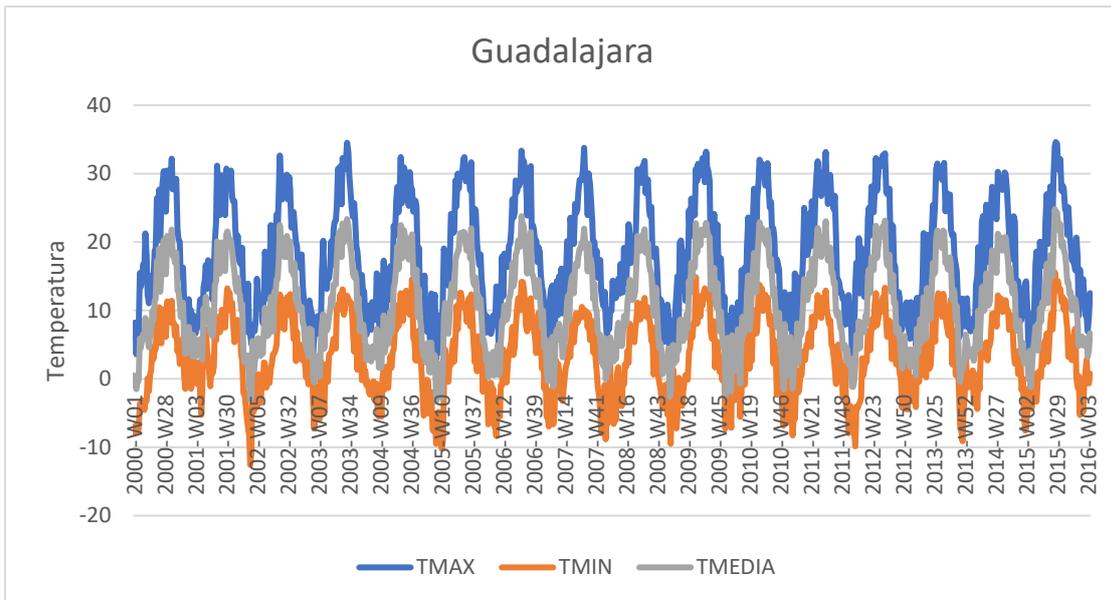
Se han incluido variables dummy para cada provincia y grupo de edad siendo el número de datos igual para cada grupo por las características de la base de datos, con lo que no hay desnivel en el número de datos para cada grupo. Además de estas dummy se ha incluido una variable que es uno en el caso en que la temperatura máxima esté por encima del percentil 95 y cero en caso contrario y otra cuyo valor es 1 en el caso en el que la temperatura mínima esté por debajo del percentil 5 de temperatura mínima, en adición, se ha incluido una variable que muestra el valor en el que se sobrepasa el percentil 95 de la temperatura máxima en el caso en que esta se sobrepase y 0 en caso contrario y otra que muestra lo que se sobrepasa la temperatura mínima en el caso en que esta sea menor que el percentil 5 de la temperatura mínima y cero en caso contrario.

### 3.1 GRÁFICOS DE TEMPERATURAS

A modo de tener una vista previa de las temperaturas en cada provincia se plantean los siguientes gráficos.

**Figura 4**

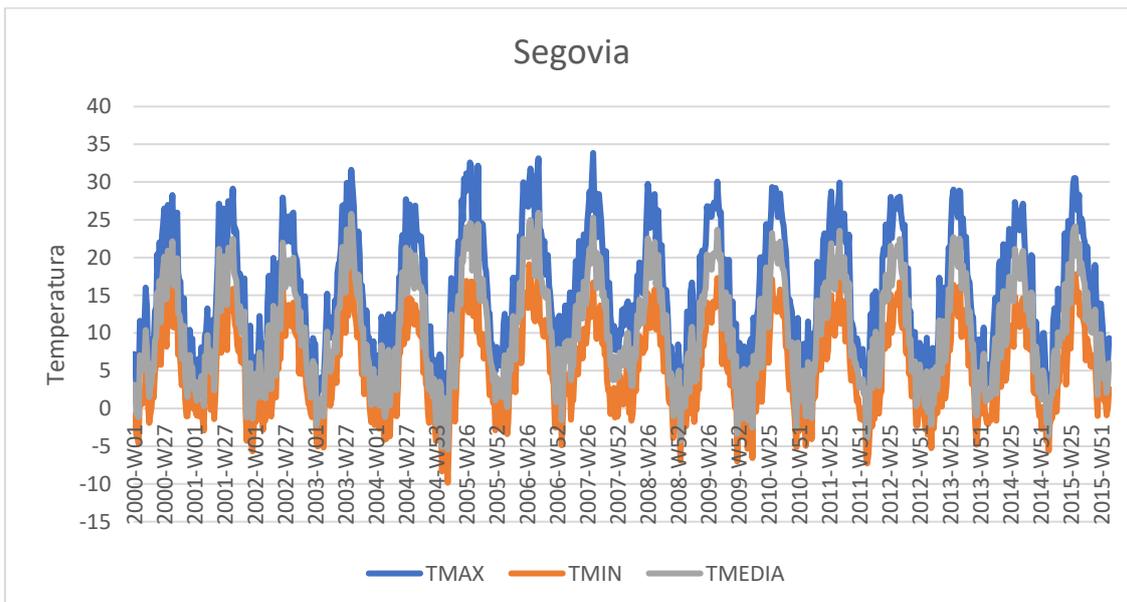
*Temperaturas en Guadalajara*



*Fuente: Elaboración propia.*

**Figura 5**

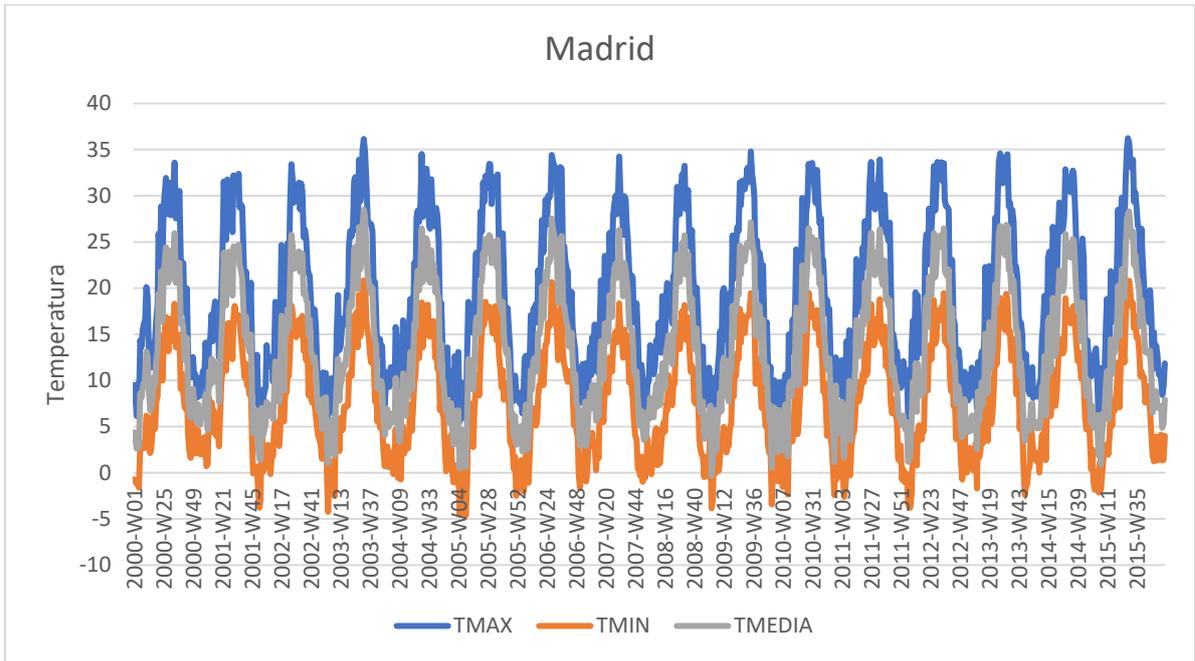
*Temperaturas en Segovia*



*Fuente: Elaboración propia.*

**Figura 6**

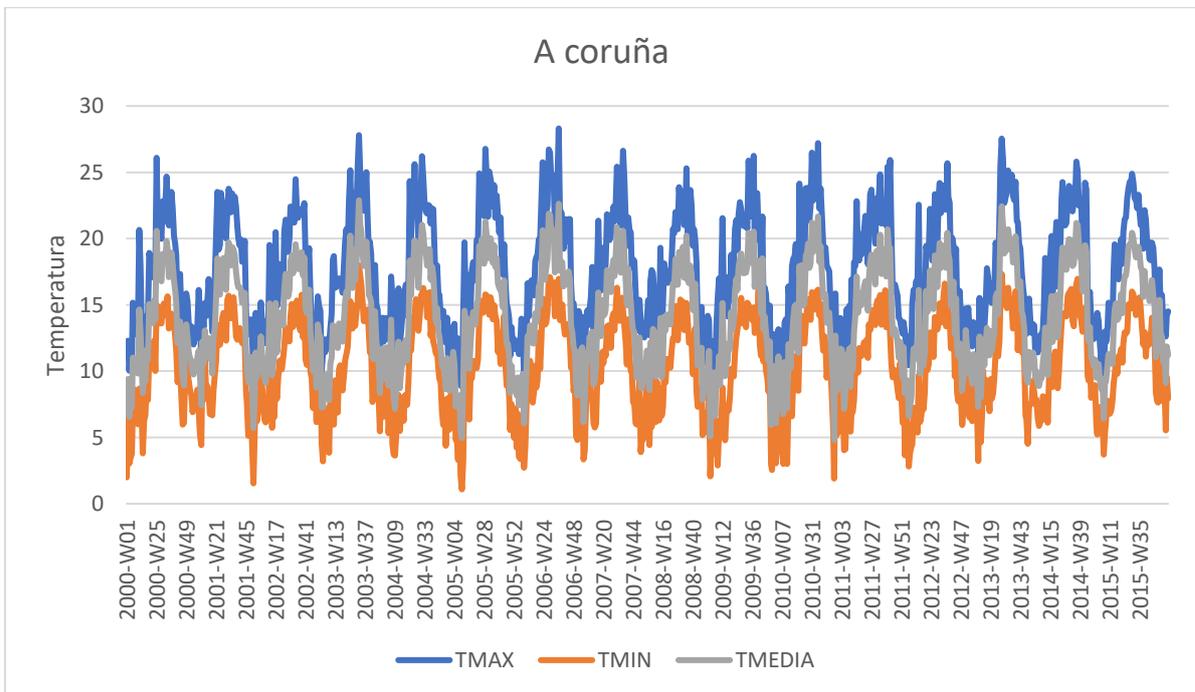
*Temperaturas en Madrid*



*Fuente: Elaboración propia.*

**Figura 7**

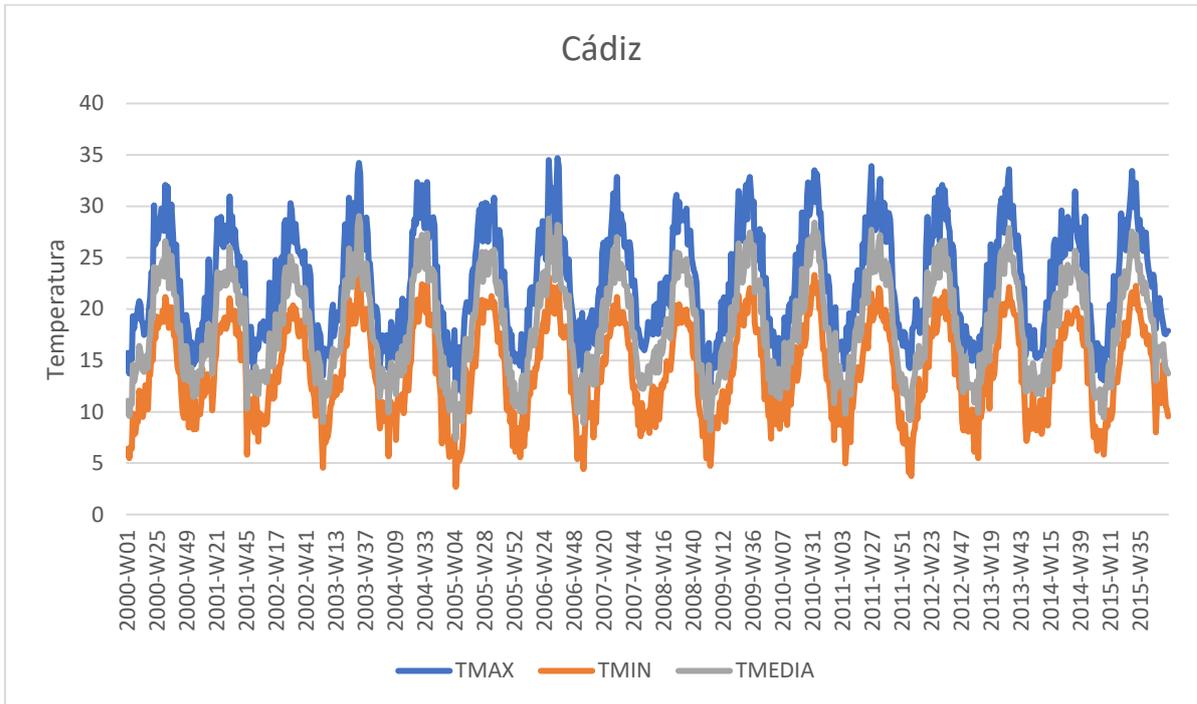
*Temperaturas en A coruña*



*Fuente: Elaboración propia.*

**Figura 8**

*Temperaturas en Cádiz*



*Fuente: Elaboración propia.*

Con estos gráficos se puede comprobar lo dicho anteriormente con los coeficientes basados en la varianza, siendo Segovia y Guadalajara las provincias con más variación y A coruña y Cádiz las que menos.

## 4 METODOLOGÍA:

A la hora de modelizar se ha hecho uso del Automated Machine Learning que se trata de una automatización a la hora de elegir el mejor Machine Learning, el aprendizaje automático (Machine Learning) es una herramienta importante en diversos campos, desde la predicción de enfermedades hasta el procesamiento de lenguaje natural. Sin embargo, el desarrollo de modelos de aprendizaje automático es un proceso complejo y requiere una experiencia significativa en la selección de algoritmos.

En los últimos años, ha surgido una nueva metodología conocida como Automated Machine Learning (AutoML), que tiene como objetivo automatizar y simplificar el proceso de creación de modelos de aprendizaje automático. El AutoML aprovecha técnicas de inteligencia artificial y optimización automática para reducir la necesidad de intervención humana.

En resumen, haremos uso del AutoML como una herramienta en la creación automatizada de modelos a la hora de analizar el efecto de la temperatura en la mortalidad.

En concreto, para este trabajo se utilizará la librería de H2O (Poirier, s.f.), la librería H2O de R ofrece una funcionalidad de Auto Machine Learning (AutoML) que automatiza el proceso de construcción de modelos de aprendizaje automático. AutoML en H2O simplifica el flujo de trabajo al realizar automáticamente varias tareas, como la selección de algoritmos.

La función principal de AutoML en H2O es encontrar el mejor modelo de aprendizaje automático para un problema dado, sin necesidad de que el usuario tenga un conocimiento profundo sobre los algoritmos o la configuración de los hiperparámetros. Algunas características destacadas de la funcionalidad AutoML en H2O son las siguientes:

1. Selección automática de algoritmos: H2O AutoML realiza una búsqueda exhaustiva entre una amplia variedad de algoritmos de aprendizaje automático disponibles en la librería H2O. Evalúa automáticamente el rendimiento de diferentes algoritmos en el conjunto de datos proporcionado y selecciona los mejores.
2. Optimización de hiperparámetros: Los hiperparámetros son configuraciones específicas de cada algoritmo que influyen en el rendimiento del modelo. AutoML en H2O realiza una optimización automática de los hiperparámetros, explorando diferentes combinaciones y ajustándolos para maximizar el rendimiento del modelo.

3. Ensamblado de modelos: AutoML en H2O también permite crear modelos de ensamblado (ensemble) automáticamente. Los modelos de ensamblado combinan las predicciones de varios modelos individuales para obtener una mejor precisión predictiva. H2O AutoML evalúa diferentes técnicas de ensamblado, como Bagging, Stacking o Boosting, y selecciona la más adecuada para el conjunto de datos y el problema en cuestión.
4. Interpretación de modelos: Además de generar modelos automatizados, H2O AutoML proporciona herramientas para interpretar y comprender los modelos resultantes. Esto incluye la capacidad de obtener información sobre la importancia de las características (feature importance) y las relaciones entre las variables, lo que ayuda a entender qué características son más relevantes para las predicciones del modelo.

En resumen, la funcionalidad AutoML de la librería H2O en R permite automatizar el proceso de construcción de modelos de aprendizaje automático. Con AutoML, se pueden seleccionar automáticamente algoritmos, optimizar hiperparámetros y crear modelos de ensamblado para obtener resultados precisos y eficientes sin requerir un conocimiento profundo de los detalles técnicos.

Dentro de los modelos disponibles en esta librería están:

- Distributed random forest y Extremely Randomized Trees.
- GLM
- CGBoost
- GBM
- DeepLearning
- StackedEsemble

En este caso los modelos seleccionados por AutoML son los de Gradient Boosting Machine, el Gradient Boosting Machine (GBM) es un algoritmo de aprendizaje automático basado en árboles de decisión que se utiliza para problemas de clasificación y regresión. Es una técnica de ensamblado que combina múltiples árboles de decisión débiles para formar un modelo más fuerte y preciso.

El proceso de entrenamiento del GBM comienza con la construcción de un árbol de decisión inicial que se utiliza como modelo base. Luego, se calcula el error residual entre las predicciones del modelo y los valores reales del conjunto de entrenamiento. El GBM ajusta gradualmente los árboles subsiguientes para minimizar este error residual. Cada

árbol subsiguiente se entrena de manera que se enfoque en los ejemplos que el modelo anterior predijo incorrectamente.

Ante la falta de posibilidad de interpretación del efecto de la temperatura en la mortalidad se ha planteado una segunda parte en el análisis en la que solo se verá el efecto de esta para la provincia de Madrid, el método empleado será elevar las temperaturas uno y tres grados en los datos de temperatura mínima, media y máxima junto con las variables referidas al percentil 95 de temperatura en los datos del test manteniendo los datos de temperatura mínima y máxima del percentil del training, de esta forma podremos comparar las estimaciones sin cambio de temperatura y con cambio de esta para comprobar las diferencias en la estimación que interpretaremos como el efecto del cambio de temperatura sobre la mortalidad.

## 5 RESULTADOS:

Una vez hemos descrito la base de datos y vista la motivación del trabajo pasamos a analizar los resultados obtenidos con Auto Machine Learning sobre el impacto de la temperatura en la mortalidad. Como se ha descrito con anterioridad, el análisis de este impacto está diferenciado entre hombres y mujeres.

En un primer apartado se analizará el impacto en Guadalajara, Segovia, A coruña, Madrid y Córdoba diferenciado entre hombres y mujeres, sin embargo, por la falta de posibilidad de interpretación de los resultados por la propia metodología utilizada, se planteará un segundo apartado en el que se analizará de forma aislada el efecto de la temperatura en la mortalidad para la provincia de Madrid siguiendo la metodología descrita.

Para todos los modelos el mejor algoritmo de Machine Learning resultante es el Gradient Boosting Machine.

### 5.1 ANÁLISIS DE LAS 5 PROVINCIAS:

#### 5.1.1 ANÁLISIS PARA HOMBRES:

En primer lugar, se procede a analizar la importancia de cada variable. Para este cálculo la librería de H2O mide la reducción en el error cuadrático medio entre el nodo “padre” y los nodos “hijos” (H2O, s.f.).

Figura 9

*Ranking de modelos de 5 provincias en hombres*

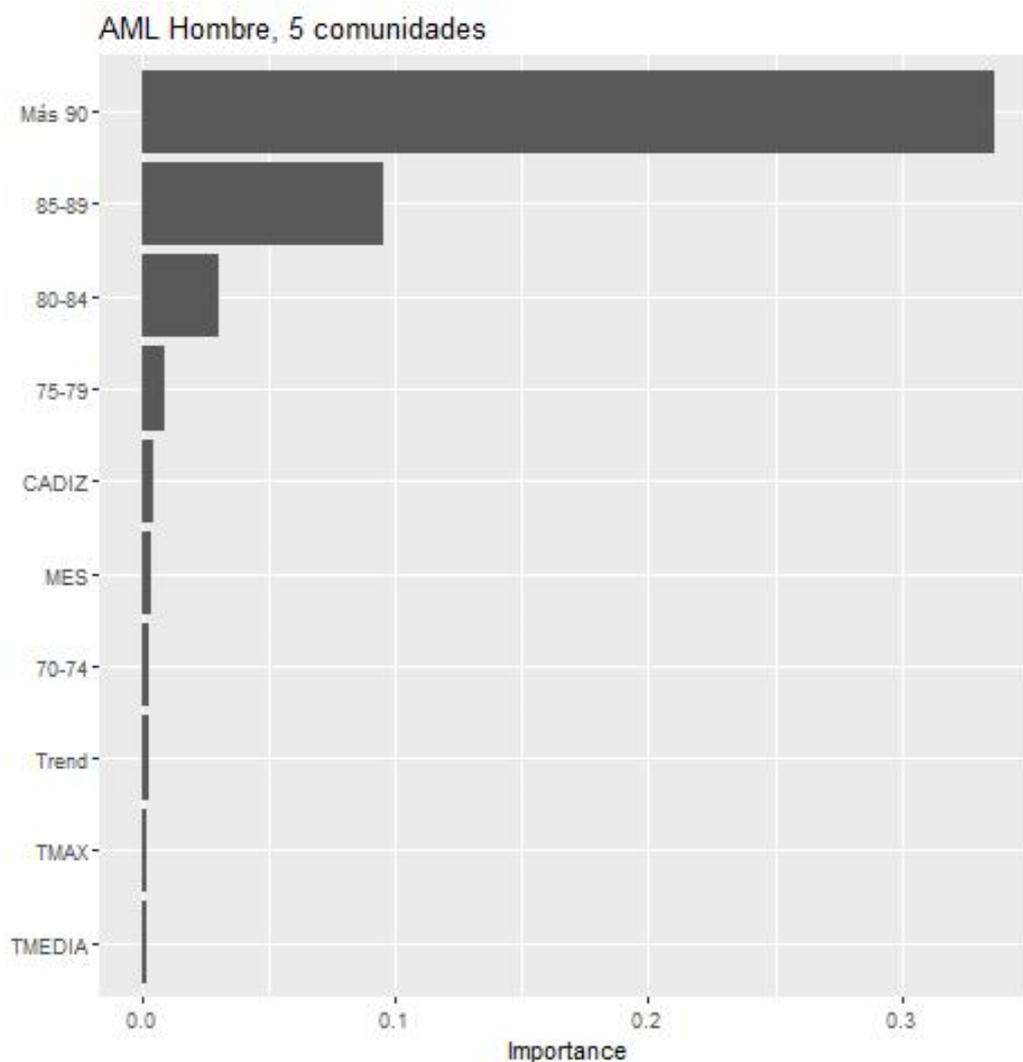
```
> automl_model@leaderboard
```

	model_id	rmse	mse	mae	rmsle	mean_residual_deviance
1	GBM_grid_1_AutoML_1_20230520_175733_model_2	0.0005425185	2.943263e-07	0.0001995552	0.0005402490	2.943263e-07
2	StackedEnsemble_AllModels_3_AutoML_1_20230520_175733	0.0005425799	2.943929e-07	0.0001995381	0.0005403101	2.943929e-07
3	StackedEnsemble_BestOfFamily_4_AutoML_1_20230520_175733	0.0005427506	2.945782e-07	0.0001995887	0.0005404800	2.945782e-07
4	GBM_2_AutoML_1_20230520_175733	0.0005438775	2.958027e-07	0.0001948022	0.0005415980	2.958027e-07
5	StackedEnsemble_BestOfFamily_2_AutoML_1_20230520_175733	0.0005439949	2.959304e-07	0.0001953040	0.0005417109	2.959304e-07
6	StackedEnsemble_AllModels_2_AutoML_1_20230520_175733	0.0005440199	2.959576e-07	0.0001953082	0.0005417358	2.959576e-07

*Fuente: Elaboración propia.*

**Figura 10**

*Importancia de variables para 5 provincias en hombres*



*Fuente: Elaboración propia*

Como se puede comprobar cuatro primeras variables en orden de importancia son relativas con las dummy de edad, de esta forma, las variables que mejor explican la mortalidad son las edades a partir de 70 años, sin embargo, las edades inferiores no explican tan bien como la variable de mes del año o de tendencia. Las siguientes variables en orden de importancia son las referidas con la temperatura mínima y máxima después de la variable dummy de Córdoba.

**Figura 11**

*Resultados para training en 5 provincias en hombres*

```
H2ORegressionModel: gbm
Model ID: GBM_grid_1_AutoML_1_20230520_175733_model_2
Model Summary:
  number_of_trees number_of_internal_trees model_size_in_bytes min_depth max_depth mean_depth min_leaves max_leaves mean_leaves
1                74                74            18904         4         4         4.00000         13         16         15.72973

H2ORegressionMetrics: gbm
** Reported on training data. **

MSE: 2.804307e-07
RMSE: 0.000529557
MAE: 0.0001960791
RMSLE: 0.0005273556
Mean Residual Deviance : 2.804307e-07

H2ORegressionMetrics: gbm
** Reported on cross-validation data. **
** 5-fold cross-validation on training data (Metrics computed for combined holdout predictions) **

MSE: 2.943263e-07
RMSE: 0.0005425185
MAE: 0.0001995552
RMSLE: 0.000540249
Mean Residual Deviance : 2.943263e-07

Cross-Validation Metrics Summary:
              mean          sd cv_1_valid cv_2_valid cv_3_valid cv_4_valid cv_5_valid
mae          0.000200 0.000003 0.000195 0.000197 0.000202 0.000201 0.000203
mean_residual_deviance 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
mse          0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
r2           0.805398 0.009720 0.810441 0.817415 0.792417 0.807312 0.799405
residual_deviance 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
rmse        0.000542 0.000021 0.000524 0.000519 0.000559 0.000543 0.000566
rmsle       0.000540 0.000021 0.000522 0.000517 0.000557 0.000540 0.000564
```

*Fuente: Elaboración propia.*

Dentro de la diagnosis del modelo podemos comprobar que el R cuadrado es 0,805398 para la validación cruzada sobre el training.

Pasamos a analizar los resultados en el test:

**Figura 12**

*Resultados en el test para 5 provincias en hombres*

```
> perf_aml_model
H2ORegressionMetrics: gbm

MSE: 2.731961e-07
RMSE: 0.0005226816
MAE: 9.696929e-05
RMSLE: 0.000517755
Mean Residual Deviance : 2.731961e-07
```

*Fuente: Elaboración propia.*

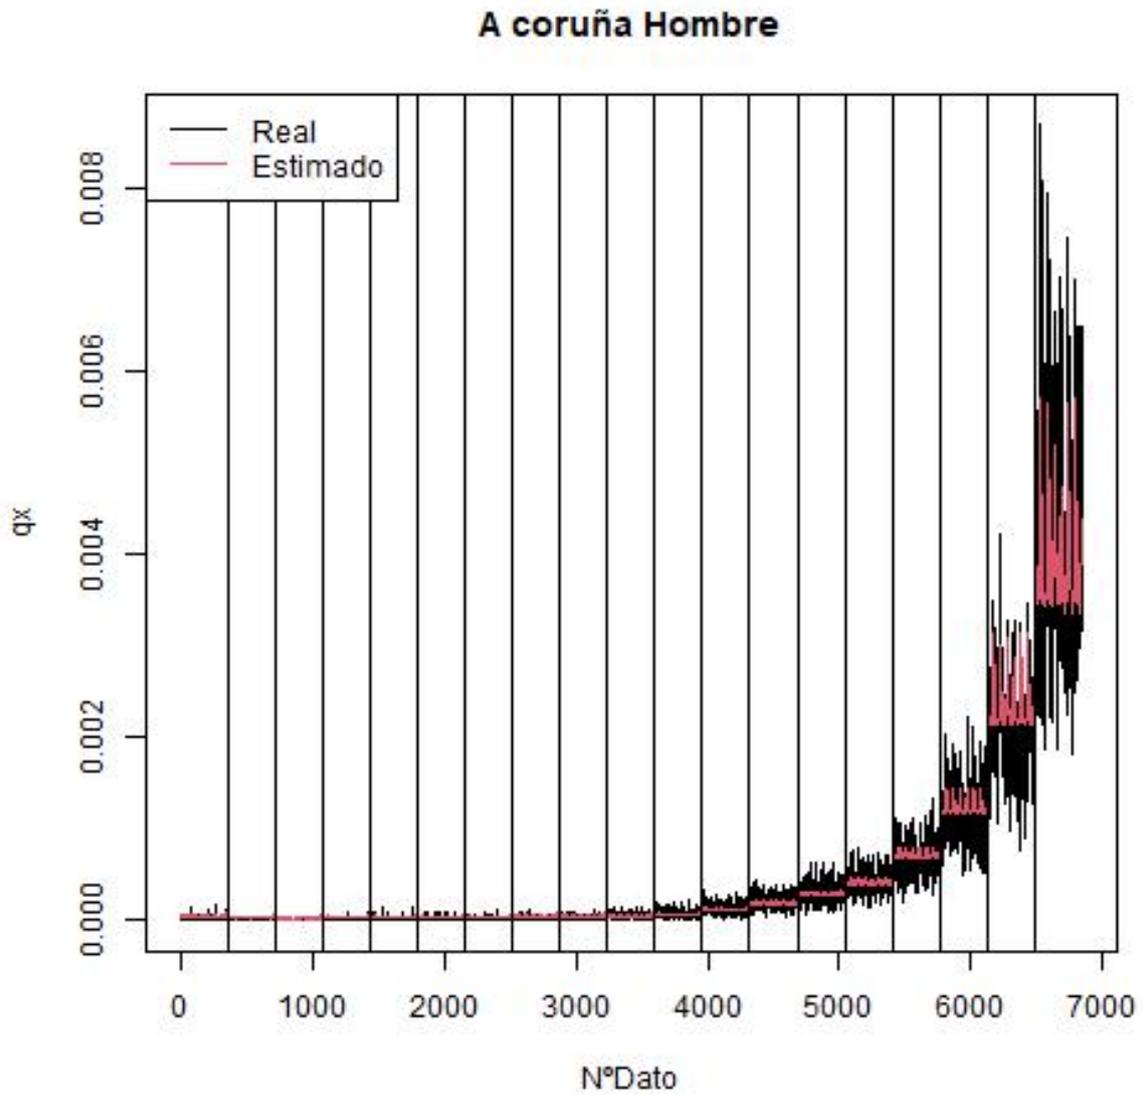
Dentro del test podemos analizar como el error cuadrático medio ha subido con respecto al training, lo cual es esperable. Dentro del análisis de gráficos podremos ver como ajusta el modelo de una manera más sencilla.

### 5.1.1.1 GRÁFICOS:

Para el análisis de los gráficos se ha graficado para todos los grupos de edad, cada grupo de edad se diferencia por una línea vertical negra con 360 datos en la serie temporal. Los valores en negro son los reales y en rojo los estimados.

**Figura 13**

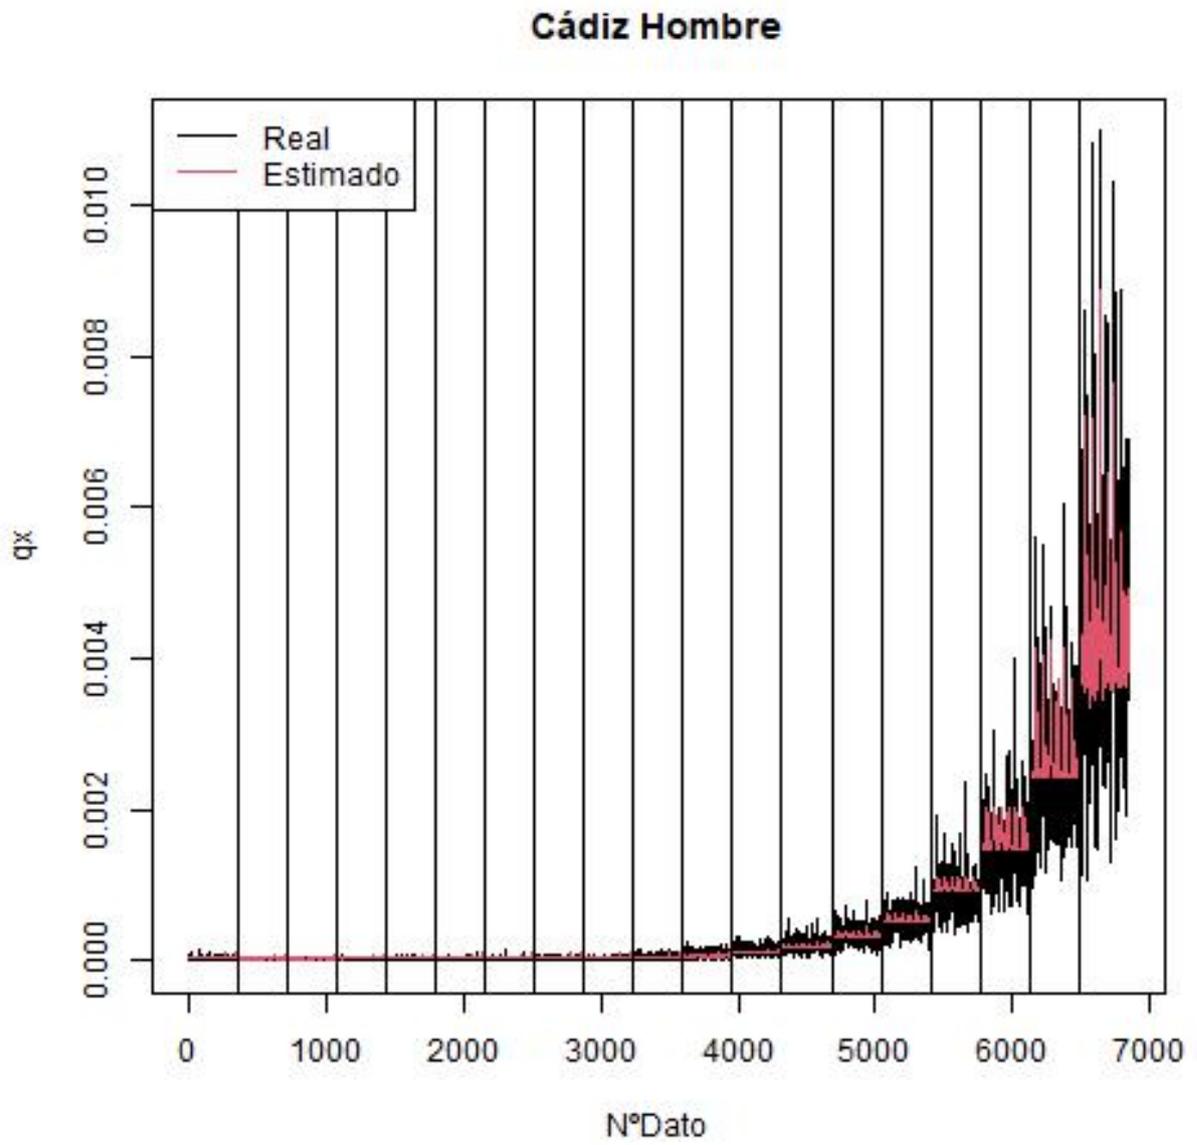
*Gráfico real y estimado para A coruña 5 provincias en hombres*



*Fuente: Elaboración propia.*

**Figura 14**

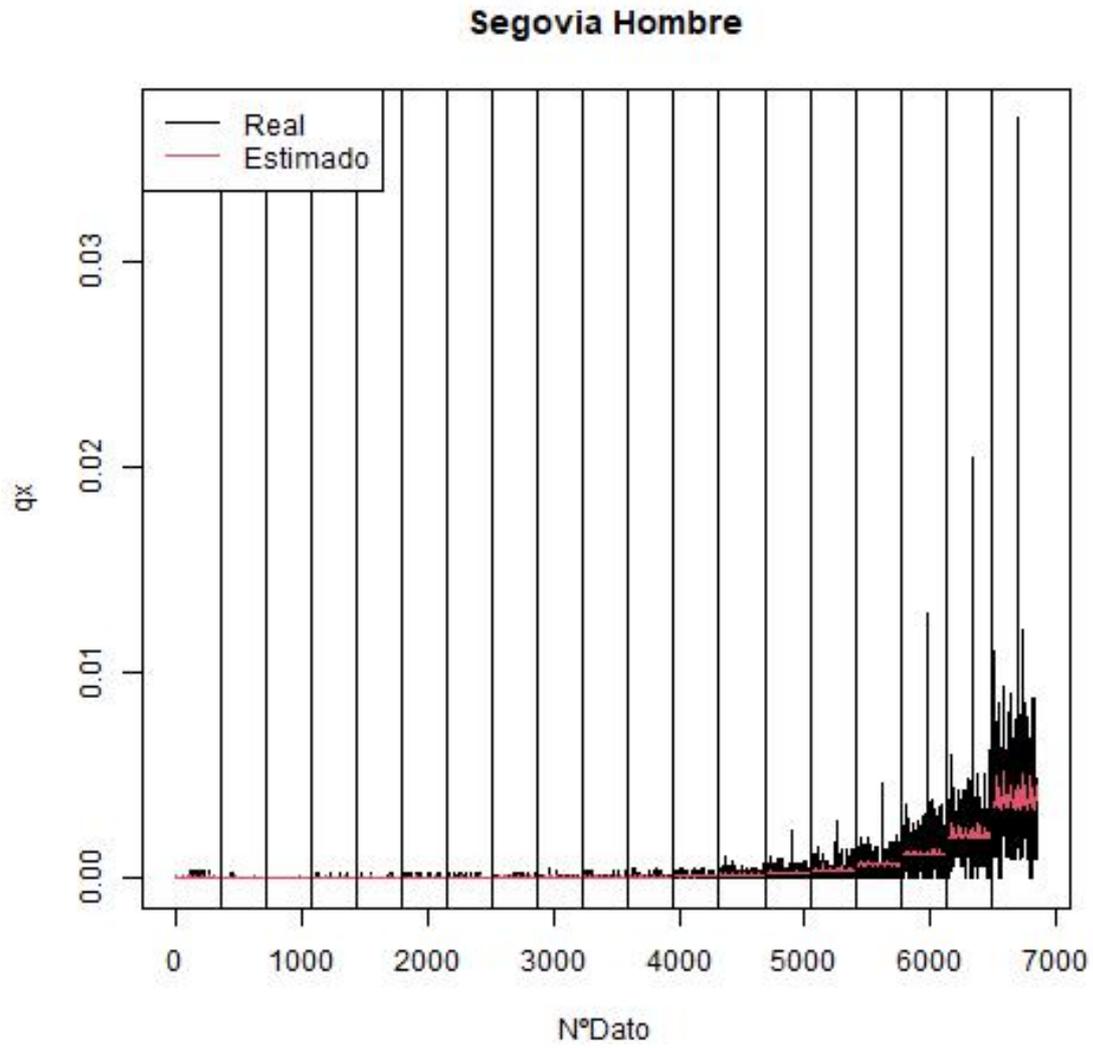
*Gráfico real y estimado para Cádiz 5 provincias en hombres*



*Fuente: Elaboración propia*

**Figura 15**

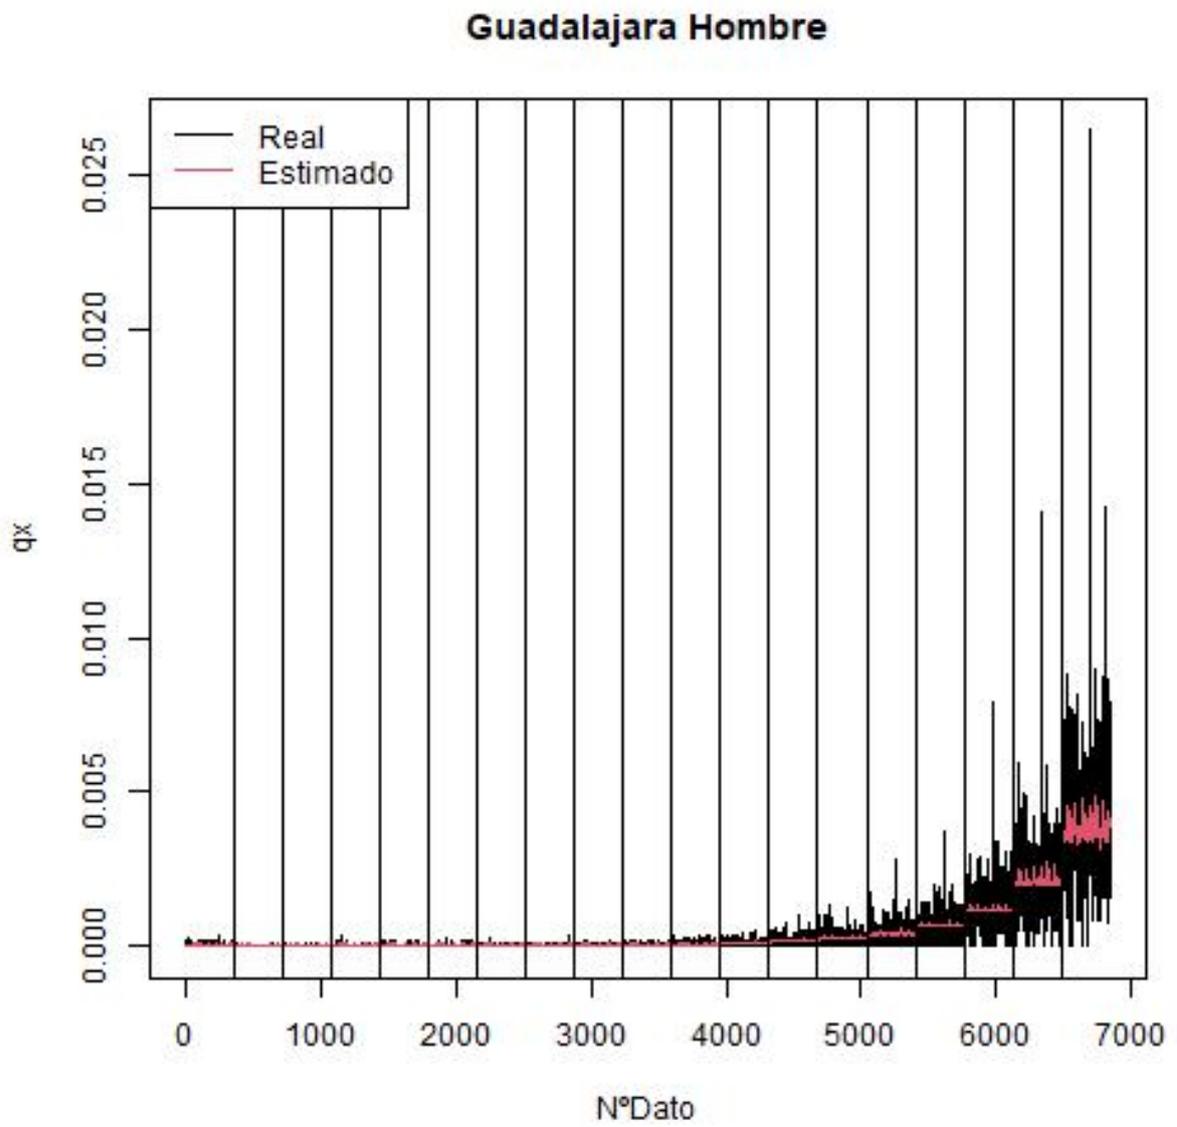
*Gráfico real y estimado para Segovia 5 provincias en hombres*



*Fuente: Elaboración propia*

**Figura 16**

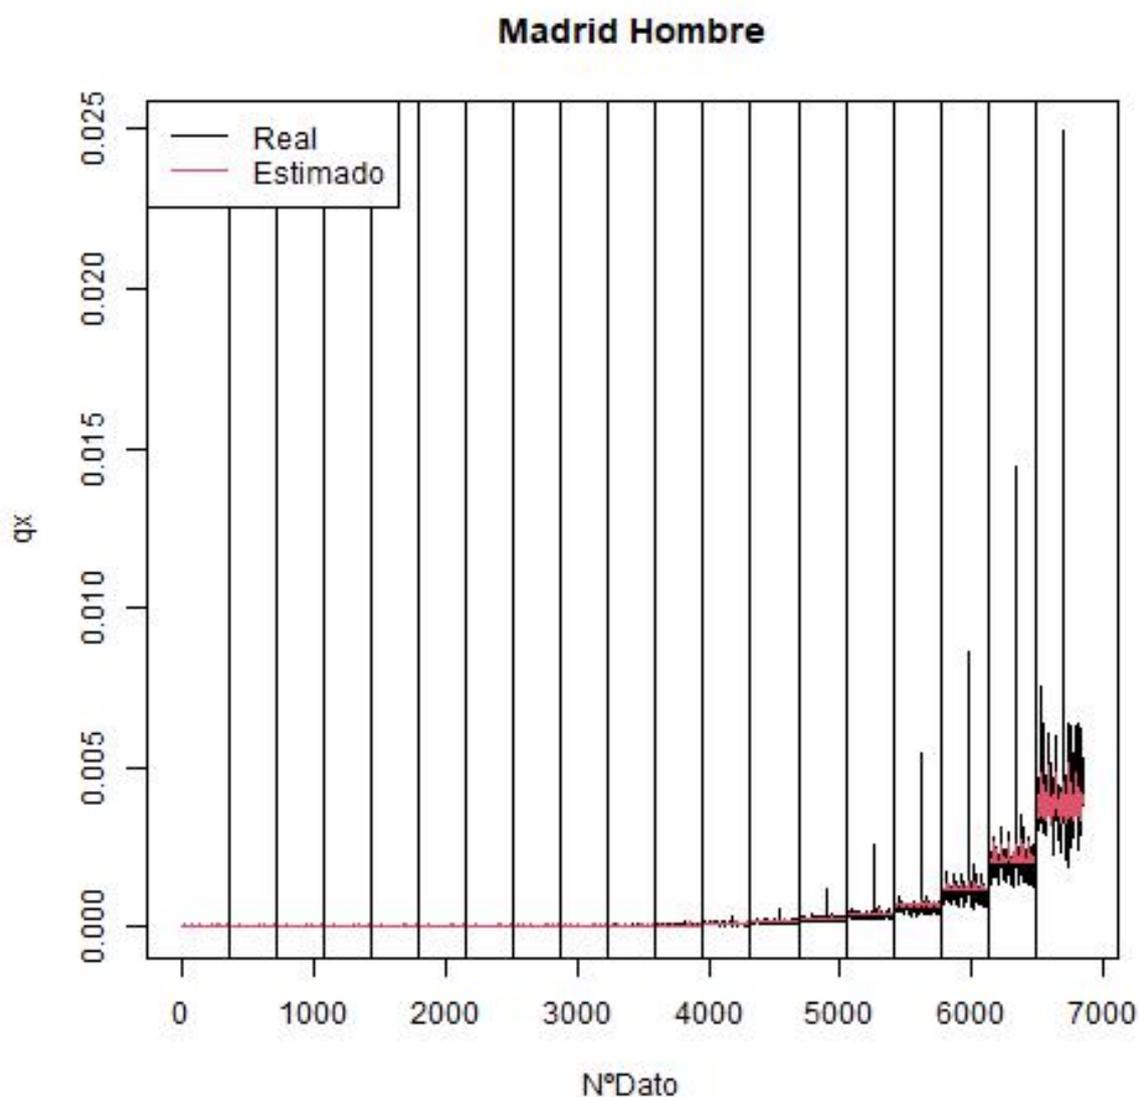
*Gráfico real y estimado para Guadalajara 5 provincias en hombres*



*Fuente: Elaboración propia*

**Figura 17**

*Gráfico real y estimado para Madrid 5 provincias en hombres*



Como se puede comprobar el modelo predice peor en las dos provincias en las que la temperatura tiene más varianza de temperaturas (Guadalajara y Segovia) además de no predecir los valores extremos de mortalidad referentes a la pandemia (valores extremos para todos los grupos de edad).

Cabe recalcar que el modelo explica mejor los movimientos de mortalidad al alza que a la baja.

Vamos a pasar a analizar los resultados para mujeres.

## 5.1.2 ANÁLISIS PARA MUJERES:

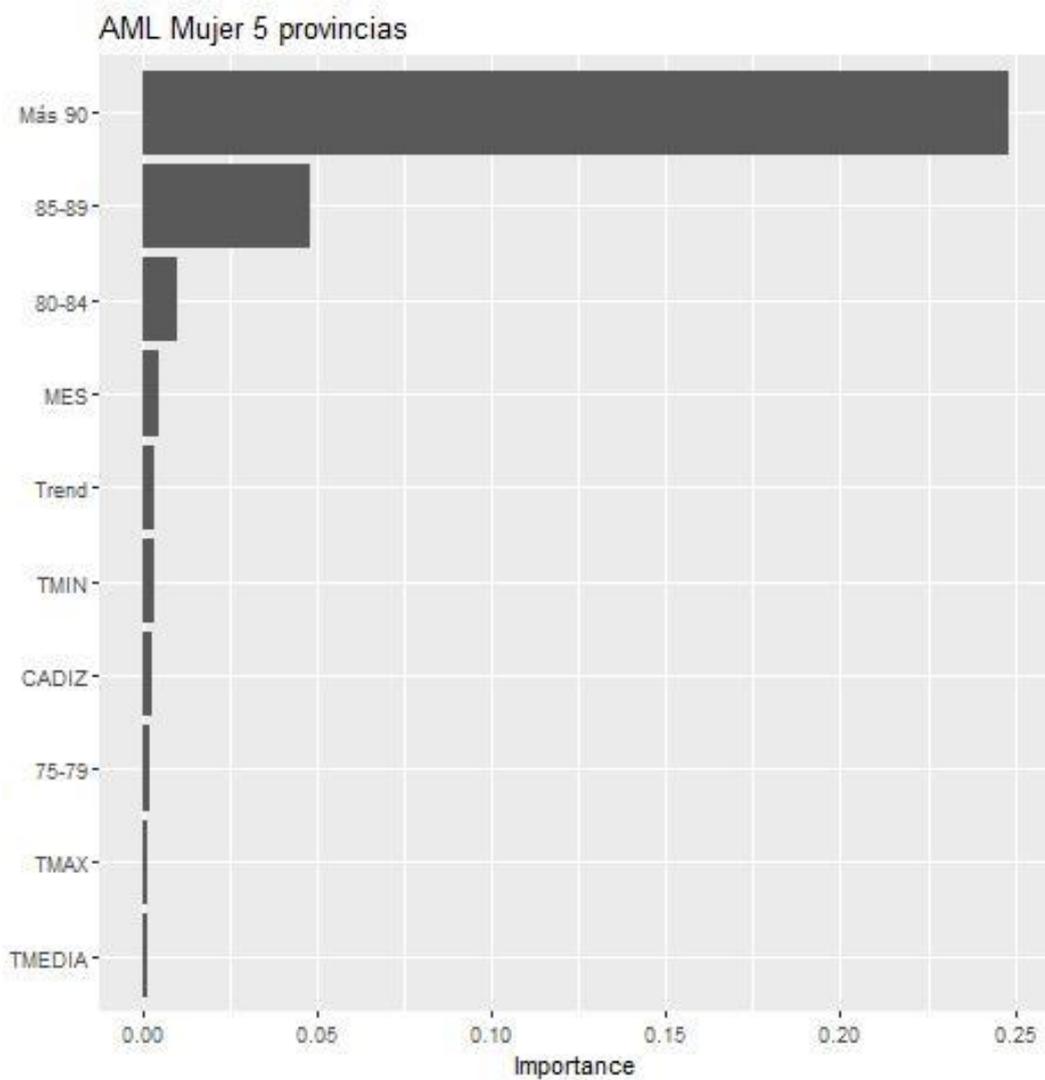
Figura 18

Ranking de variables para 5 provincias en mujeres

```
> automl_model12@leaderboard
      model_id      rmse      mse      mae      rmsle mean_residual_deviance
1 GBM_2_AutoML_2_20230520_180034 0.0003421816 1.170883e-07 0.0001208779 0.0003410118 1.170883e-07
2 StackedEnsemble_BestofFamily_3_AutoML_2_20230520_180034 0.0003422526 1.171368e-07 0.0001210092 0.0003410817 1.171368e-07
3 StackedEnsemble_BestofFamily_2_AutoML_2_20230520_180034 0.0003422716 1.171499e-07 0.0001210173 0.0003411007 1.171499e-07
4 StackedEnsemble_AllModels_1_AutoML_2_20230520_180034 0.0003422768 1.171534e-07 0.0001210089 0.0003411059 1.171534e-07
5 StackedEnsemble_AllModels_3_AutoML_2_20230520_180034 0.0003422812 1.171564e-07 0.0001210247 0.0003411104 1.171564e-07
6 StackedEnsemble_AllModels_2_AutoML_2_20230520_180034 0.0003423661 1.172146e-07 0.0001210378 0.0003411946 1.172146e-07
```

Figura 19

Importancia de variables para 5 provincias en mujeres



De la misma forma que en hombres las primeras variables en orden de explicación son las de edad, sin embargo, esta vez de 75 a 79 años no explica mejor que la temperatura mínima, de la misma forma la variable de temperatura mínima sigue explicando mejor que las variables de provincia, en cambio, la variable de temperatura máxima explica peor en el caso de mujeres que en el de hombres.

Figura 20

Resultados del training para 5 provincias en mujeres

```
> aml_model2
Model Details:
=====
H2ORegressionModel: gbm
Model ID: GBM_2_AutoML_2_20230520_180034
Model Summary:
  number_of_trees number_of_internal_trees model_size_in_bytes min_depth max_depth mean_depth min_leaves max_leaves mean_leaves
1             66             66             65512             7             7             7.00000             27             113             74.36364

H2ORegressionMetrics: gbm
** Reported on training data. **

MSE: 9.391394e-08
RMSE: 0.0003064538
MAE: 0.000117763
RMSLE: 0.0003054395
Mean Residual Deviance : 9.391394e-08

H2ORegressionMetrics: gbm
** Reported on cross-validation data. **
** 5-fold cross-validation on training data (Metrics computed for combined holdout predictions) **

MSE: 1.170883e-07
RMSE: 0.0003421816
MAE: 0.0001208779
RMSLE: 0.0003410118
Mean Residual Deviance : 1.170883e-07

Cross-validation Metrics Summary:
      mean      sd cv_1_valid cv_2_valid cv_3_valid cv_4_valid cv_5_valid
mae      0.000121 0.000002 0.000120 0.000122 0.000119 0.000122 0.000122
mean_residual_deviance 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
mse      0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
r2      0.877444 0.005170 0.882479 0.877796 0.879957 0.868808 0.878178
residual_deviance 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
rmse     0.000342 0.000010 0.000330 0.000340 0.000339 0.000358 0.000343
rmsle    0.000341 0.000010 0.000329 0.000339 0.000338 0.000357 0.000342
```

Fuente: Elaboración propia

Como se comentó con anterioridad el modelo de Machine Learning elegido vuelve a ser el de Gradient Boosting Machine pero esta vez el R cuadrado sube a 0,877444 en la validación cruzada del training, esto se repite para el caso específico de Madrid más adelante, siendo un continuo el que en mujeres el modelo explique mejor que en hombres.

Pasamos a analizar los resultados en el test:

Figura 21

Resultados en el test 5 provincias en mujeres

```
> perf_aml_model2
H2ORegressionMetrics: gbm

MSE: 1.765775e-07
RMSE: 0.0004202112
MAE: 0.0001171251
RMSLE: 0.0004174746
Mean Residual Deviance : 1.765775e-07
```

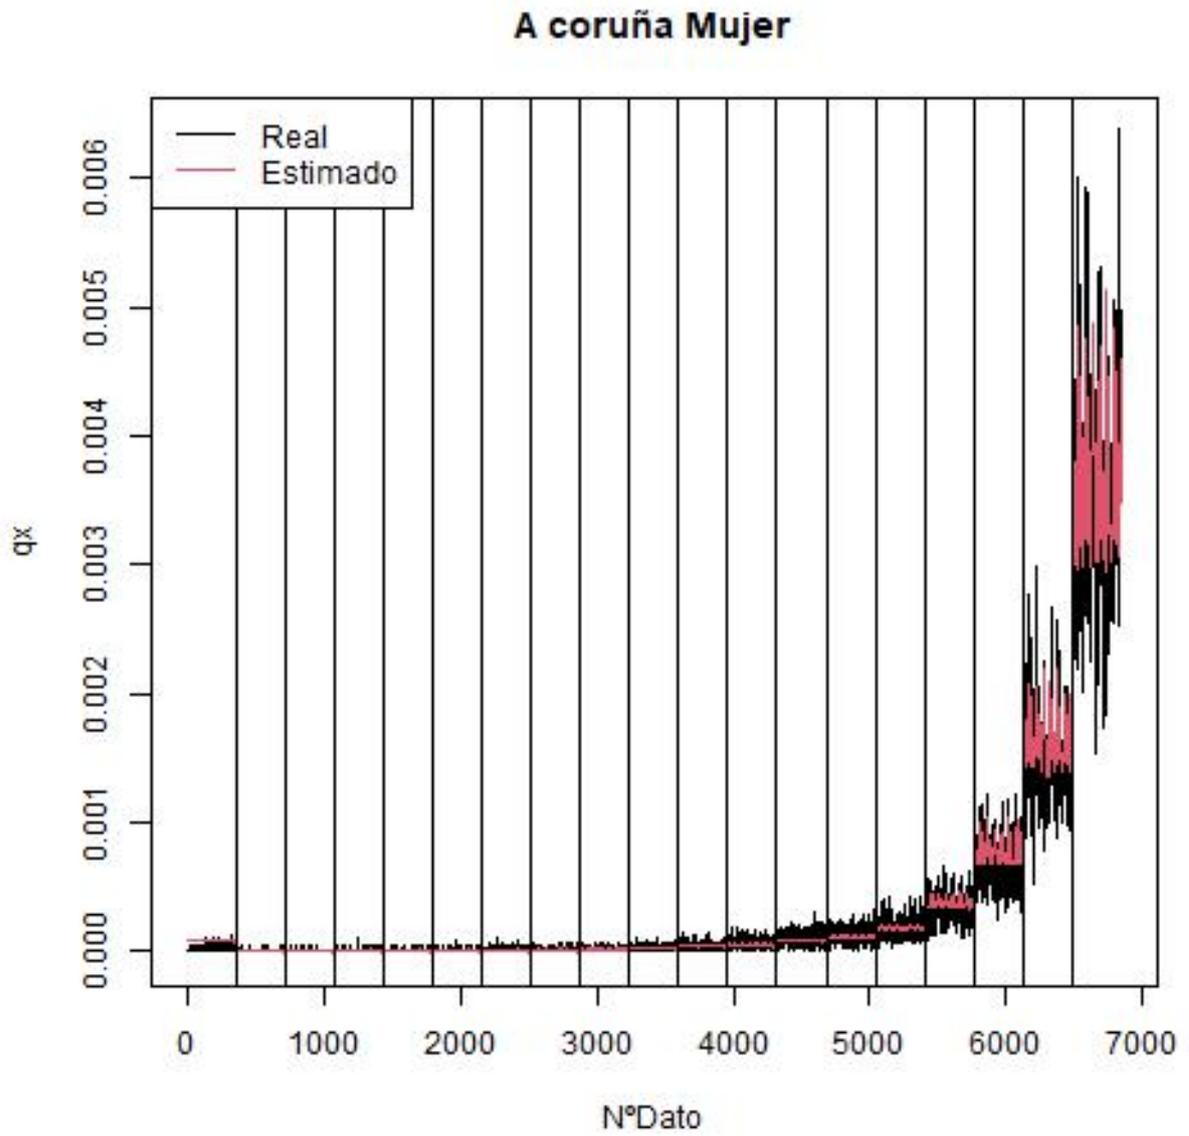
Fuente: Elaboración propia

De la misma forma que con hombres el RMSE sube en el test.

5.1.2.1 GRÁFICOS.

**Figura 22**

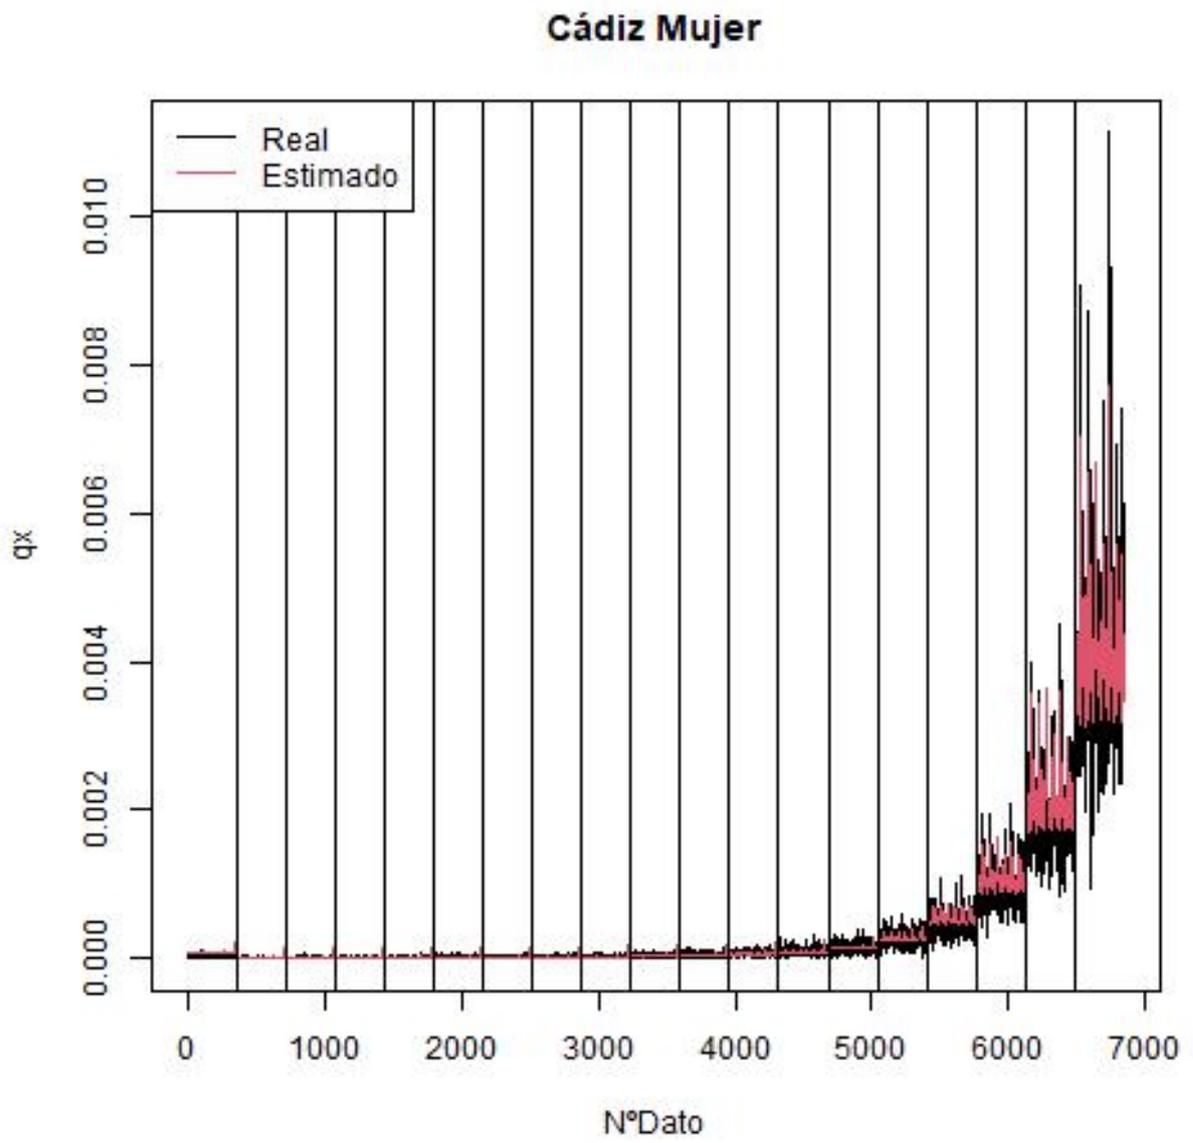
*Real y estimado para A coruña para 5 provincias en mujeres*



*Fuente: Elaboración propia*

**Figura 23**

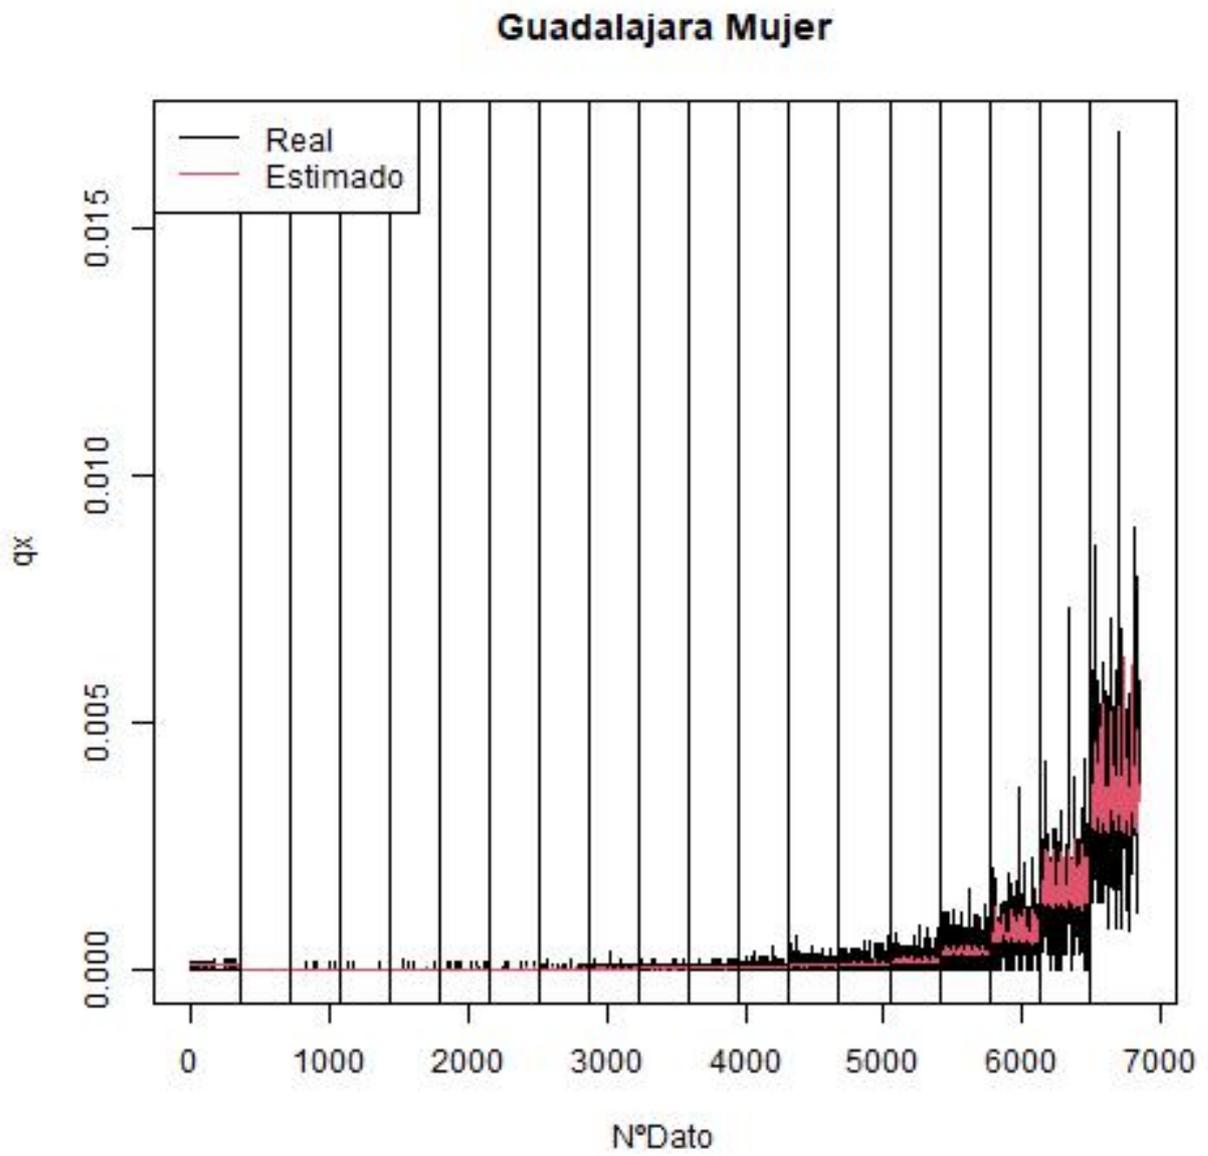
*Real y estimado para Cádiz para 5 provincias en mujeres*



*Fuente: Elaboración propia*

**Figura 24**

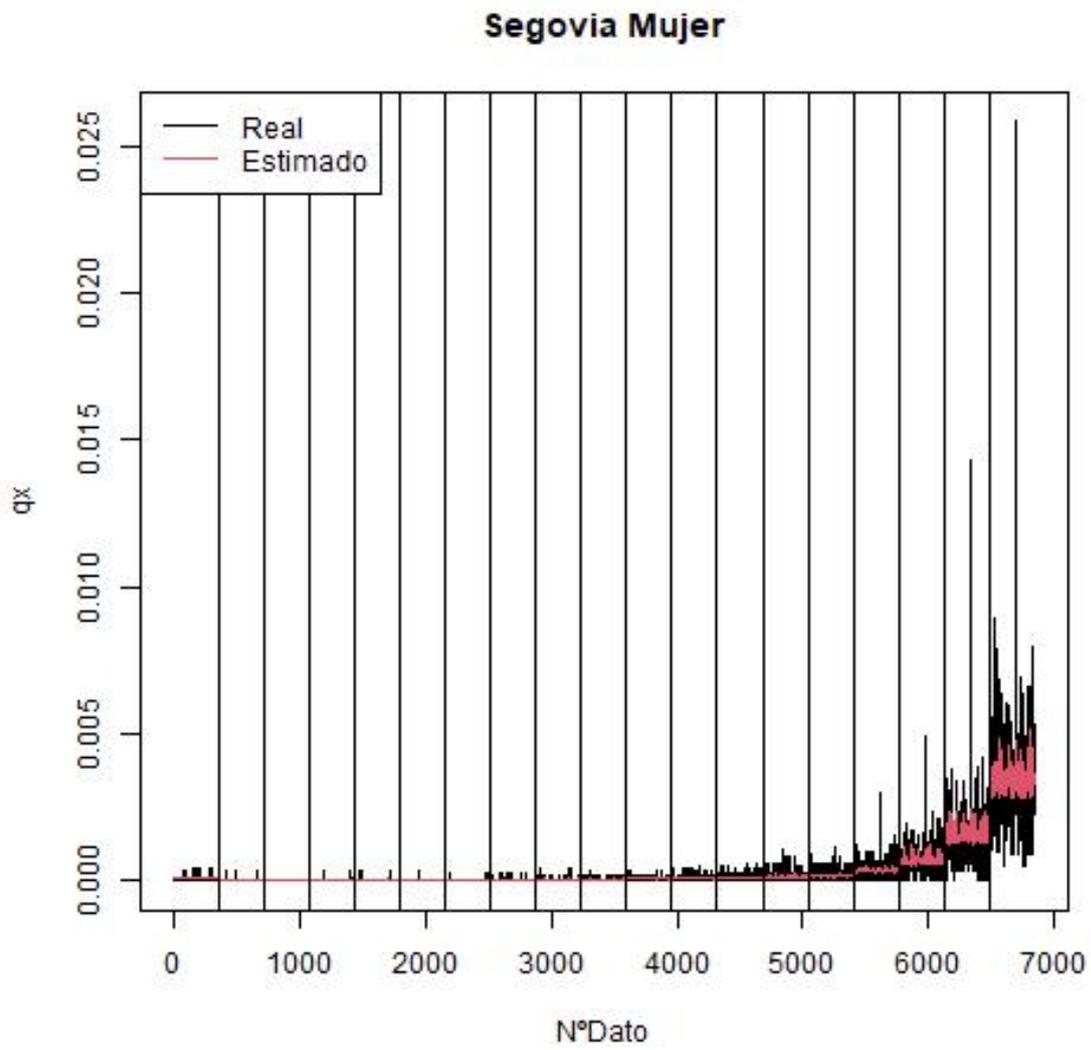
*Real y estimado para Guadalajara para 5 provincias en mujeres*



*Fuente: Elaboración propia*

**Figura 25**

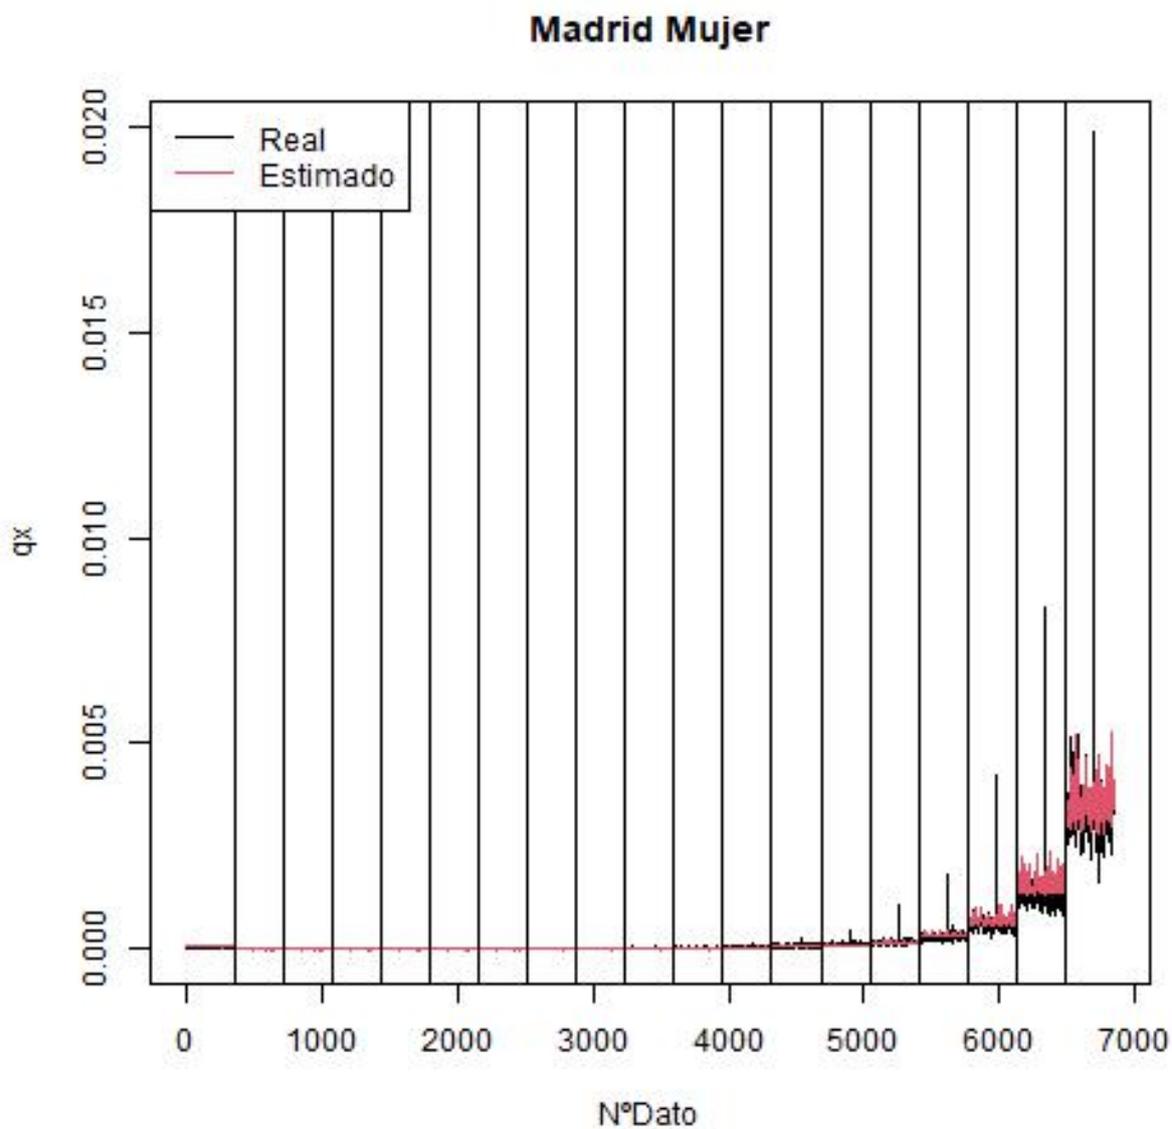
*Real y estimado para Segovia para 5 provincias en mujeres*



*Fuente: Elaboración propia*

**Figura 26**

*Real y estimado para Madrid para 5 provincias en mujeres*



*Fuente: Elaboración propia*

Gráficamente observamos resultados similares que en hombres, obteniendo errores para la estimación en el periodo de la pandemia para todos los grupos de edades y estimando mejor las subidas que las bajadas en mortalidad.

### **5.1.3 CONCLUSIONES (5 provincias)**

La estimación es mejor para mujeres que para hombres si atendemos al error cuadrático medio, además, la temperatura es relevante a la hora de explicar la mortalidad en ambos casos siendo más relevante que la edad en el caso de que esta sea menor a los 70 años en todos los casos.

La estimación es mejor para los casos de subidas de mortalidad que de bajadas.

## 5.2 RESULTADOS MADRID:

Una vez analizados los resultados para las cinco provincias pasamos a modelizar mediante Auto Machine Learning con solo los datos para Madrid, como se ha especificado anteriormente el mejor modelo de Machine Learning es el Gradient Boosting Machine.

Se analizará de la misma forma los resultados viendo la importancia de las variables, el R cuadrado en el training del modelo y el RMSE en el test además del añadido viendo el efecto de una subida de temperaturas de uno y tres grados sobre la mortalidad en distintos grupos de edad.

### 5.2.1 ANÁLISIS PARA HOMBRES:

Figura 27

Ranking de modelos para Madrid en hombres

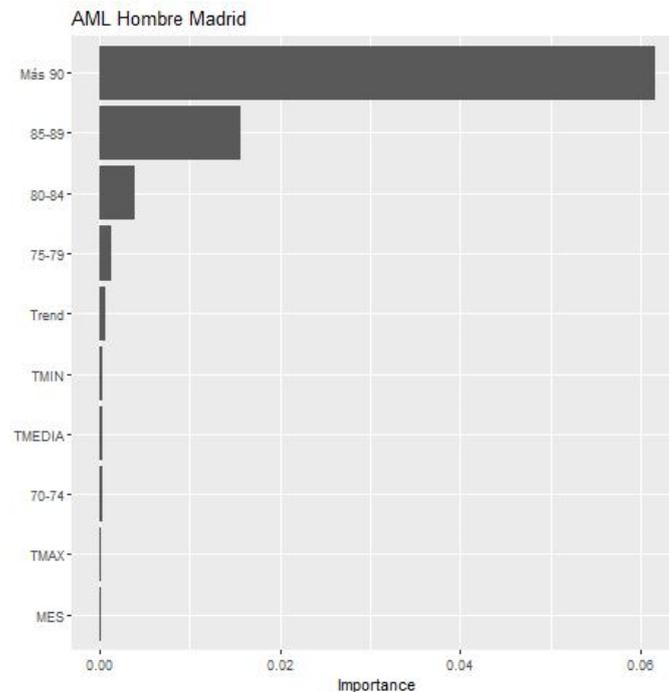
```
> automl_model13@leaderboard
```

	model_id	rmse	mse	mae	rms1e	mean_residual_deviance
1	GBM_grid_1_AutoML_3_20230520_181357_model_15	0.0002015439	4.061993e-08	7.700377e-05	0.0002007729	4.061993e-08
2	StackedEnsemble_BestOfFamily_4_AutoML_3_20230520_181357	0.0002019584	4.078718e-08	7.732873e-05	0.0002011851	4.078718e-08
3	StackedEnsemble_AllModels_4_AutoML_3_20230520_181357	0.0002023766	4.095628e-08	8.064926e-05	0.0002016072	4.095628e-08
4	StackedEnsemble_AllModels_3_AutoML_3_20230520_181357	0.0002024638	4.099159e-08	8.067435e-05	0.0002016939	4.099159e-08
5	GBM_grid_1_AutoML_3_20230520_181357_model_23	0.0002028254	4.113813e-08	7.777079e-05	0.0002020453	4.113813e-08
6	GBM_grid_1_AutoML_3_20230520_181357_model_14	0.0002029433	4.118600e-08	7.299367e-05	0.0002021563	4.118600e-08

Fuente: Elaboración propia

Figura 28

Importancia de variables para Madrid en hombres



Fuente: Elaboración propia

El orden de las variables por importancia vuelve a ser similar siendo las variables de edad las más importantes y estando las variables de temperatura en posiciones similares de importancia estando por delante de variables de edades por debajo de los 75 años.

**Figura 29**

*Datos del training del modelo en Madrid para Hombres*

```

Model Details:
=====
H2ORegressionModel: gbm
Model ID: GBM_grid_1_AutoML_3_20230520_181357_model_15
Model Summary:
  number_of_trees number_of_internal_trees model_size_in_bytes min_depth max_depth mean_depth min_leaves max_leaves mean_leaves
1             70             70             26929             5             5             5.00000             18             32             25.91429

H2ORegressionMetrics: gbm
** Reported on training data. **

MSE: 2.962845e-08
RMSE: 0.0001721292
MAE: 6.797546e-05
RMSLE: 0.0001714877
Mean Residual Deviance : 2.962845e-08

H2ORegressionMetrics: gbm
** Reported on cross-validation data. **
** 5-fold cross-validation on training data (Metrics computed for combined holdout predictions) **

MSE: 4.061993e-08
RMSE: 0.0002015439
MAE: 7.700377e-05
RMSLE: 0.0002007729
Mean Residual Deviance : 4.061993e-08

Cross-validation Metrics Summary:
      mean      sd cv_1_valid cv_2_valid cv_3_valid cv_4_valid cv_5_valid
mae      0.000076 0.000001 0.000077 0.000075 0.000079 0.000076 0.000076
mean_residual_deviance 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
mse      0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
r2      0.965410 0.001475 0.963174 0.966617 0.964628 0.966274 0.966354
residual_deviance 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
rmse     0.000202 0.000002 0.000203 0.000198 0.000205 0.000202 0.000201
rmsle    0.000201 0.000002 0.000202 0.000197 0.000204 0.000202 0.000200

```

*Fuente: Elaboración propia*

El modelo para el caso de Madrid se comporta mucho mejor que para el caso de las cinco provincias teniendo un R cuadrado de 0,965410 en la validación cruzada del training.

**Figura 30**

*Resultados en el test para hombres en Madrid*

```

> perf_aml_model3
H2ORegressionMetrics: gbm

MSE: 2.791074e-07
RMSE: 0.0005283062
MAE: 9.46729e-05
RMSLE: 0.0005233358
Mean Residual Deviance : 2.791074e-07

```

*Fuente: Elaboración propia*

#### 5.2.1.1 *Análisis en test con cambio de temperaturas de uno y tres grados:*

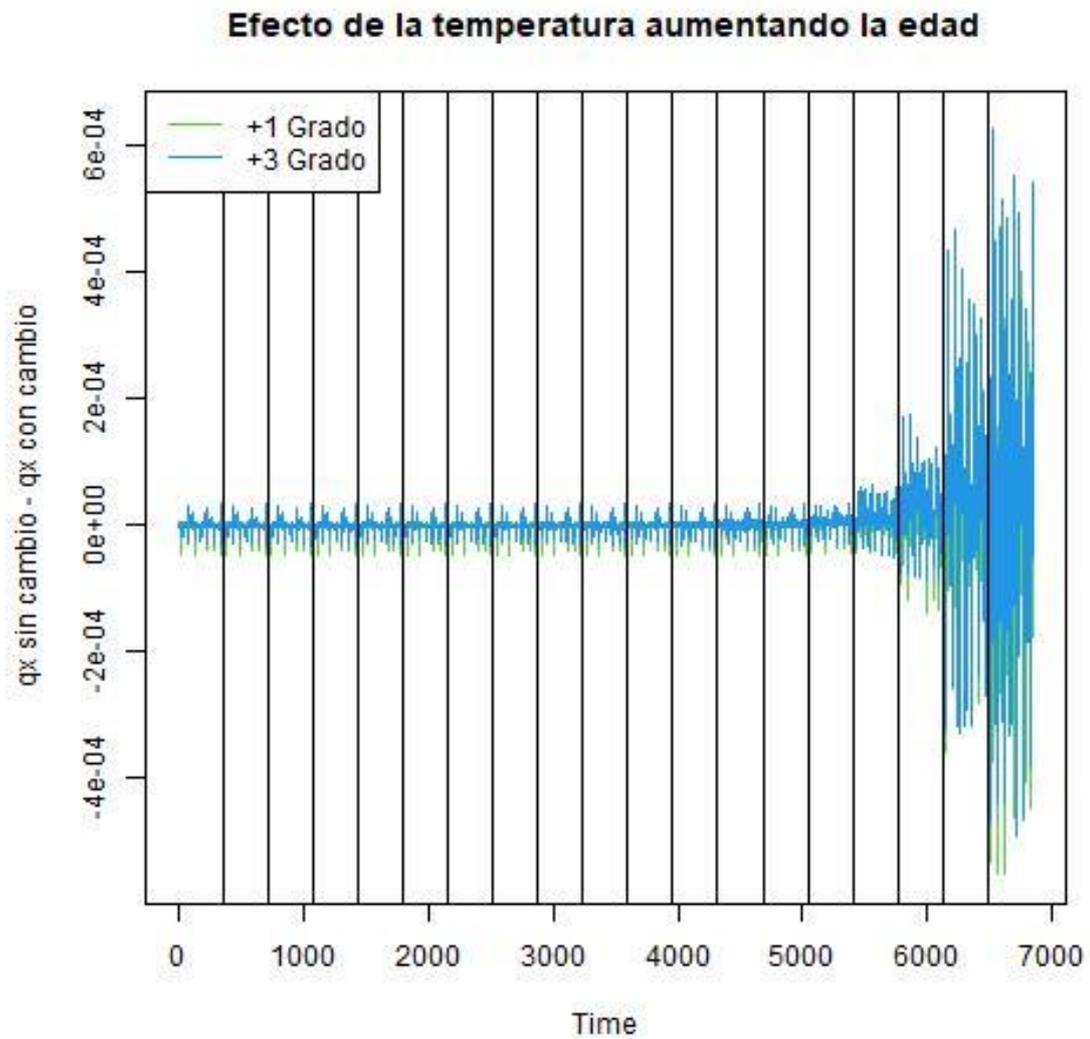
Como se especificó anteriormente, ya que no se tiene la capacidad de interpretar los resultados con un coeficiente, intentaremos analizar el efecto de la temperatura en la mortalidad aumentando uno y tres grados en el test todas las variables relacionadas con la temperatura y modificando las variables que tienen que ver con el percentil de esta, dejando fija la temperatura del percentil 95 de temperatura máxima y mínima del training y ejecutando la predicción de la mortalidad del modelo con esta variación.

Como se explicará más adelante, el efecto del aumento de la temperatura aumenta la mortalidad en los meses en los que hace más calor y la disminuye en los meses en los que hace menos calor.

En un primer lugar se plantea la diferencia entre la predicción sin aumento de temperaturas y con un aumento en uno y tres grados de forma gráfica, de esta forma, se realiza la resta entre el valor predicho sin cambio de temperaturas y con cambio, por lo que, si tenemos un resultado relativo negativo, se interpreta como que la estimación de la mortalidad con el cambio de temperaturas es mayor a sin este cambio y de manera contraria para el caso contrario.

**Figura 31**

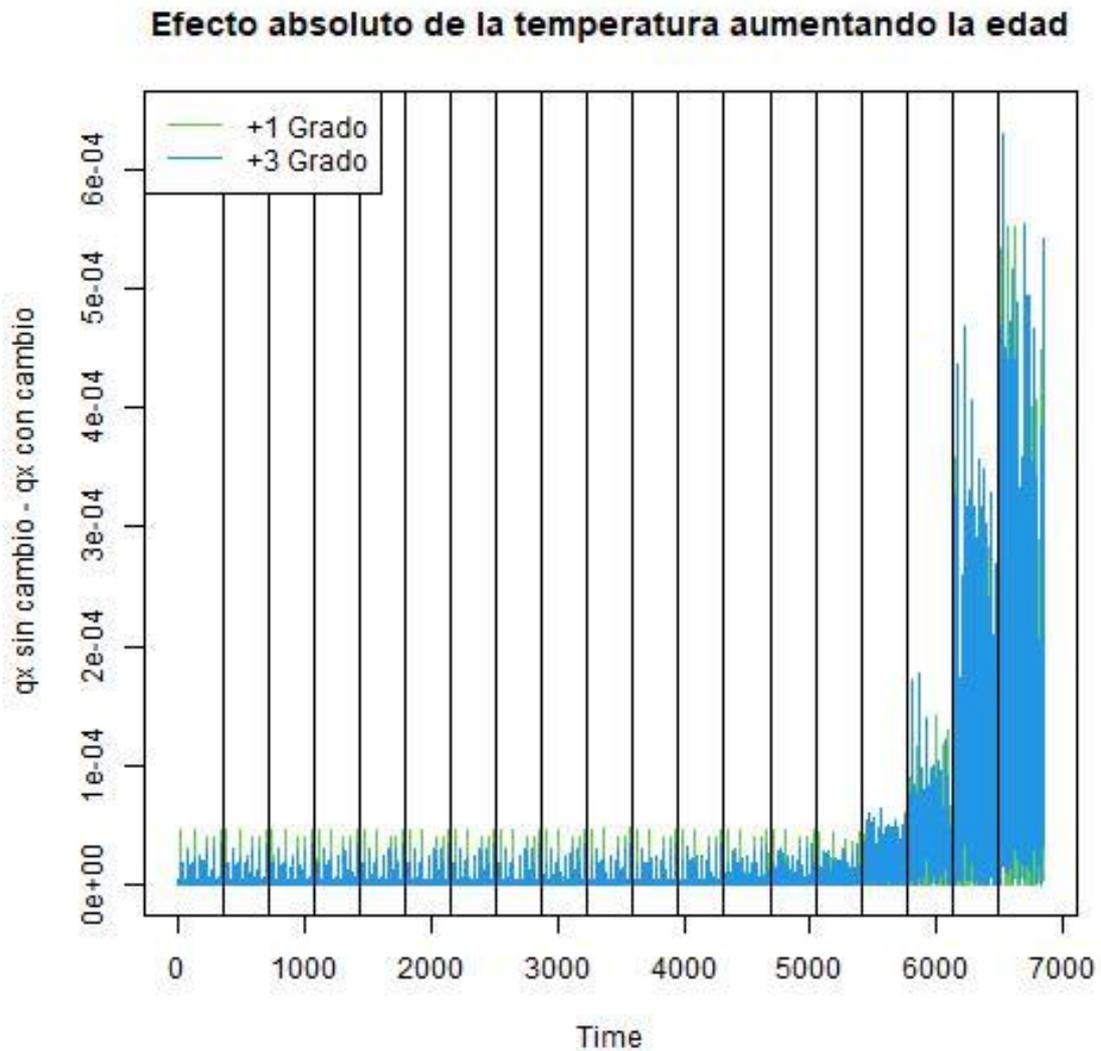
*Efecto de la temperatura aumentando la edad para Madrid en hombres*



El efecto relativo del cambio de temperaturas es mayor cuando aumenta la edad, asemejándose a un efecto exponencial a partir de los 80 años. Lo veremos de mejor manera viendo el efecto absoluto.

Figura 32

Efecto absoluto de la temperatura aumentando la edad



Fuente: Elaboración propia

En este gráfico podemos ver el efecto absoluto, es decir, sin tener en cuenta el signo, de los aumentos de temperatura, no siendo lineal este efecto con el aumento de la edad.

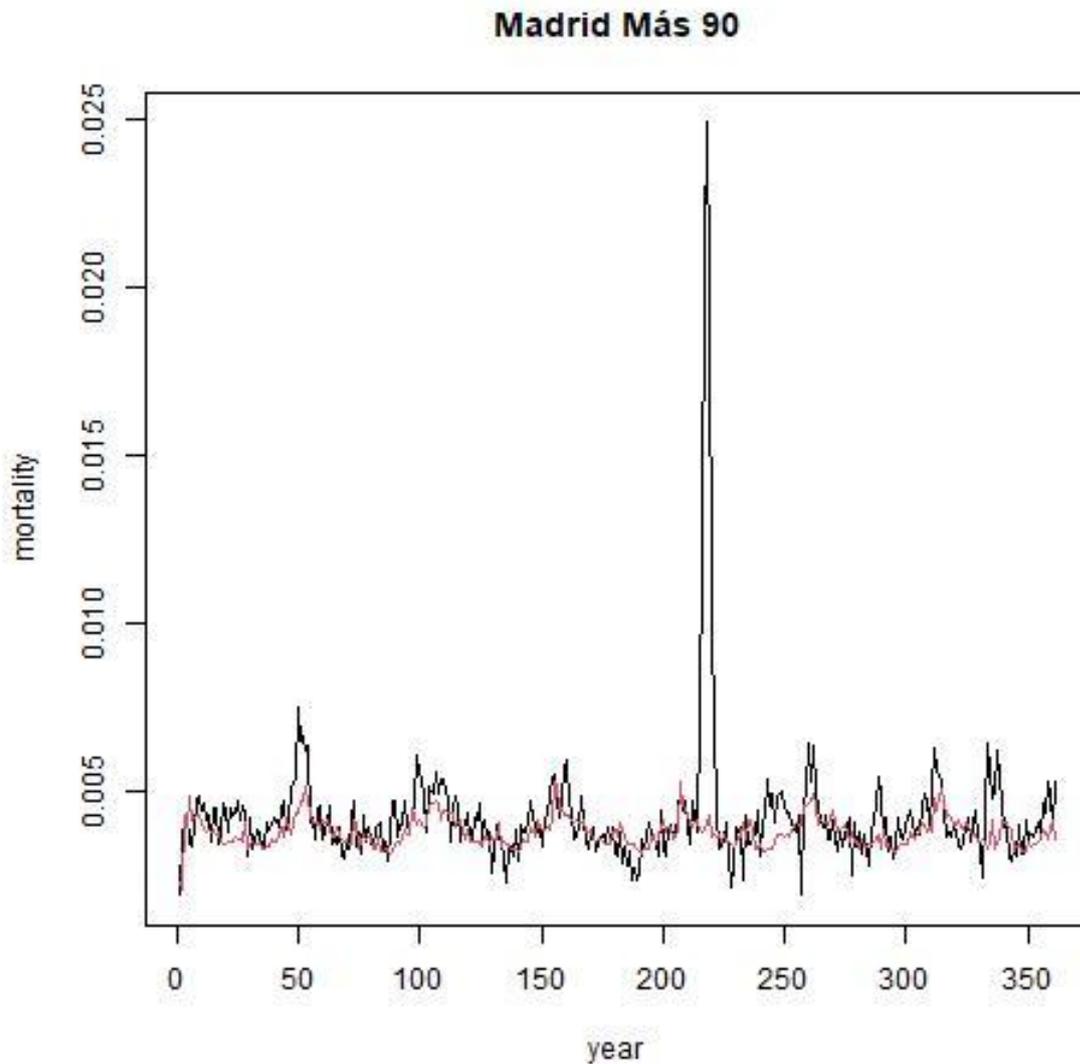
En las edades en las que empezamos a encontrar un cambio en el efecto de la temperatura son a partir de los 75 años siendo a partir de los 90 donde vemos el mayor efecto y siempre siendo creciente con el aumento de la edad.

Para poder analizar los efectos de la temperatura vamos a centrar el análisis para mayores de 90 años los cuales identificamos como los más afectados.

En primer lugar, analicemos los datos reales (en negro) con los datos estimados sin cambio de temperatura (en rojo) dentro del test.

**Figura 33**

*Real y estimado para mayores de 90 madrileños hombres*



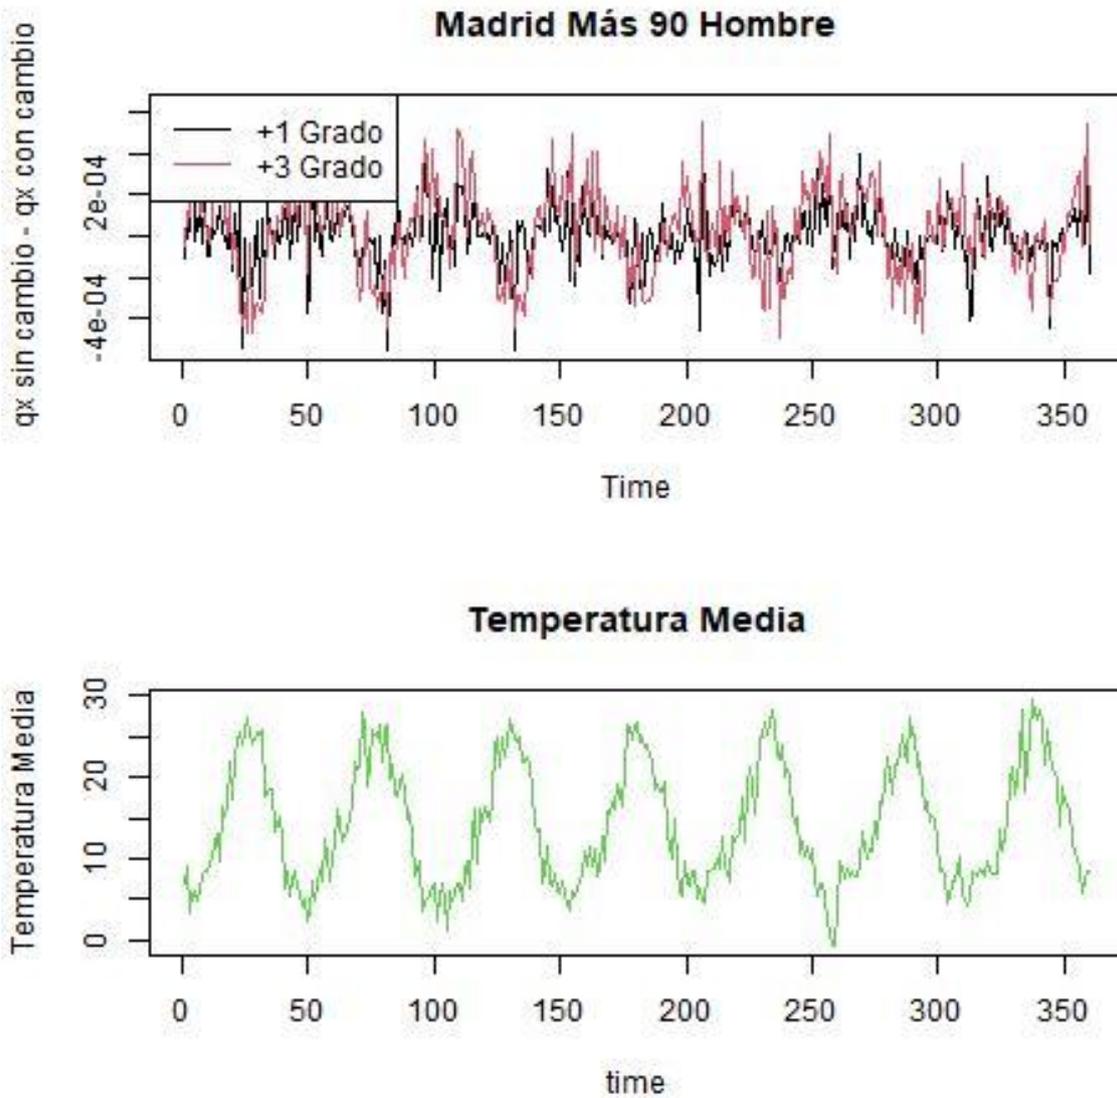
*Fuente: Elaboración propia*

Se puede ver como en el periodo de la pandemia no se estima el enorme aumento de mortalidad ya que este modelo no tiene experiencia previa de ningún fenómeno similar en el entrenamiento con lo que tampoco se esperaba que estimase bien en estas condiciones.

Una vez vistos los datos reales vamos a comprobar el efecto de la temperatura en la estimación de mortalidad.

**Figura 34**

*Efecto de una subida de uno y tres grados en la mortalidad para madrileños hombres y temperatura media*



En el gráfico de arriba podemos ver el efecto del aumento de uno y tres grados mientras que en el de abajo podemos ver la temperatura media.

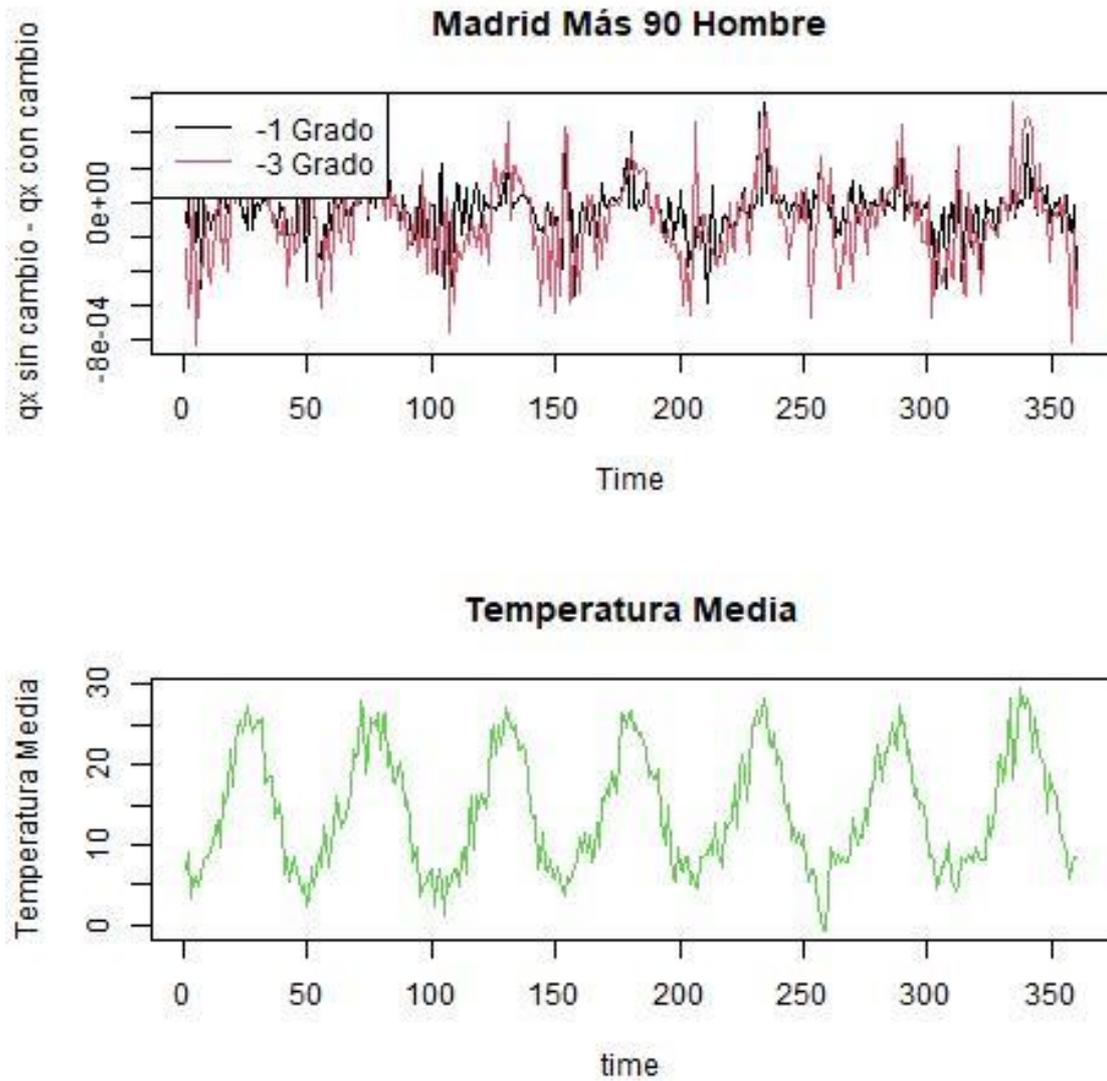
Tal y como se esperaba, el efecto del aumento de temperatura implica un aumento en la mortalidad en los periodos en los que la temperatura es alta, mientras que cuando la temperatura es baja el efecto de un aumento de esta resulta en una reducción de la mortalidad.

En conclusión, podemos ver como el modelo estima una mayor mortalidad con el aumento de la temperatura en periodos en la que esta es alta y una reducción en los que

es baja, de la misma forma ocurre con la temperatura mínima (en rojo -3 grados y negro -1 grado):

**Figura 35**

*Efecto de una bajada de uno y tres grados en la mortalidad para madrileños hombres y temperatura media*



## 5.2.2 ANÁLISIS PARA MUJERES:

Figura 36

Ranking de modelos para mujeres madrileñas

```
> automl_model14@leaderboard
```

	model_id	rmse	mse	mae	rmsle	mean_residual_deviance
1	GBM_grid_1_AutoML_4_20230520_182312_model_26	0.0001234518	1.524034e-08	4.471737e-05	0.0001230494	1.524034e-08
2	GBM_grid_1_AutoML_4_20230520_182312_model_3	0.0001235157	1.525613e-08	4.365240e-05	0.0001231117	1.525613e-08
3	GBM_5_AutoML_4_20230520_182312	0.000123609	1.526731e-08	4.590069e-05	0.0001231620	1.526731e-08
4	StackedEnsemble_BestOffFamily_4_AutoML_4_20230520_182312	0.0001236016	1.527737e-08	4.505982e-05	0.0001231982	1.527737e-08
5	StackedEnsemble_BestOffFamily_3_AutoML_4_20230520_182312	0.0001237167	1.530582e-08	4.577228e-05	0.0001233165	1.530582e-08
6	StackedEnsemble_AllModels_2_AutoML_4_20230520_182312	0.0001237554	1.531540e-08	4.578069e-05	0.0001233551	1.531540e-08

Figura 37

Resultados en el training de mujeres madrileñas

```
H2ORegressionModel: gbm
Model ID: GBM_grid_1_AutoML_4_20230520_182312_model_26
Model Summary:
  number_of_trees number_of_internal_trees model_size_in_bytes min_depth max_depth mean_depth min_leaves max_leaves mean_leaves
1             77             77             30618             5             5             5.00000             13             32             26.94805

H2ORegressionMetrics: gbm
** Reported on training data. **

MSE: 9.689903e-09
RMSE: 9.84373e-05
MAE: 3.862002e-05
RMSLE: 9.813687e-05
Mean Residual Deviance : 9.689903e-09

H2ORegressionMetrics: gbm
** Reported on cross-validation data. **
** 5-fold cross-validation on training data (Metrics computed for combined holdout predictions) **

MSE: 1.524034e-08
RMSE: 0.0001234518
MAE: 4.471737e-05
RMSLE: 0.0001230494
Mean Residual Deviance : 1.524034e-08

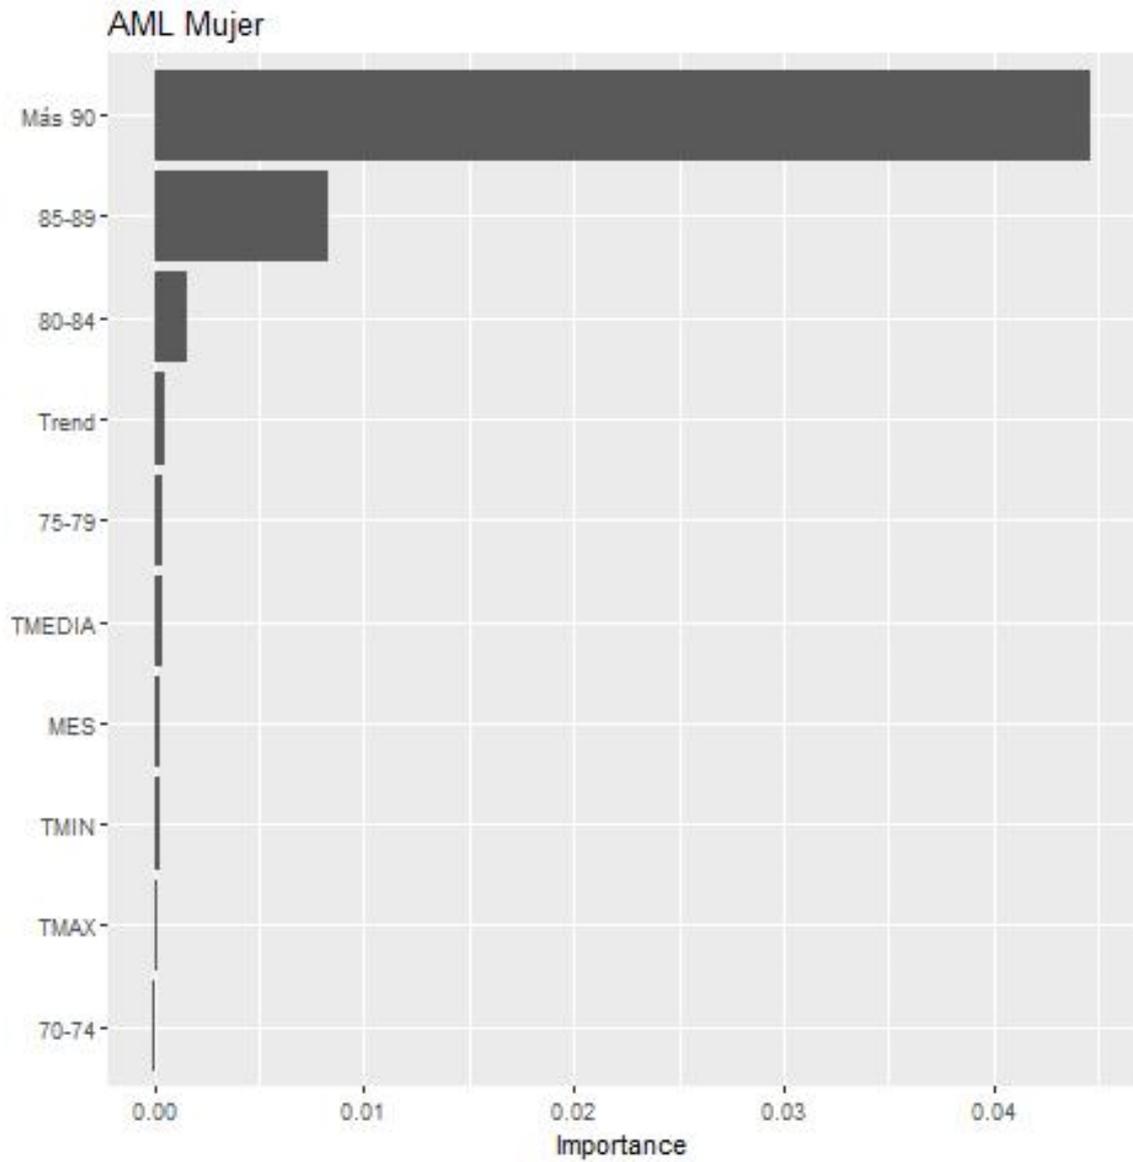
Cross-Validation Metrics Summary:
              mean          sd cv_1_valid cv_2_valid cv_3_valid cv_4_valid cv_5_valid
mae          0.000045 0.000001 0.000044 0.000045 0.000045 0.000044 0.000046
mean_residual_deviance 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
mse          0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
r2           0.979328 0.000289 0.979427 0.979113 0.978942 0.979618 0.979542
residual_deviance 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000 0.000000
rmse         0.000123 0.000001 0.000122 0.000123 0.000125 0.000124 0.000124
rmsle        0.000123 0.000001 0.000122 0.000122 0.000124 0.000123 0.000123
```

Fuente: Elaboración propia

Igual que en el caso de las cinco provincias el R cuadrado es mayor para mujeres que para hombres en la validación cruzada del training con un R cuadrado de 0,979328 por lo que nuestro modelo en todos los casos estima mejor la mortalidad para mujeres que para hombres.

**Figura 38**

*Importancia de variables para mujeres madreñas*



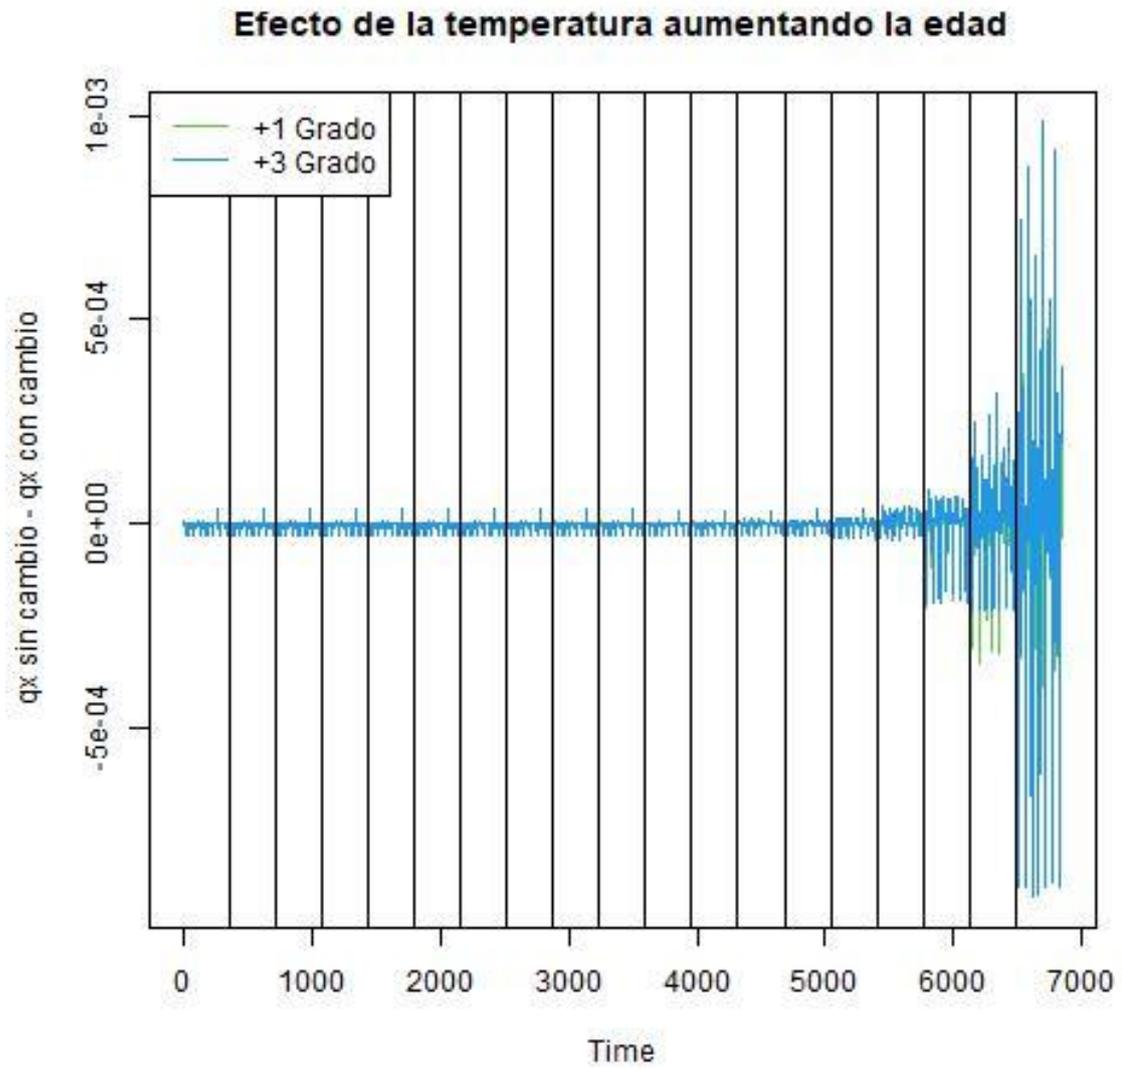
*Fuente: Elaboración propia*

La importancia de las variables de temperatura sigue siendo alta después de las variables de edad siendo las más representativas desde más de 90 años hasta los 75.

5.2.2.1 Análisis en test con cambio de temperaturas de uno y tres grados:

**Figura 39**

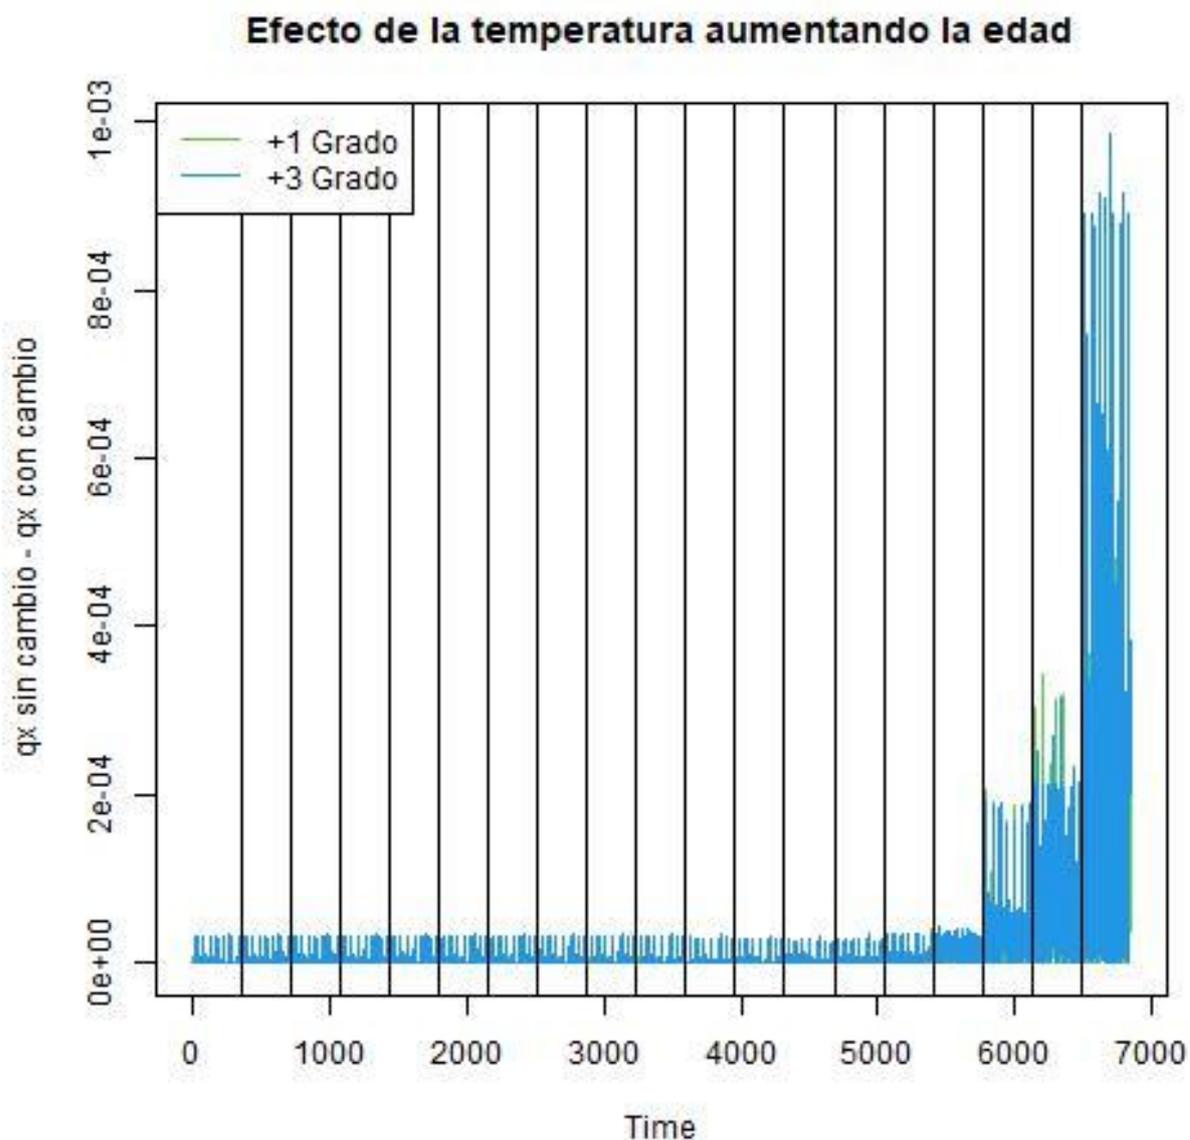
*Efecto de la temperatura aumentando la edad para mujeres madrileñas*



*Fuente: Elaboración propia*

**Figura 40**

*Efecto absoluto de la temperatura para mujeres madrileñas*



*Fuente: Elaboración propia*

En este gráfico podemos ver el efecto absoluto, es decir, sin tener en cuenta el signo, de los aumentos de temperatura, no siendo lineal este efecto con el aumento de la edad.

En las edades en las que empezamos a encontrar un cambio en el efecto de la temperatura son a partir de los 80 años siendo a partir de los 90 donde vemos el mayor efecto y siempre siendo creciente con el aumento de la edad.

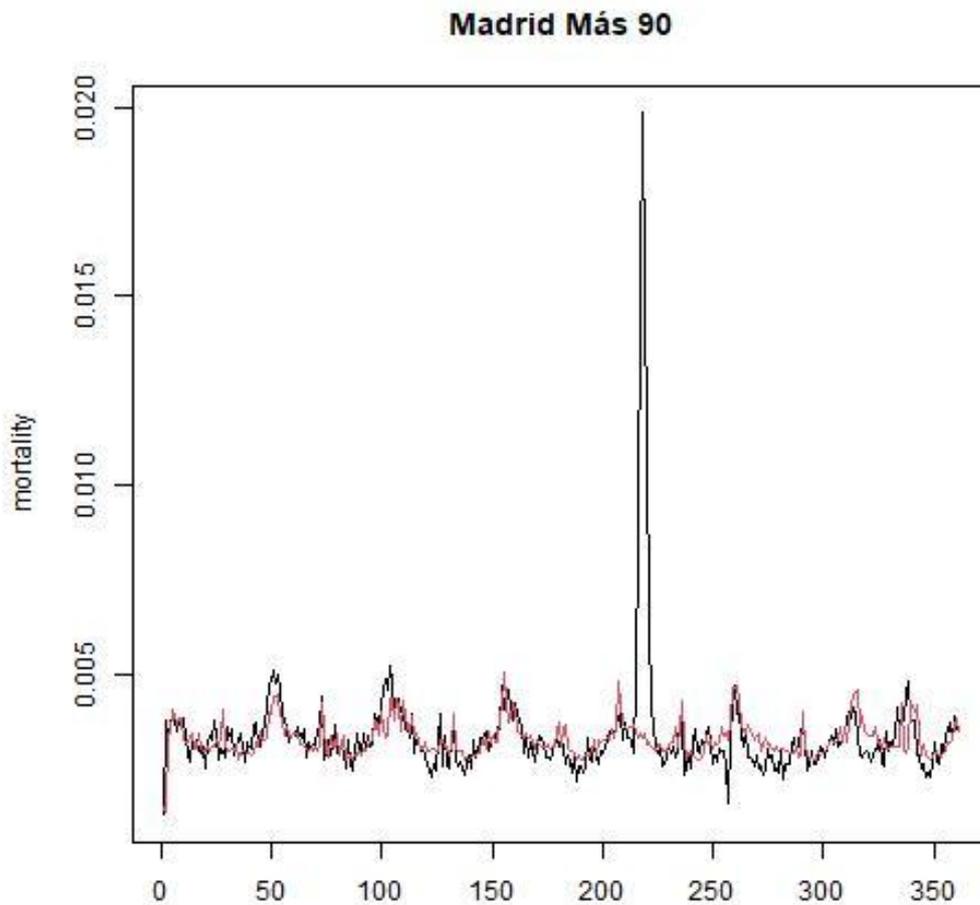
Comparando el efecto entre hombres y mujeres podemos ver que existe una diferencia notable entre el grupo de edades de 85 a 89 y más de 90.

Para poder analizar los efectos de la temperatura vamos a centrar el análisis para mayores de 90 años los cuales identificamos como los más afectados.

En primer lugar, analicemos los datos reales (en negro) con los datos estimados sin cambio de temperatura (en rojo) dentro del test.

**Figura 41**

*Real y estimado para mayores de 90 años mujeres madrileñas*



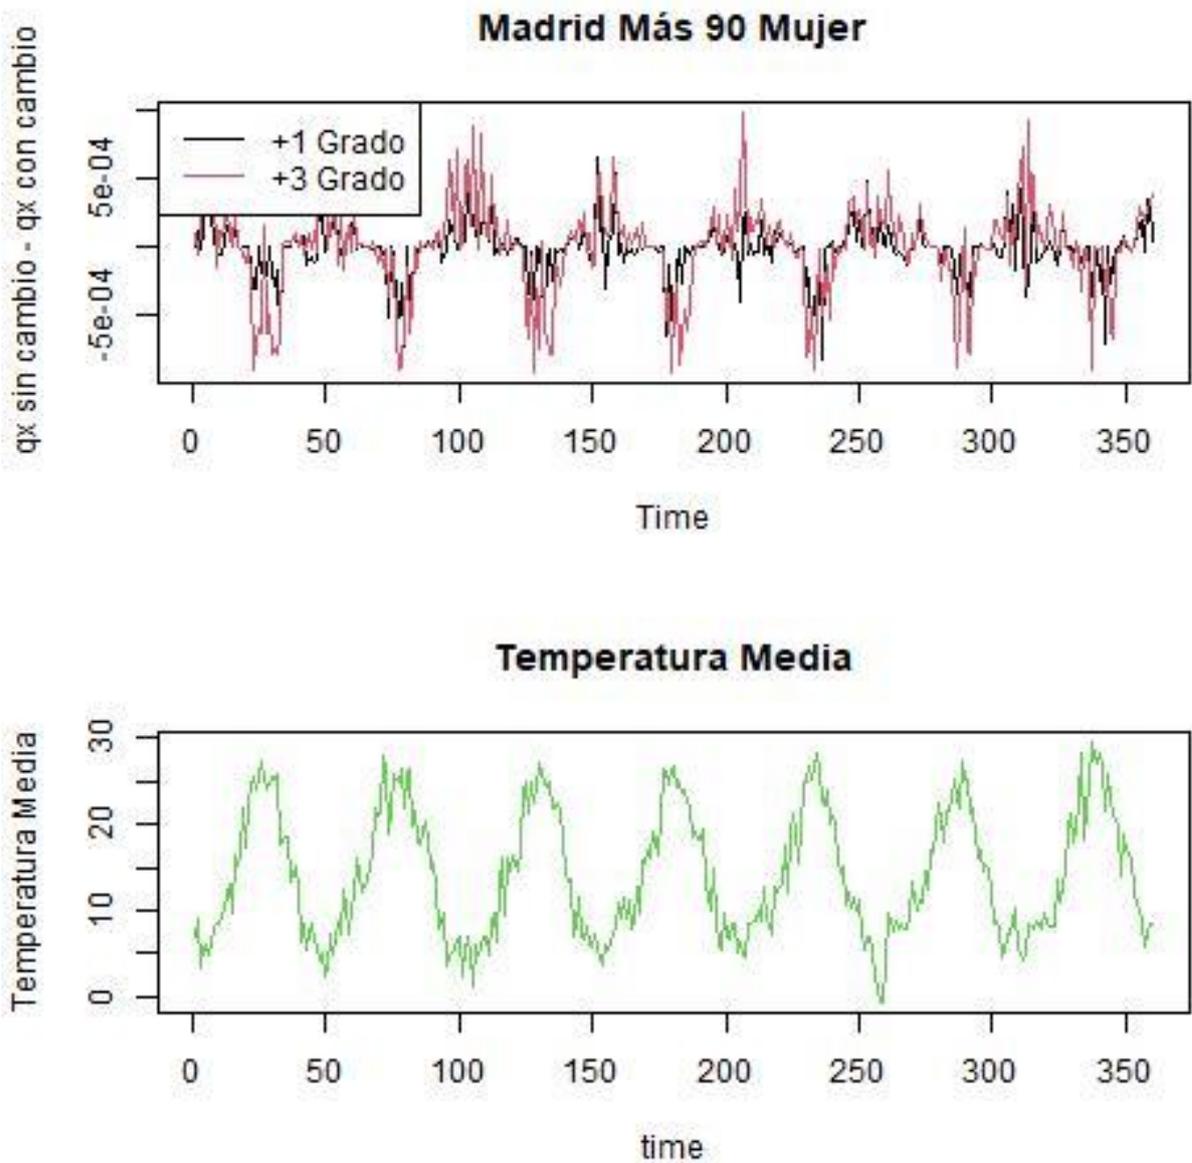
*Fuente: Elaboración propia*

La estimación para el caso de mujeres en el test funciona mejor que para hombres, siendo el periodo de la pandemia mal estimado por el modelo.

Igual que en el caso para hombres el efecto del aumento en la temperatura es significativo.

Figura 42

Efecto de una subida en uno y tres grados en la mortalidad junto con la temperatura media



Fuente: Elaboración propia

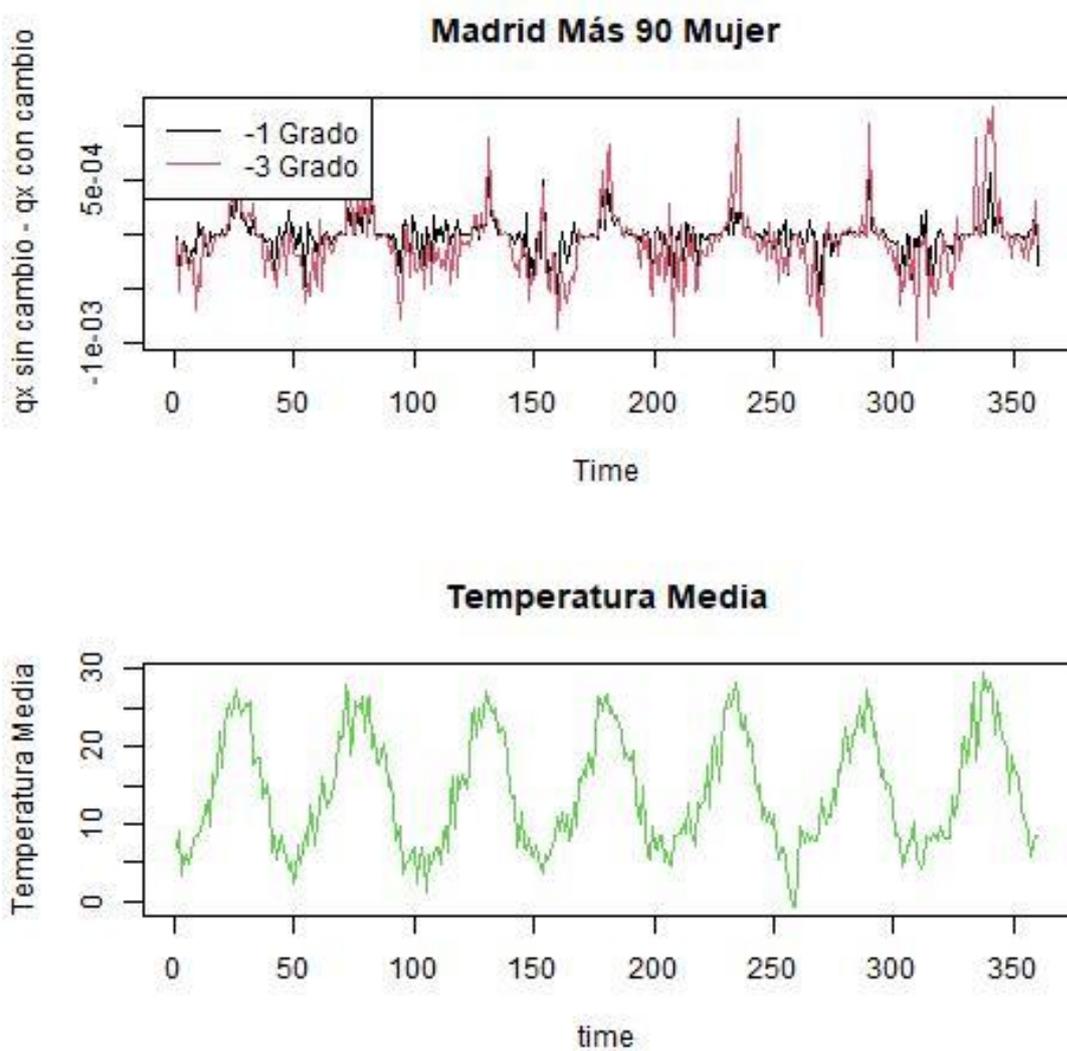
En el gráfico de arriba podemos ver el efecto del aumento de uno y tres grados mientras que en el de abajo podemos ver la temperatura media.

Tal y como se esperaba, de la misma forma que en hombres, el efecto del aumento de temperatura implica un aumento en la mortalidad en los periodos en los que la temperatura es alta, mientras que cuando la temperatura es baja el efecto de un aumento de esta resulta en una reducción de la mortalidad.

En conclusión, podemos ver como el modelo estima una mayor mortalidad con el aumento de la temperatura en periodos en la que esta es alta y una reducción en los que es baja, de la misma forma ocurre con la temperatura mínima (en rojo -3 grados y negro -1 grado) encontrando una mayor mortalidad cuando la reducción de temperatura se da en un momento en el que esta es baja y al contrario cuando la temperatura es alta:

**Figura 43**

*Efecto de una bajada en uno y tres grados en la mortalidad junto con la temperatura media*



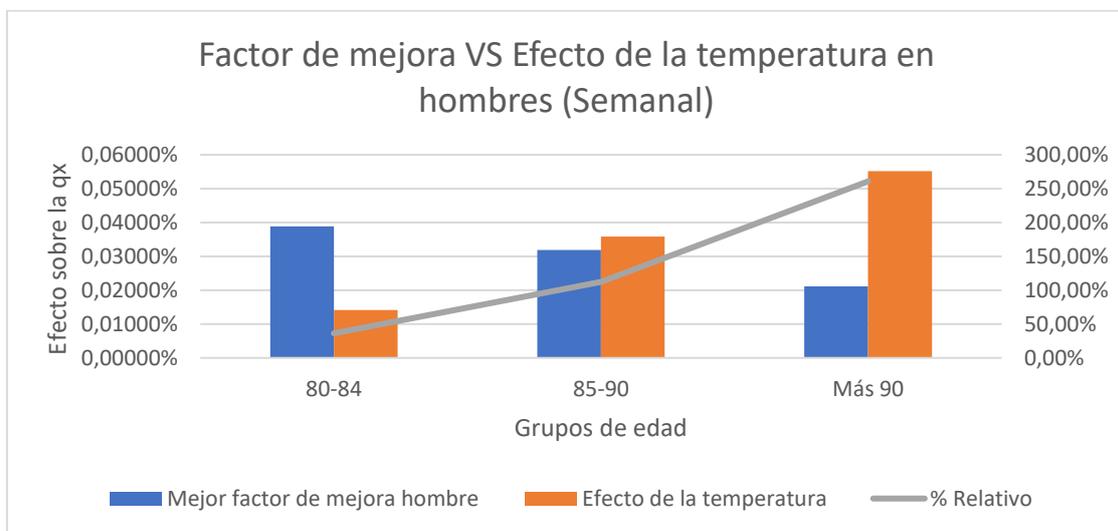
*Fuente: Elaboración propia*

## 6 COMPARACIÓN DEL EFECTO DE LA TEMPERATURA CON EL FACTOR DE MEJORA DE LA PER2020\_Ind\_2ndo.orden

Habiendo analizado los efectos de la temperatura en la mortalidad podemos comparar estos con el factor de mejora de la tabla de longevidad PER2020 y así comprobar a partir de que edad el efecto máximo sobre la mortalidad de la temperatura es mayor que la mejora propuesta por la tabla de longevidad.

**Figura 44**

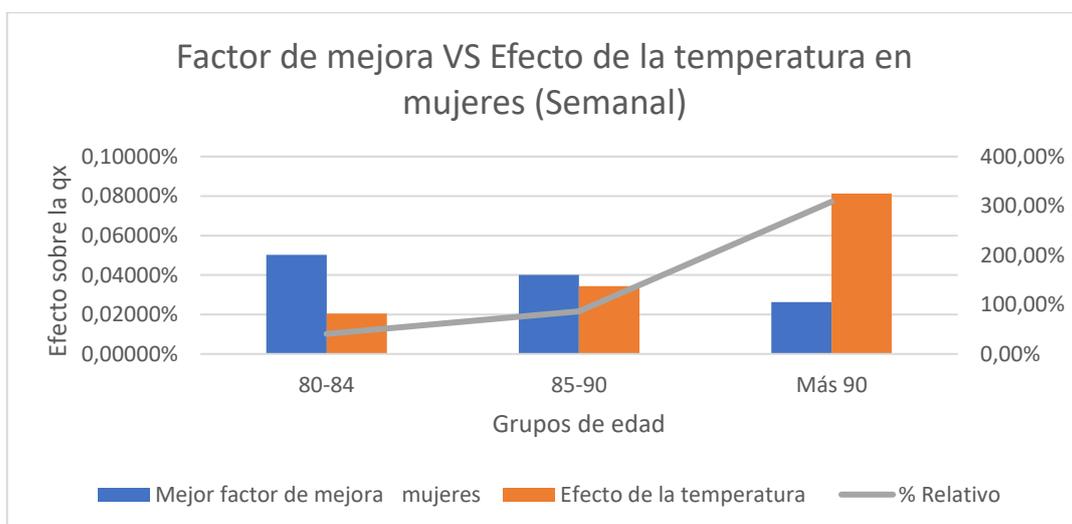
*Comparación del factor de mejora de longevidad con el mayor impacto de una subida de un grado en la mortalidad en hombres*



*Fuente: Elaboración propia, datos de factor de mejora del BOE (BOE)*

**Figura 45**

*Comparación del factor de mejora de longevidad con el mayor impacto de una subida de un grado en la mortalidad en mujeres*



*Fuente: Elaboración propia, datos de factor de mejora del BOE (BOE)*

Comparando los efectos para hombres y mujeres del aumento de la temperatura podemos decir que existe un aumento de hasta 0,05516% de mortalidad por un aumento de un grado de temperatura para mayores de 90 años en hombres siendo su factor de mejora para la longevidad usando la *PER2020\_Ind\_2ndo.orden* (BOE) para una cohorte después del 2012 de 0,02115% (aproximando el factor de mejora anual semanalmente como  $1 - e^{-\lambda/52}$ ) con lo que el aumento de la mortalidad en meses semanas con mucho calor es 2,6 veces mayor que el factor de mejora correspondiente para una cohorte de nacimiento superior para 90 años, para mujeres el factor de mejora es de un 0,02634% y el efecto de la temperatura máximo es de un 0,08124% con lo que el aumento en mortalidad semanal con mucho calor en mujeres es 3,08 veces mayor que el factor de mejora para personas con más de 90 años.

En hombres el factor de mejora de longevidad con un año de diferencia de cohorte es menor al efecto de un grado en la temperatura a partir de edades inferiores a 85 años mientras que para mujeres este es superior para edades inferiores a los 90 años, no obstante, la diferencia entre factores de mejora de longevidad para mujeres con respecto al efecto máximo de mortalidad por aumento de temperatura es mayor que para hombres.

## 7 CONCLUSIONES.

Este trabajo supone una primera toma de contacto con el Auto Machine Learning para el entorno actuarial y el primer trabajo para el caso de España, dentro de el hemos podido comprobar como las temperaturas tienen un impacto, que, aunque no trascendental para todos los grupos de edad, si significativo para los grupos de edad de más de 75 años, encontrando una relación mayor cuanto más edad tenga la persona.

También hemos podido comprobar gráficamente que el modelo no estima con la misma precisión para todas las provincias.

Además hemos podido encontrar que, para el caso de Madrid, en hombres el factor de mejora de longevidad con un año de diferencia de cohorte es menor al efecto de un grado en la temperatura a partir de edades inferiores a 85 años mientras que para mujeres este es superior para edades inferiores a los 90 años, no obstante, la diferencia entre factores de mejora de longevidad para mujeres con respecto al efecto máximo de mortalidad por aumento de temperatura es mayor que para hombres.

Para futuras líneas de investigación se podría ahondar en el efecto de la temperatura teniendo en cuenta todas las provincias de España, así como las diferencias por provincias de los aumentos y las disminuciones en la temperaturas.

## 8 BIBLIOGRAFÍA

- AEMET. (s.f.). *AEMET*. Obtenido de AEMET:  
<https://datosclima.es/Aemethistorico/Meteostation.php>
- EUROSTAT. (s.f.). *EUROSTAT*. Obtenido de EUROSTAT:  
[https://ec.europa.eu/eurostat/databrowser/view/DEMO\\_R\\_MWEEK3\\_\\_custom\\_5193854/default/table?lang=en](https://ec.europa.eu/eurostat/databrowser/view/DEMO_R_MWEEK3__custom_5193854/default/table?lang=en)
- Gasparri, A. G.-C. (2017). Projections of temperature-related excess mortality under climate change scenarios. *The Lancet Planetary Health*, 360-367.
- H2O. (s.f.). Obtenido de <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/variable-importance.html>
- INE. (s.f.). *INE*. Obtenido de INE: <https://www.ine.es/jaxiT3/Tabla.htm?t=2852>
- Lee, H. (2023). AR6 Synthesis Report. doi:<https://www.ipcc.ch/report/ar6/syr/>
- Mazaira, C. C. (2022). Modelo actuarial de la medida del impacto del cambio climático en los riesgos de mortalidad y longevidad. Obtenido de <https://e-archivo.uc3m.es/handle/10016/36527>
- McDermott-Levy, R. S. (2021). Factors That Influence Climate Change-Related Mortality in the United States: An Integrative Review. *International Journal of Environmental Research and Public Health*.  
doi:<http://dx.doi.org/10.3390/ijerph18158220>
- McMichael, A. J. (2006). Climate change and human health: present and future risks. *The Lancet*, 859-869.
- Patz, J. A.-L. (2005). Impact of regional climate change on human health. *Nature*, 310-317.
- Poirier, E. L. (s.f.). *H2O*. Obtenido de <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/automl.html?highlight=citation#citation>
- Vicedo-Cabrera, A. M. (2019). Excess mortality during the warm summer of 2015 in Switzerland. *Swiss Medical Weekly*, 149.
- Watts, N. A. (2015). Health and climate change: policy responses to protect public health. *The Lancet*, 1861-1914.

## ANEXO DE CÓDIGO:

```
setwd("D:/MCAF/TFM/Datos/DatosAgrup")
library(h2o)
library(tidyverse)
library(caret)
library(vip)
library(gridExtra)
library("readxl")
library(TSstudio)
library(ggplot2)
library(lubridate)

#####

#####

#####ANÁLISIS EN LAS 5
COMUNIDADES#####

#####HOMBRES#####

Train <- read_excel(file.choose())
Test <- read_excel(file.choose())
h2o.init(max_mem_size = "2G")

names <- colnames(Train)

y <- names[3]
x <- c(names[1],names[5:8],names[10:36])#Todo

#####

automl_model <-
  h2o.automl(
    x = x,
    y = y,
```

```

training_frame      = as.h2o(Train),
#nfold              = 5,
stopping_metric     = "RMSE",
#stopping_rounds    = 10,
#stopping_tolerance = 0.005,
max_runtime_secs    = 120,
seed                = 1
)

automl_model@leaderboard
aml_model <- automl_model@leader
h2o.saveModel(aml_model, "DatosAgrup",filename = "Modelo Hombres 5
comunidades")
jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/Importancia
de variables.png")
p_aml <- vip(aml_model) + ggtitle("AML Hombre, 5 comunidades")
grid.arrange(p_aml)
dev.off()
#####
perf_aml_model <-
  h2o.performance(aml_model, newdata = as.h2o(Test))

perf_aml_model

test_predict <- h2o.predict(object = aml_model,
                           newdata = as.h2o(Test))

predictions_x_real <- cbind(
  as.data.frame(as.h2o(Test$`Mortalidad Hombre`)),
  as.data.frame(test_predict[1:34200])
)

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/Guadalajara
Hombre 5 comunidades.png")

```

```

ts.plot(ts(predictions_x_real$x[1:6840]),ts(predictions_x_real$predict[1:
6841]),col= 1:2,main="Guadalajara Hombre",gpars = list(ylab=
"qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/Segovia
Hombre 5 comunidades.png")
ts.plot(ts(predictions_x_real$x[6841:(6841+6840-
1)]),ts(predictions_x_real$predict[6842:(6842+6840-1)]),col=
1:2,main="Segovia Hombre",gpars = list(ylab= "qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/Madrid
Hombre 5 comunidades.png")
ts.plot(ts(predictions_x_real$x[13681:(13681+6840-
1)]),ts(predictions_x_real$predict[13682:(13682+6840-1)]),col=
1:2,main="Madrid Hombre",gpars = list(ylab= "qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/A coruña
Hombre 5 comunidades.png")
ts.plot(ts(predictions_x_real$x[20521:(20521+6840-
1)]),ts(predictions_x_real$predict[20522:(20522+6840-1)]),col=
1:2,main="A coruña Hombre",gpars = list(ylab= "qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}

```

```

}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/Cádiz Hombre
5 comunidades.png")
ts.plot(ts(predictions_x_real$x[27361:(27361+6840-
1)]),ts(predictions_x_real$predict[27362:(27362+6840-1)]),col=
1:2,main="Cádiz Hombre",gpars = list(ylab= "qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

#####MUJERES#####
#####
y <- names[2]

#####

automl_model2 <-
  h2o.automl(
    x = x,
    y = y,
    training_frame = as.h2o(Train),
    #nfold = 5,
    stopping_metric = "RMSE",
    #stopping_rounds = 10,
    #stopping_tolerance = 0.005,
    max_runtime_secs = 120,
    seed = 2
  )

automl_model2@leaderboard
aml_model2 <- automl_model2@leader
h2o.saveModel(aml_model2, "DatosAgrup",filename = "Modelo Mujeres 5
comunidades")

```

```

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Importancia
de variables.png")
p_aml <- vip(aml_model2) + ggtitle("AML Mujer 5 provincias")
grid.arrange(p_aml)
dev.off()

#####

perf_aml_model2 <-
  h2o.performance(aml_model2, newdata = as.h2o(Test))

perf_aml_model2

test_predict2 <- h2o.predict(object = aml_model2,
                           newdata = as.h2o(Test))

predictions_x_real <- cbind(
  as.data.frame(as.h2o(Test$`Mortalidad Mujer`)),
  as.data.frame(test_predict2[1:34200])
)

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Guadalajara
Mujer 5 comunidades.png")
ts.plot(ts(predictions_x_real$x[1:6840]),ts(predictions_x_real$predict[1:
6841]),col= 1:2,main="Guadalajara Mujer",gpars = list(ylab=
"qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Segovia Mujer
5 comunidades.png")
ts.plot(ts(predictions_x_real$x[6841:(6841+6840-
1)]),ts(predictions_x_real$predict[6842:(6842+6840-1)]),col=
1:2,main="Segovia Mujer",gpars = list(ylab= "qx",xlab="NºDato"))

```

```

for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Madrid Mujer
5 comunidades.png")
ts.plot(ts(predictions_x_real$x[13681:(13681+6840-
1)]),ts(predictions_x_real$predict[13682:(13682+6840-1)]),col=
1:2,main="Madrid Mujer",gpars = list(ylab= "qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/A coruña
Mujer 5 comunidades.png")
ts.plot(ts(predictions_x_real$x[20521:(20521+6840-
1)]),ts(predictions_x_real$predict[20522:(20522+6840-1)]),col=
1:2,main="A coruña Mujer",gpars = list(ylab= "qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Cádiz Mujer 5
comunidades.png")
ts.plot(ts(predictions_x_real$x[27361:(27361+6840-
1)]),ts(predictions_x_real$predict[27362:(27362+6840-1)]),col=
1:2,main="Cádiz Mujer",gpars = list(ylab= "qx",xlab="NºDato"))
for (i in 1:18) {
  abline(v=360*i)
}
legend("topleft", legend = c("Real","Estimado"), col = 1:2, lty = 1)

```

```

dev.off()

#####
#####

#####MADRID#####
#####

#####HOMBRES#####
#####

y <- names[3]
TrainMad <- Train[!-(Train$GUADALAJARA == 1) ,]
TrainMad <- TrainMad[!-(TrainMad$SEGOVIA == 1) ,]
TrainMad <- TrainMad[!-(TrainMad$ACORUÑA == 1),]
TrainMad <- TrainMad[!-(TrainMad$CADIZ == 1),]

TestMad <- Test[!-(Test$GUADALAJARA == 1) ,]
TestMad <- TestMad[!-(TestMad$SEGOVIA == 1) ,]
TestMad <- TestMad[!-(TestMad$ACORUÑA == 1),]
TestMad <- TestMad[!-(TestMad$CADIZ == 1),]

#####
TestMadUno <- read_excel(file.choose())

TestMadUno <- TestMadUno[!-(TestMadUno$GUADALAJARA == 1) ,]
TestMadUno <- TestMadUno[!-(TestMadUno$SEGOVIA == 1) ,]
TestMadUno <- TestMadUno[!-(TestMadUno$ACORUÑA == 1),]
TestMadUno <- TestMadUno[!-(TestMadUno$CADIZ == 1),]

#####
TestMadMenosUno <- read_excel(file.choose())

TestMadMenosUno <- TestMadMenosUno[!-(TestMadMenosUno$GUADALAJARA == 1)
,]
TestMadMenosUno <- TestMadMenosUno[!-(TestMadMenosUno$SEGOVIA == 1) ,]
TestMadMenosUno <- TestMadMenosUno[!-(TestMadMenosUno$ACORUÑA == 1),]
TestMadMenosUno <- TestMadMenosUno[!-(TestMadMenosUno$CADIZ == 1),]

#####

```

```

TestMadTres <- read_excel(file.choose())

TestMadTres <- TestMadTres[!-(TestMadTres$GUADALAJARA == 1) ,]
TestMadTres <- TestMadTres[!-(TestMadTres$SEGOVIA == 1) ,]
TestMadTres <- TestMadTres[!-(TestMadTres$ACORUÑA == 1),]
TestMadTres <- TestMadTres[!-(TestMadTres$CADIZ == 1),]
#####

TestMadMenosTres <- read_excel(file.choose())

TestMadMenosTres <- TestMadMenosTres[!-(TestMadMenosTres$GUADALAJARA ==
1) ,]
TestMadMenosTres <- TestMadMenosTres[!-(TestMadMenosTres$SEGOVIA == 1) ,]
TestMadMenosTres <- TestMadMenosTres[!-(TestMadMenosTres$ACORUÑA == 1),]
TestMadMenosTres <- TestMadMenosTres[!-(TestMadMenosTres$CADIZ == 1),]
#####

names <- colnames(TrainMad)

y <- names[3]
#####

automl_model3 <-
  h2o.automl(
    x = x,
    y = y,
    training_frame      = as.h2o(TrainMad),
    #nfold               = 5,
    stopping_metric     = "RMSE",
    #stopping_rounds    = 10,
    #stopping_tolerance = 0.005,
    max_runtime_secs   = 120,
    seed                = 3
  )

automl_model3@leaderboard
aml_model3 <- automl_model3@leader

```

```

h2o.saveModel(aml_model2, "DatosAgrup",filename = "Modelo Hombres
Madrid")

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados
Hombre/V2/Madrid/Importancia de variables.png")

p_aml <- vip(aml_model3) + ggtitle("AML Hombre Madrid")
grid.arrange(p_aml)
dev.off()

#####
####

#####EFECTO CON CAMBIOS DE
TEMPERATURA#####

#####

perf_aml_model3 <-
  h2o.performance(aml_model3, newdata = as.h2o(TestMad))

perf_aml_model3

test_predict <- h2o.predict(object = aml_model3,
                           newdata = as.h2o(TestMad))

predictions_x_real <- cbind(
  as.data.frame(as.h2o(TestMad$`Mortalidad Hombre`)),
  as.data.frame(test_predict[1:6840])
)

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/Madrid/Real
vs Estimado más de 90 años.png")

ts.plot(ts(predictions_x_real$x[(6840-360):6840])
        ,ts(predictions_x_real$predict[(6840-360):6840]),
        col= 1:2,main="Madrid Más 90",gpars = list(xlab="year",ylab=
"mortality"))
dev.off()

#####

perf_aml_model <-

```

```

h2o.performance(aml_model3, newdata = as.h2o(TestMadUno))

perf_aml_model

test_predict <- h2o.predict(object = aml_model3,
                           newdata = as.h2o(TestMadUno))

predictions_x_real2 <- cbind(
  as.data.frame(as.h2o(TestMadUno$`Mortalidad Hombre`)),
  as.data.frame(test_predict[1:6840])
)

#####

perf_aml_model <-
  h2o.performance(aml_model3, newdata = as.h2o(TestMadMenosUno))

perf_aml_model

test_predict <- h2o.predict(object = aml_model3,
                           newdata = as.h2o(TestMadMenosUno))

predictions_x_real3 <- cbind(
  as.data.frame(as.h2o(TestMadMenosUno$`Mortalidad Hombre`)),
  as.data.frame(test_predict[1:6840])
)

#####

perf_aml_model <-
  h2o.performance(aml_model3, newdata = as.h2o(TestMadTres))

perf_aml_model

test_predict <- h2o.predict(object = aml_model3,
                           newdata = as.h2o(TestMadTres))

```

```

predictions_x_real4 <- cbind(
  as.data.frame(as.h2o(TestMadTres$`Mortalidad Hombre`)),
  as.data.frame(test_predict[1:6840])
)

#####

perf_aml_model <-
  h2o.performance(aml_model3, newdata = as.h2o(TestMadMenosTres))

perf_aml_model

test_predict <- h2o.predict(object = aml_model3,
                           newdata = as.h2o(TestMadMenosTres))

predictions_x_real5 <- cbind(
  as.data.frame(as.h2o(TestMadMenosTres$`Mortalidad Hombre`)),
  as.data.frame(test_predict[1:6840])
)

#####
#####

#####+1 y
+3#####

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/Madrid/qx
sin cambio - qx con cambio +1+3 mas 90.png")
par( mfrow= c(2,1) )
ts.plot(ts(predictions_x_real$predict[6481:6840])-
ts(predictions_x_real2$predict[6481:6840]),
        ts(predictions_x_real$predict[6481:6840])-
ts(predictions_x_real4$predict[6481:6840]),
        col= 1:2,main="Madrid Más 90 Hombre",gpars = list(ylab= "qx sin
cambio - qx con cambio"))

legend("topleft", legend = c("+1 Grado", "+3 Grado"), col = 1:2, lty = 1)

```

```

-min((predictions_x_real$predict[(6481-360*3):(6840-360*3)])-
ts(predictions_x_real2$predict[(6481-360*3):(6840-360*3)]))
-min((predictions_x_real$predict[(6481-360*2):(6840-360*2)])-
ts(predictions_x_real2$predict[(6481-360*2):(6840-360*2)]))
-min((predictions_x_real$predict[(6481-360):(6840-360)])-
ts(predictions_x_real2$predict[(6481-360):(6840-360)]))
-min((predictions_x_real$predict[6481:6840])-
ts(predictions_x_real2$predict[6481:6840]))

ts.plot(ts(TestMad$TMEDIA[1:360]),
        col= 3,main="Temperatura Media",gpars = list(xlab="time",ylab=
"Temperatura Media"))
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Hombre/V2/Madrid/qx
sin cambio - qx con cambio -1-3 mas 90.png")
par( mfrow= c(2,1) )
ts.plot(ts(predictions_x_real$predict[6481:6840])-
ts(predictions_x_real3$predict[6481:6840]),
        ts(predictions_x_real$predict[6481:6840])-
ts(predictions_x_real5$predict[6481:6840]),
        col= 1:2,main="Madrid Más 90 Hombre",gpars = list(ylab= "qx sin
cambio - qx con cambio"))

legend("topleft", legend = c("-1 Grado","-3 Grado"), col = 1:2, lty = 1)
ts.plot(ts(TestMad$TMEDIA[1:360]),
        col= 3,main="Temperatura Media",gpars = list(xlab="time",ylab=
"Temperatura Media"))
dev.off()

#####Plot del efecto de la temperatura en todos los grupos de
edad#####
jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados
Hombre/V2/Madrid/Efecto en todas las edades cambio temperatura.png")
par( mfrow= c(1,1) )
ts.plot((ts(predictions_x_real$predict[1:6840])-
ts(predictions_x_real2$predict[1:6840])),

```

```

        (ts(predictions_x_real$predict[1:6840])-
ts(predictions_x_real4$predict[1:6840])),
        col= 3:4,main="Efecto de la temperatura aumentando la edad",gpars
= list(ylab= "qx sin cambio - qx con cambio"))

for (i in 1:18) {
  abline(v=360*i)
}

legend("topleft", legend = c("+1 Grado","+3 Grado"), col = 3:4, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados
Hombre/V2/Madrid/Efecto Absoluto en todas las edades cambio
temperatura.png")

ts.plot((abs(ts((predictions_x_real$predict[1:6840])-
ts(predictions_x_real2$predict[1:6840])))),
        (abs(ts((predictions_x_real$predict[1:6840])-
ts(predictions_x_real4$predict[1:6840])))),
        col= 3:4,main="Efecto absoluto de la temperatura aumentando la
edad",gpars = list(ylab= "qx sin cambio - qx con cambio"))

for (i in 1:18) {
  abline(v=360*i)
}

legend("topleft", legend = c("+1 Grado","+3 Grado"), col = 3:4, lty = 1)
dev.off()

#####MUJERES#####
#####

y <- names[2]

#####

automl_model4 <-
  h2o.automl(
    x = x,
    y = y,
    training_frame = as.h2o(TrainMad),

```

```

#nfolde      = 5,
stopping_metric = "RMSE",
#stopping_rounds = 10,
#stopping_tolerance = 0.005,
max_runtime_secs = 120,
seed           = 4
)

automl_model4@leaderboard
aml_model4 <- automl_model4@leader
h2o.saveModel(aml_model2, "DatosAgrup",filename = "Modelo Mujeres
Madrid")
jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados
Mujer/V2/Madrid/Importancia de variables.png")
p_aml <- vip(aml_model4) + ggtitle("AML Mujer")
grid.arrange(p_aml)
dev.off()

#####
#####
#####EFECTO CON CAMBIOS DE
TEMPERATURA#####
#####

perf_aml_model4 <-
  h2o.performance(aml_model4, newdata = as.h2o(TestMad))

perf_aml_model4

test_predict <- h2o.predict(object = aml_model4,
                           newdata = as.h2o(TestMad))

predictions_x_real <- cbind(
  as.data.frame(as.h2o(TestMad$`Mortalidad Mujer`)),
  as.data.frame(test_predict[1:6840])
)

```

```

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Madrid/Real
vs Estimado más de 90 años.png")
ts.plot(ts(predictions_x_real$x[(6840-360):6840])
        ,ts(predictions_x_real$predict[(6840-360):6840]),
        col= 1:2,main="Madrid Más 90",gpars = list(xlab="year",ylab=
"mortality"))
dev.off()
#####

perf_aml_model4 <-
  h2o.performance(aml_model4, newdata = as.h2o(TestMadUno))

perf_aml_model4

test_predict <- h2o.predict(object = aml_model4,
                           newdata = as.h2o(TestMadUno))

predictions_x_real2 <- cbind(
  as.data.frame(as.h2o(TestMadUno$`Mortalidad Mujer`)),
  as.data.frame(test_predict[1:6840])
)

#####

perf_aml_model4 <-
  h2o.performance(aml_model4, newdata = as.h2o(TestMadMenosUno))

perf_aml_model4

test_predict <- h2o.predict(object = aml_model4,
                           newdata = as.h2o(TestMadMenosUno))

predictions_x_real3 <- cbind(
  as.data.frame(as.h2o(TestMadMenosUno$`Mortalidad Mujer`)),
  as.data.frame(test_predict[1:6840])
)

```

```
#####
perf_aml_model4 <-
  h2o.performance(aml_model4, newdata = as.h2o(TestMadTres))

perf_aml_model4

test_predict <- h2o.predict(object = aml_model4,
                           newdata = as.h2o(TestMadTres))

predictions_x_real4 <- cbind(
  as.data.frame(as.h2o(TestMadTres$`Mortalidad Mujer`)),
  as.data.frame(test_predict[1:6840])
)

#####
perf_aml_model4 <-
  h2o.performance(aml_model4, newdata = as.h2o(TestMadMenosTres))

perf_aml_model4

test_predict <- h2o.predict(object = aml_model4,
                           newdata = as.h2o(TestMadMenosTres))

predictions_x_real5 <- cbind(
  as.data.frame(as.h2o(TestMadMenosTres$`Mortalidad Mujer`)),
  as.data.frame(test_predict[1:6840])
)

#####
#####

#####+1 y
+3#####
```

```

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Madrid/qx sin
cambio - qx con cambio +1+3 mas 90.png")
par( mfrow= c(2,1) )
ts.plot(ts(predictions_x_real$predict[6481:6840])-
ts(predictions_x_real2$predict[6481:6840]),
      ts(predictions_x_real$predict[6481:6840])-
ts(predictions_x_real4$predict[6481:6840]),
      col= 1:2,main="Madrid Más 90 Mujer",gpars = list(ylab= "qx sin
cambio - qx con cambio"))

legend("topleft", legend = c("+1 Grado","+3 Grado"), col = 1:2, lty = 1)

-min((predictions_x_real$predict[(6481-360*3):(6840-360*3)])-
ts(predictions_x_real2$predict[(6481-360*3):(6840-360*3)]))
-min((predictions_x_real$predict[(6481-360*2):(6840-360*2)])-
ts(predictions_x_real2$predict[(6481-360*2):(6840-360*2)]))
-min((predictions_x_real$predict[(6481-360):(6840-360)])-
ts(predictions_x_real2$predict[(6481-360):(6840-360)]))
-min((predictions_x_real$predict[6481:6840])-
ts(predictions_x_real2$predict[6481:6840]))

ts.plot(ts(TestMad$TMEDIA[1:360]),
      col= 3,main="Temperatura Media",gpars = list(xlab="time",ylab=
"Temperatura Media"))
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Madrid/qx sin
cambio - qx con cambio -1-3 mas 90.png")
par( mfrow= c(2,1) )
ts.plot(ts(predictions_x_real$predict[6481:6840])-
ts(predictions_x_real3$predict[6481:6840]),
      ts(predictions_x_real$predict[6481:6840])-
ts(predictions_x_real5$predict[6481:6840]),
      col= 1:2,main="Madrid Más 90 Mujer",gpars = list(ylab= "qx sin
cambio - qx con cambio"))

legend("topleft", legend = c("-1 Grado","-3 Grado"), col = 1:2, lty = 1)

```

```

ts.plot(ts(TestMad$TMEDIA[1:360]),
        col= 3,main="Temperatura Media",gpars = list(xlab="time",ylab=
"Temperatura Media"))
dev.off()

#####Plot del efecto de la temperatura en todos los grupos de
edad#####

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Madrid/Efecto
en todas las edades cambio temperatura.png")
par( mfrow= c(1,1) )
ts.plot((ts(predictions_x_real$predict[1:6840])-
ts(predictions_x_real2$predict[1:6840])),
        (ts(predictions_x_real$predict[1:6840])-
ts(predictions_x_real4$predict[1:6840])),
        col= 3:4,main="Efecto de la temperatura aumentando la edad",gpars
= list(ylab= "qx sin cambio - qx con cambio"))

for (i in 1:18) {
  abline(v=360*i)
}

legend("topleft", legend = c("+1 Grado","+3 Grado"), col = 3:4, lty = 1)
dev.off()

jpeg(file="D:/MCAF/TFM/Datos/DatosAgrup/Resultados Mujer/V2/Madrid/Efecto
absoluto en todas las edades cambio temperatura.png")
ts.plot((abs(ts((predictions_x_real$predict[1:6840])-
ts(predictions_x_real2$predict[1:6840])))),
        (abs(ts((predictions_x_real$predict[1:6840])-
ts(predictions_x_real4$predict[1:6840])))),
        col= 3:4,main="Efecto de la temperatura aumentando la edad",gpars
= list(ylab= "qx sin cambio - qx con cambio"))

for (i in 1:18) {
  abline(v=360*i)
}

legend("topleft", legend = c("+1 Grado","+3 Grado"), col = 3:4, lty = 1)

```

```
dev.off()
```